

МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное учреждение высшего
образования «Пензенский государственный технологический университет»

На правах рукописи



Танцеров Александр Хабибуллоевич

**МЕТОДЫ ИНТЕЛЛЕКТУАЛЬНОГО АНАЛИЗА ДИНАМИЧЕСКИХ
ПАРАМЕТРОВ ПОДПИСИ НА ОСНОВЕ ИСКУССТВЕННЫХ
НЕЙРОННЫХ СЕТЕЙ**

Специальность: 2.3.8 – Информатика и информационные процессы
(технические науки)

Диссертация
на соискание ученой степени
кандидата технических наук

Научный руководитель –
кандидат технических наук
Данилов Е.А.

СОДЕРЖАНИЕ

СПИСОК СОКРАЩЕНИЙ.....	5
ВВЕДЕНИЕ.....	6
1. СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОЛОГИЙ И АЛГОРИТМИЧЕСКИХ ПОДХОДОВ К СОПОСТАВЛЕНИЮ И КЛАССИФИКАЦИИ РЕАЛИЗАЦИЙ ДИНАМИЧЕСКОЙ ПОДПИСИ	17
1.1. Анализ современного методологического и технического уровня методов регистрации, предобработки, выделения признаков и сопоставления реализаций динамической подписи	17
1.2. Обзор математических методов и подходов к анализу, сопоставлению и классификации по динамическим параметрам подписи	24
1.3. Обоснование нейросетевых алгоритмов как решений задач анализа и классификации многомерных сигнатур динамической подписи	35
1.4. Выводы по первой главе и общая постановка задач исследований...	42
2. МЕТОДЫ ПРЕДСТАВЛЕНИЯ БИОМЕТРИЧЕСКИХ ДАННЫХ В НЕЙРОСЕТЕВОМ ВЫЧИСЛИТЕЛЬНОМ БАЗИСЕ.....	43
2.1. Метод обработки и расширения признакового описания динамических параметров подписи на множестве функционально связанных многомерных кривых.....	43
2.2. Метод эталонирования реализаций динамической подписи на основе SOM в пространстве функционально связанных многомерных кривых .	58
2.3. Основные современные архитектуры нейронных сетей для классификации различных форм представления многомерных кривых динамической подписи	73
2.4. Методика нейросетевого отождествления образца динамической сигнатуры подписи с эталонами по кортежу уникальных матриц синаптических коэффициентов межнейронных связей	76
2.5. Выводы по второй главе.....	80

3. МЕТОДИКИ И АЛГОРИТМЫ АНАЛИЗА, СОПОСТАВЛЕНИЯ И КЛАССИФИКАЦИИ РЕАЛИЗАЦИЙ ДИНАМИЧЕСКОЙ ПОДПИСИ НА ОСНОВЕ НЕЙРОСЕТЕВОГО ВЫЧИСЛИТЕЛЬНОГО БАЗИСА	82
3.1. Постановка задач анализа и классификации динамической сигнатуры подписи на основе функционального подхода и многоточечного представления статистических характеристик семейства кривых	82
3.2. Структурный синтез нейросетевых архитектур анализа и классификации динамических параметров подписи в пространстве отсчетов многомерных кривых	84
3.3. Структурный синтез нейросетевых архитектур анализа и классификации динамических параметров подписи в пространстве вторичных признаков многомерных кривых	90
3.4. Методика классификации динамической сигнатуры в пространстве многоточечного представления инвариантов	98
3.5. Алгоритм комплексного анализа и классификации динамической сигнатуры подписи в пространстве отсчетов многомерных кривых.....	102
3.6. Выводы по третьей главе.....	109
4. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ И ПРЕДЛОЖЕНИЯ ПО ПРАКТИЧЕСКОЙ РЕАЛИЗАЦИИ РАЗРАБОТАННЫХ МЕТОДОВ	111
4.1. Программные реализации макета программного комплекса моделирования, эталонирования, сопоставления и классификации динамической сигнатуры подписи	111
4.2. Экспериментальное сравнение нейросетевых алгоритмов классификации динамической подписи в пространстве отсчетов многомерных кривых с базовыми алгоритмами сопоставления многомерных сигналов	121
4.3. Предложения по организации хранения эталонных представлений динамической подписи на основе специализированных баз данных	

временных рядов и уникальных матриц синаптических коэффициентов межнейронных связей.....	127
4.4. Предложения по облику системы передачи данных и децентрализованной структуре центров обработки и анализа динамической подписи	130
4.5. Выводы по четвертой главе.....	132
ЗАКЛЮЧЕНИЕ	135
СПИСОК ЛИТЕРАТУРЫ.....	139
ПРИЛОЖЕНИЕ 1. СВИДЕТЕЛЬСТВА О РЕГИСТРАЦИИ ПРОГРАММ	150
ПРИЛОЖЕНИЕ 2. АКТЫ О ВНЕДРЕНИИ	154

СПИСОК СОКРАЩЕНИЙ

ДВП – дискретное вейвлет-преобразование;

ДПФ – дискретное преобразование Фурье;

ЕБС – Единая биометрическая система;

ИИ – Искусственный интеллект;

МТО – многоточечный объект;

НС – нейронная сеть;

СКО – среднеквадратическое отклонение;

СПО – специальное программное обеспечение;

MLP – (*Multilayer Perceptron*) – многослойный перцептрон;

TSDB – (*Time Series Database*) – база данных временных рядов;

FAR – (*False Acceptance Rate*) – коэффициент ложного допуска;

FRR – (*False Rejection Rate*) – коэффициент ложного отказа;

EER – (*Equal Error Rate*) – уровень равных ошибок.

ВВЕДЕНИЕ

В современном цифровом мире, где информационные технологии проникают во все сферы нашей жизни, качество сбора, обработки и интерпретации персонализированных данных становится вопросом первостепенной важности. В этом контексте использование биометрических данных является одним из наиболее перспективных подходов к анализу индивидуальных поведенческих и моторных паттернов. Биометрические методы анализа и классификации приобретают массовое распространение в большинстве персональных и корпоративных электронных устройств и систем [1-3].

Рукописные подписи как биометрический источник данных для анализа индивидуальных особенностей являются предметом научных исследований более 40 лет, поскольку оцифрованная статическая подпись человека относится к одному из самых дешёвых и доступных по реализации способов получения и обработки рукописного образа. Развитие современных цифровых технологий существенно повышает доступность средств воспроизведения статического изображения подписи, что снижает информативность статического представления и усиливает интерес к анализу динамических характеристик процесса подписания [4-6].

Между тем, лишь в последнее десятилетие, с развитием и распространением доступных технологий получения и обработки динамических данных процесса постановки подписи (с помощью планшетов, смартфонов, оснащенных специализированными сенсорными экранами), фокус научных исследований сместился в область интеллектуального анализа и классификации сигнатуры динамической подписи по многомерным временным данным.

Анализ динамической подписи является одним из наиболее значимых направлений в области поведенческой биометрии, поскольку позволяет работать с информативными многомерными временными

рядами и учитывать внутрикласовую вариативность исполнения. Такие системы анализируют не статическое изображение, а многомерный временной ряд, описывающий процесс ее создания. Это включает в себя анализ кинетических параметров, таких как скорость, ускорение, и инструментальных характеристик, в частности, давление пера и др.

Динамическая подпись востребована в прикладных сценариях, связанных с электронным документооборотом и удалённым вводом рукописных данных, где важны устойчивость сопоставления и корректная классификация реализаций при вариативности исполнения и различиях в аппаратуре регистрации. В этих условиях ключевое значение приобретают методы нормализации, расширения признакового пространства, эталонирования и нейросетевой классификации, обеспечивающие воспроизводимое качество обработки многомерных временных рядов.

Динамическая подпись частично свободна от недостатков, свойственных статической подписи, однако и для нее остро стоит проблема устойчивости анализа и качества классификации реализаций, обусловленная [7-12]:

- 1) зависимостью реализации подписи от параметров датчиков-преобразующей аппаратуры;
- 2) вариабельностью постановки для одного и того же исполнителя, обусловленной эмоциями, стрессом и другими факторами.

Самая большая проблема – непредсказуемая межличностная изменчивость, позволяющая осуществлять не обнаруживаемую со 100% вероятностью подделки.

Таким образом возникает **прагматическое противоречие**, заключающееся, с одной стороны, в наличии гигантской потребности в использовании методов интеллектуального анализа и сопоставления динамической подписи в широком спектре приложений (т.е. необходимостью внедрения в различных отраслях сравнительно дешевого и оперативного способа обработки рукописных данных), с другой стороны

– ограничениями по качеству сопоставления и классификации, обусловленными высокой вариабельностью и параметрической неопределенностью состояния исполнителя и датчико-преобразующей аппаратуры сенсорных средств.

Одним из направлений разрешения подобного прагматического противоречия является расширение пространства признаков и регуляризация решения задачи классификации, обусловленной ненаблюдаемыми состояниями пользователя и аппаратуры регистрации, на основе методологии решения некорректных задач А. Н. Тихонова [13, 14].

Дополнительно, математически это усугубляется отсутствием единого сличаемого шаблона, малым количеством примеров для статистических методов, многомерностью и априорной неопределенности относительно информативности признаков для тех или иных состояний исполнения подписи.

Таким образом возникает **научное противоречие**, связанное, с одной стороны, с необходимостью сопоставлять и классифицировать образцы динамической подписи, обладающей внутриклассовой вариабельностью, обусловленной ненаблюдаемыми переменными процесса постановки подписи, с другой стороны – отсутствием научной методологии математического представления многомерных кривых и их обобщения на новые (вне обучающей выборки) реализации в условиях большого числа классов.

Степень разработанности темы. Исследования в области интеллектуального анализа динамических параметров подписи активно развиваются, и для работы с большими объемами данных всё шире используются методология и средства машинного обучения. Так, в обзорных исследованиях *S. M. Lucas, R. I. Damper, J. Bromley* (1989–1993) описаны ранние применения синтактических нейросетей для проверки динамической подписи. *K. Spałka, M. Zalasinski, L. Rutkowski* (2014-2019) предлагался гибридный подход для динамической проверки подлинности

подписи. *Songxuan Lai* и *Lianwen Jin* в 2017-2019 годах получили первые результаты связанные с синтезом обучающих выборок динамической подписи. Авторами *Ruben Tolosana*, *Ruben Vera-Rodriguez*, *Julián Fierrez*, *Javier Ortega-García* в работе “*DeepSign: Deep On-Line Signature Verification*” (2020) предложена архитектура TA-RNN (*Time-Aligned Recurrent Neural Networks*), объединяющая *Dynamic Time Warping* и рекуррентные нейронные сети. И наконец, *Moises Diaz*, *Miguel A. Ferrer* и соавторы в цикле работ с завершающей статьей “*Neural network modelling of kinematic and dynamic features for signature verification*” (2024) апробировали методологию использования синтетических выборок для оценки кинематических и динамических параметров (угловая скорость/позиция, момент силы).

В отечественной научной школе последователи Журавлёва Ю.И. (МГУ) активно развивают методы машинного обучения для задач биометрической классификации, в том числе и для анализа подписи. Его школа заложила фундаментальные основы для многих современных исследований в России. Группа Котлярова И.Д. (СПбПУ) провела одну из самых цитируемых и практических работ в области. Они разработали и подробно исследовали свёрточные нейронные сети (*CNN*) и рекуррентные нейронные сети (*RNN*), в частности *LSTM*-сети, для верификации динамической подписи. Команда Соколова А.В. (МЭИ) сфокусирована на различных архитектурах нейронных сетей, методах обработки временных рядов данных подписи и повышения устойчивости систем к подделкам. В работах А. И. Иванова и соавт. сформирована отечественная линия высокоразмерной нейросетевой биометрии «биометрия→код»: предложены методы ускорённого тестирования с синтетическим расширением выборок и априорным описанием распределений выходных кодов, а также анализ в пространстве расстояний Хэмминга для оценки энтропии и устойчивости на малых выборках; показана применимость к рукописным автографам.

При этом существующий в различных научных школах научно-методический аппарат приложения методов нейроинформатики напрямую (подачей отсчетов кривых реализаций на вход нейронной сети), не дает удовлетворительного результата, т.к. зашумленность данных и их вариабельность не сформируют четкие, как правило, замкнутые области классов (персон пользователей) в пространстве отсчетов многомерных кривых [15-17]. Объем обучающей выборки и число классов обуславливают все классические признаки «проклятия размерностей» прямого решения такой задачи.

Таким образом, в эпоху четвертой промышленной революции, тема диссертации «Методы интеллектуального анализа динамических параметров подписи на основе искусственных нейронных сетей» является **актуальной** и обусловлена необходимостью повышения качества интеллектуального анализа динамических параметров подписи, при росте числа пользователей информационных систем и сервисов, где требуется персонализация данных.

Объект исследования – информационные процессы регистрации, предобработки и анализа динамических параметров подписи.

Предмет исследования – методы и алгоритмы выделения признаков, нормализации, эталонирования и классификации реализаций динамической подписи с применением искусственных нейронных сетей.

Цель работы состоит в повышении качества сопоставления и классификации реализаций динамической подписи на основе экстраполяции дополнительных параметров и нейросетевых методов эталонирования при вариативности исполнения и различиях в аппаратуре регистрации.

Для достижения поставленной цели исследования определены следующие задачи:

1. Провести анализ существующих методов сопоставления и классификации реализаций динамической подписи по ее параметрам, определить их функциональные возможности.

2. Разработать метод обработки и расширения дополнительных динамических параметров подписи по кортежу стандартных параметров сенсорного устройства, обеспечивающий повышение качества анализа и устойчивости сопоставления.

3. Разработать метод эталонирования реализаций динамической подписи (парольной фразы) для задач кластеризации, классификации и сопоставления в нейросетевом вычислительном базисе.

4. Разработать методику отождествления образца динамической подписи с эталонами на основе кортежа уникальных матриц синаптических коэффициентов межнейронных связей многослойной нейросети.

5. Усовершенствовать методику нейросетевого анализа и сопоставления динамической сигнатуры в пространстве многоточечного представления статистических характеристик семейства кривых, определить инварианты и метрики сравнения, рассматриваемые как дополнительные динамические признаки.

6. Провести экспериментальные исследования для подтверждения гипотезы расширения числа учитываемых биометрических параметров, сформулировать предложения по практической реализации разработанных методов и алгоритмов.

Методы исследования. Исследования проведены с применением основ системотехники, теории вероятностей и математической статистики, теории случайных процессов, статистической теории принятий решений, методов нейроинформатики. Практическая часть выполнена с использованием методов математического моделирования, технологий объектно-ориентированного программирования.

Научная новизна исследования состоит в следующем.

1. Разработан метод обработки и расширения признакового описания динамической подписи на множестве функционально связанных многомерных кривых, основанный на экстраполяции дополнительных динамических параметров из стандартного кортежа сенсорных измерений и формировании расширенных (синтетических) признаков. Данное отличие позволило повысить информативность признакового пространства и обеспечило достижение метрики качества модели 0,95, что на 25–35 % превышает показатели известных статистических методов и на 5–15 % — метрических алгоритмов.

2. Разработан метод эталонирования биометрических реализаций подписи на основе самоорганизующихся карт Кохонена (*SOM*), отличающийся алгоритмом взвешивания признаков для учета их разной информативности и адаптивной процедурой подбора числа эталонов. Введенные отличия позволяют компенсировать внутриклассовую вариативность подписи и снизить вероятность ложного отказа (*FRR*) до уровня 0,12.

3. Разработана методика отождествления образца динамической подписи с эталонами, отличающаяся декомпозицией вычислительной процедуры на последовательный прогон по кортежу уникальных послонных матриц синаптических коэффициентов и введением класса «отказ от распознавания». Такая архитектура позволяет жестко фильтровать аномальные реализации и минимизировать вероятность ложного допуска (*FAR*) до уровня 0,08.

4. Усовершенствована методика нейросетевого анализа и классификации динамической сигнатуры, отличающаяся представлением каждой реализации в виде многоточечного набора статистических характеристик семейства кривых. Данный подход обеспечивает сбалансированное соотношение надежности и точности системы: при настройке порогового параметра (чувствительности) около 0,06

интегрированный показатель равной вероятности ошибок (*EER*) достигает 0,09.

Соответствие паспорту научной специальности. Область исследования, обозначенная в паспорте специальности 2.3.8. «Информатика и информационные процессы», охватывает следующие направления:

– разработка компьютерных методов и моделей описания, оценки и оптимизации информационных процессов и ресурсов, а также средств анализа и выявления закономерностей на основе обмена информацией пользователями и возможностей используемого программно-аппаратного обеспечения (п. 1);

– разработка методов и алгоритмов кодирования, сжатия и размещения информации для повышения эффективности и надежности функционирования инфокоммуникационных систем при её хранении и передаче (п.3);

– разработка и применение методов распознавания образов, кластерного анализа, нейросетевых и нечетких технологий, решающих правил, мягких вычислений при анализе разнородной информации в базах данных (п. 13).

Теоретическая значимость исследования заключается в развитии научно-методического аппарата нейросетевого анализа и классификации многомерных сигнатур динамической подписи в условиях априорной информационной недостаточности по физическим параметрам регистрации и выраженной межличностной вариабельности реализаций подписи.

Практическая ценность исследования заключается в том, что применение разработанных методов, алгоритмов и программных реализаций макета программного комплекса моделирования и анализа динамической сигнатуры подписи, позволяет повысить достоверность и устойчивость сопоставления и классификации реализаций динамической

подписи за счёт увеличения входной размерности представления подписи путем экстраполяции дополнительных динамических параметров, их нормализации к единому диапазону и последующего комплексирования метрических, статистических и нейросетевых оценок.

Реализация и внедрение результатов работы. Разработанные методы и алгоритмы внедрены в учебный процесс на кафедре «Программирование» ФГБОУ ВО ПензГТУ и используются при подготовке студентов по направлениям магистратуры 09.04.04 «Программная инженерия» при проведении лекционных и лабораторных работ по дисциплинам: «Искусственные нейронные сети и глубокое обучение», «Интеллектуальный анализ данных», «Методы и алгоритмы искусственного интеллекта». Отдельные программно-технические решения, созданные в ходе диссертационного исследования, использованы в ООО НИИ «Криптософт» (г. Пенза) при работе с проектом «*QP-MD3*» на этапах разработки опытного образца.

Достоверность результатов работы подтверждается их непротиворечивостью результатам других исследователей, внедрением в практическую и научно-исследовательскую деятельность ряда организаций, а также апробацией и одобрением на всероссийских и международных научных конференциях.

Основные положения, выносимые на защиту:

1. Метод обработки и расширения динамических параметров подписи пользователя. За счет синтеза множества функционально связанных многомерных кривых метод преодолевает проблему малой информативности стандартных сенсоров. Эффективность метода подтверждается стабильным распознаванием на уровне 0,95, даже при выраженной межличностной вариабельности реализаций.

2. Метод эталонирования реализаций в пространстве функционально связанных кривых с применением модифицированной сети SOM. Введение критерия остановки по стабилизации степеней принадлежности

гарантирует устойчивость модели к поведенческим изменениям подписи пользователя, обеспечивая удержание показателя ложного отказа (FRR) в пределах 0,12.

3. Декомпозированная методика нейросетевого отождествления динамической сигнатуры. Использование распределенного кортежа матриц межнейронных связей вместо единой сети повышает защищенность системы от квалифицированных подделок. Поддержка состояния «отказ от распознавания» ограничивает вероятность ложного допуска (FAR) значением 0,08 без деградации общей точности.

4. Методика классификации динамической сигнатуры в пространстве многоточечного представления инвариантов. Применение выявленных статистических метрик сравнения обеспечивает высокую масштабируемость системы и гарантирует достижение компромисса между ошибками 1-го и 2-го рода на уровне $EER = 0,09$ при рабочей чувствительности 0,06.

Апробация работы. Основные результаты, полученные в рамках диссертационного исследования, были опубликованы в научных журналах и апробированы на международных и всероссийских научных конференциях: Международная научно-практическая конференция «Индустрия 4.0» (*SmartIndustryCon*) (Сочи, 2025); Всероссийская научно-практическая конференция «Итоги прошлого и проблемы настоящего» (Пенза, 2025); Международная научно-практическая конференция «Современные информационные технологии» (Пенза, 2024, 2025); Международная научно-практическая конференция «Взаимодействие науки и общества - путь к модернизации и инновационному развитию» (Стерлитамак, 2025); XX Всероссийская научно-практическая конференция посвященной 60-летию кафедры "Программирование" ПензГТУ (Пенза, 2023); Международная научно-техническая конференция «Актуальные вопросы современной науки и образования» (Пенза, 2020).

По результатам диссертационного исследования опубликовано 15 научных работ, в том числе 4 статьи в журналах, рекомендованных ВАК Минобрнауки России, 1 статья, индексируемая в международной базе данных Scopus.

Личный вклад автора. Все представленные в работе результаты исследования являются оригинальными и были получены автором самостоятельно. Данные, заимствованные у других авторов, сопровождаются ссылками на соответствующие опубликованные источники.

Объем и структура диссертации. Диссертация состоит из введения, четырех глав, заключения и списка литературы, который включает 88 наименований, и 2 приложения. Общий объем диссертации составляет 157 страниц. Диссертация содержит 8 таблиц и 53 рисунка.

1. СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОЛОГИЙ И АЛГОРИТМИЧЕСКИХ ПОДХОДОВ К СОПОСТАВЛЕНИЮ И КЛАССИФИКАЦИИ РЕАЛИЗАЦИЙ ДИНАМИЧЕСКОЙ ПОДПИСИ

1.1. Анализ современного методологического и технического уровня методов регистрации, предобработки, выделения признаков и сопоставления реализаций динамической подписи

Статические (неизменные) физиологические и динамические (кинематические) особенности человека являются не только статистически постоянными на протяжении значительного периода его жизни (некоторые из которых получены при рождении и неизменны, а другие меняются в течение жизни), но и обеспечивают его достоверную классификацию [18-22].

Прогнозы роста мирового рынка биометрических систем иллюстрированы на рис. 1.1.

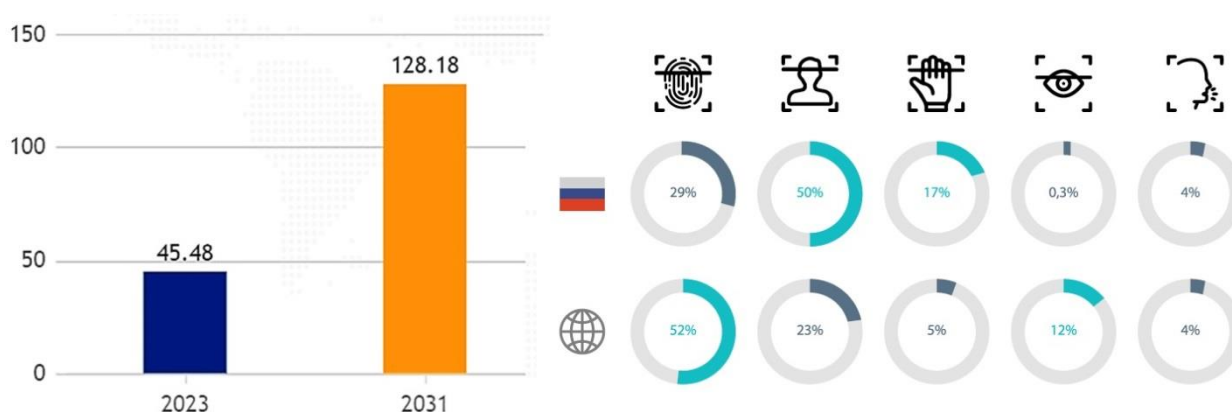


Рисунок 1.1 – Среднегодовой темп роста мирового рынка биометрических систем и его структура (справа)

Исследование рынка *Data Bridge* [23] показывает, что объем мирового рынка биометрических систем оценивался в 45,48 млн долларов США в 2023 году и, по прогнозам, к 2031 году достигнет 128,18 млн долларов США, а среднегодовой темп роста составит 13,83% в течение прогнозируемого периода с 2024 по 2031 год.

В отечественной практике, еще в 2018 году ЦБ РФ и Минцифры разработали стратегию и запустили Единую биометрическую систему (ЕБС). В 2022 году оператором Государственной информационной системы «Единая биометрическая система» стал специально созданный АО «Центр биометрических технологий» [24].

В ЕБС при помощи банков регистрируются два биометрических признака:

- 1) снимок лица;
- 2) запись голоса.

Не реализованные, но входящие в потенциальный перечень биометрических характеристик человека, связанных с его анатомией и физиологией, составляют:

- 3) отпечатки пальцев;
- 4) радужная оболочка глаза;
- 5) ДНК;
- 6) рисунок вен на руках;
- 7) динамические характеристики движения губ;
- 8) антропометрия: рост, вес;
- 9) видео с изображением человека;
- 10) термограмма лица;
- 11) **динамические характеристики подписи.**

В сфере регулирования существующие ГОСТ по биометрической классификации охватывают широкий спектр вопросов - от терминологии и форматов обмена данными до методик испытаний. Ключевые стандарты разработаны техническим комитетом № 098 «Биометрия и

биомониторинг» [25]. В табл. 1.1 представлены основные группы национальных стандартов в области биометрии.

Таблица 1.1 – Основные группы национальных стандартов в области биометрии

Группа стандартов	Ключевые примеры ГОСТ	Основная область регулирования
Основополагающие стандарты	ГОСТ ISO/IEC 2382-37-2016	Терминология и словарь в области биометрии.
Форматы обмена биометрическими данными	ГОСТ Р ИСО/МЭК 19794-5-2013 (данные изображения лица), ГОСТ Р 58668.11-2019 (данные голоса), ГОСТ Р ИСО/МЭК 19794-2-2013 (данные отпечатка пальца)	Стандартизация форматов данных для разных биометрических модальностей (голос, лицо, отпечатки пальцев и др.) для обеспечения совместимости систем.
Испытания и оценка	ГОСТ Р 71414.1-2024, ГОСТ Р 58292-2018	Принципы и методики проведения эксплуатационных испытаний биометрических систем.
Программные интерфейсы (API)	ГОСТ Р ИСО/МЭК 19784-1-2007 (БиоАПИ)	Спецификации программных интерфейсов для интеграции биометрических компонентов.

Кроме того, в законодательстве представлена серия ГОСТ Р 52633, представляющая собой комплекс взаимосвязанных стандартов (табл.1.2), где ГОСТ Р 52633.0-2006 задает общие требования, а последующие части (** .1- .6**) детализируют конкретные аспекты, такие как тестирование, создание биометрических образцов и работу с нейросетевыми преобразователями [26].

Таблица 1.2 – Серия биометрических ГОСТ Р 52633

Номер стандарта	Название
ГОСТ Р 52633.0-2006	Защита информации. Техника защиты информации. Требования к средствам высоконадежной биометрической аутентификации
ГОСТ Р 52633.1-2009	Требования к формированию баз естественных биометрических образов для тестирования
ГОСТ Р	Требования к формированию синтетических биометрических образов

52633.2-2010	для тестирования
ГОСТ Р 52633.3-2011	Тестирование стойкости средств высоконадежной биометрической защиты к атакам подбора
ГОСТ Р 52633.4-2011	Интерфейсы взаимодействия с нейросетевыми преобразователями биометрия-код доступа
ГОСТ Р 52633.5-2011	Автоматическое обучение нейросетевых преобразователей биометрия-код доступа
ГОСТ Р 52633.6-2012	Требования к индикации близости предъявленных биометрических данных образу «Свой»

По мнению ряда авторов [18, 27, 28] биометрическую информацию нельзя отнести ни к текстовой, ни к графической, ни к изобразительной, ни к какой-либо другой.

Биометрические данные, классифицируются на два больших класса:

1) статические биометрические данные – уникальные признаки образца или сличаемого шаблона, полученные мгновенно, в один момент времени, которые неизменны на интервале времени несоизмеримо малым по сравнению с временем жизни носителя, например ручная подпись, ДНК, отпечатки пальцев, геометрия руки, радужная оболочка глаза, признаки лица и другие;

2) динамические биометрические данные (т.н. поведенческая биометрия) – уникальные признаки, возможность регистрации, которых определена только на конечном интервале времени наблюдения психофизиологических или психомоторных реакций человека, например, характеристики движения руки в процессе подписи, походки, набора текста при работе с клавиатурой (клавиатурного подчерка), голоса, мимических реакций и т.д.

Идентификация и аутентификация – это два основных процесса в области информационной безопасности, которые позволяют проверить личность пользователя и установить его право на доступ к системе, данным или ресурсам.

Любая биометрическая система функционирует согласно следующему обобщенному алгоритму с незначительными вариациями (рис. 1.2).

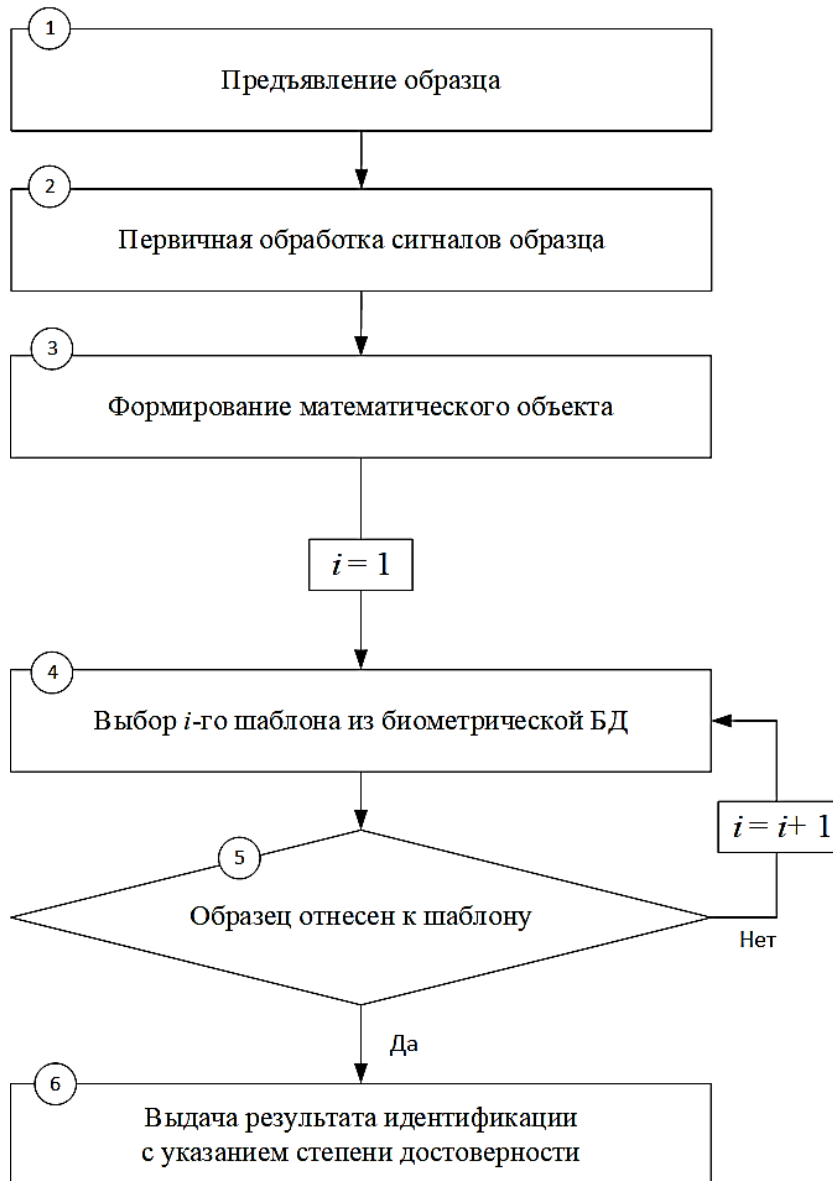


Рисунок 1.2 – Обобщенная схема функционирования системы биометрической классификации

Системы регистрации и анализа динамической подписи обычно представляют собой многокомпонентные решения, включающие как специализированное аппаратное обеспечение для сбора поведенческих данных (планшеты и стилусы), так и программные платформы для

предобработки, нормализации, выделения признаков, эталонирования и классификации многомерных временных рядов.

Примеры существующих систем и ключевых игроков рынка приведены в табл. 1.3 [29, 30].

Таблица 1.3 – Основные программные платформы (*e-Signature Solutions*)

Название Платформы	Специализация и особенности	Назначение платформы
<i>Adobe Sign (Adobe Document Cloud)</i>	Корпоративное решение с глубокой интеграцией в экосистему <i>Adobe</i> и инструменты <i>Microsoft 365</i> , а также <i>Salesforce</i> .	Обеспечивает классификацию при работе с <i>PDF</i> -документами и контрактами.
<i>OneSpan Sign</i>	Решение, отличающееся высоким уровнем безопасности, часто позиционируется как соответствующее стандартам «банковского класса» (<i>bank-grade security</i>). Активно использует инструменты предотвращения мошенничества и распознавания личности.	Применяется для цифровизации критически важных сценариев, таких как финансовые транзакции и открытие счетов, где требуется максимальная защита от подделки.
БиоНейроАвтограф	Исследовательская среда распознавания рукописной подписи по динамическим параметрам; формирование признаков из траектории пера (X , Y) и их производных/статистик.	Исследования и учебные задачи по биометрической классификации, прототипирование модулей распознавания подписи и генерация идентификатора; оценка точности и подбор параметров систем.
<i>Scrive</i>	Скандинавская платформа, ориентированная на юридическое соответствие (<i>legal compliance</i>) и распознавание личности, с сильным акцентом на правомерности подписи и архивировании документов.	Используется для обеспечения юридической силы электронных контрактов.

Для сбора полных наборов динамических данных (скорость, давление, ускорение, угол наклона) используются серийно изготавливаемые специализированные устройства, способные регистрировать эти

динамические параметры с высокой частотой дискретизации во времени и пространстве рабочей области планшета или иного устройства постановки подписи [31, 32].

Оценка достоверности систем осуществляется с помощью стандартного набора скалярных и векторных показателей (метрик), описывающих компромисс между безопасностью и удобством классификации.

Достоверность различных существующих систем, в особенности при использовании современных методов глубокого обучения (*Deep Learning*), демонстрирует сильную зависимость от типа атаки.

Так, в исследованиях по распознаванию онлайн-подписи с использованием глубоких нейронных сетей (таких как *MLP* и *CNN*) были получены результаты, сведенные в табл. 1.4 [29-32].

Таблица 1.4 – Сводка показателей ошибок (*EER*) при классификации динамической подписи в существующих системах *DSV*

Метод / Алгоритм	Тип фальсификации	Показатель	Значение (%)
<i>Deep Neural Network (CNN/MLP)</i>	Случайная (<i>Random Forgery</i>)	<i>EER</i>	0.63%
<i>Deep Neural Network (CNN/MLP)</i>	Профессиональная (<i>Skilled Forgery</i>)	<i>EER</i>	6.66%
<i>PCA-based Classifier (Baseline)</i>	Не указан	<i>EER</i>	6.70%
<i>Forensic DTW (Local Features)</i>	Имитационная (<i>Simulated</i>)	<i>EER</i>	5,33%

Данные табл. 1.4 демонстрируют критический разрыв в производительности. В то время как системы чрезвычайно устойчивы к случайной фальсификации (*EER* 0.63%), их уязвимость перед профессиональной имитацией возрастает почти на порядок, достигая *EER* 6.66%. Этот десятикратный разрыв указывает на то, что, хотя динамическая подпись эффективно фильтрует нетренированных злоумышленников, она сталкивается с серьезными проблемами при целенаправленных атаках. Это объясняет, почему поведенческие

биометрии в целом характеризуются более высокими показателями FAR и FRR , чем физиологические системы и свидетельствуют о необходимости добавления альтернативных - локальных, не облачных механизмов классификации, позволяющих принимать решения рядом с источником информации.

1.2. Обзор математических методов и подходов к анализу, сопоставлению и классификации по динамическим параметрам подписи

Технологии интеллектуального анализа, сопоставления и классификации по динамическим параметрам подписи тесно связаны с направлением поведенческой биометрии, которое находится в стадии становления. [33].

Обобщенная схема динамических биометрических систем иллюстрирована на рис. 1.3 [34-40].

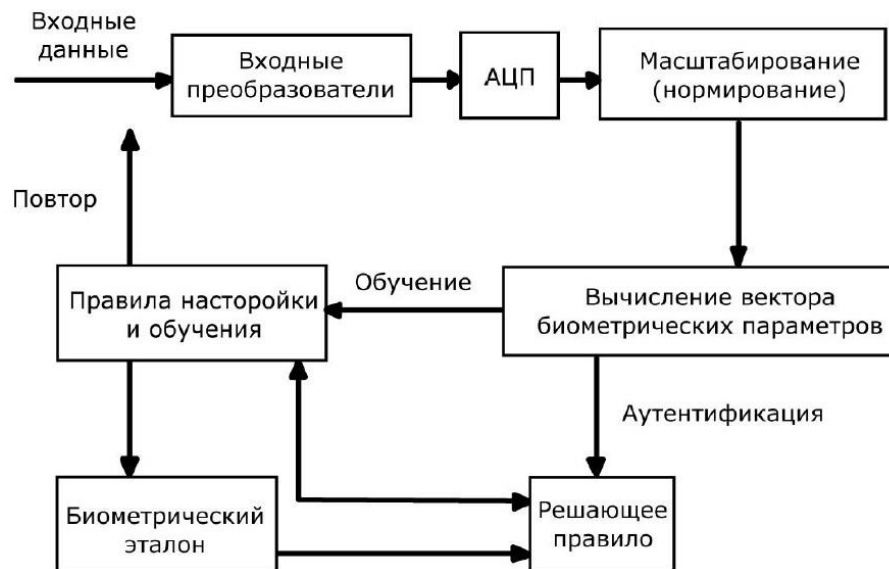


Рисунок 1.3 – Обобщенная схема динамических биометрических систем

Решение задачи классификации динамических рукописных подписей часто характеризуется следующими особенностями:

- искажение рукописной подписи, вызванное условиями её формирования (место, время, положение человека, его состояние и т.д.) [41];

- малый размер обучающей выборки;

- возможность наличия поддельных образцов, которые по некоторым показателям имеют схожие с подлинными образцами значения

В связи с компьютеризацией и цифровизацией всех отраслей внедрения биометрии повсеместно внедряются графические планшеты.

В ряде публикаций [28, 42] встречаются разработки с использованием дополнительных параметров скорости и ускорения, измеряемых встроенными *MEMS*-датчиками в стилус (рис. 1.4).




Рисунок 1.4 – Пример развертки динамических параметров скорости конца пера и его ускорения в процессе постановки сличаемой подписи

Совокупность полученных, таким образом, функционально связанных 5-ти кривых можно считать многомерной (пятимерной) кривой, которая может быть обработана методами цифровой обработки сигналов и проанализирована методами статистического, нейросетевого структурно-лингвистического, вероятностного метрического и дискриминантного анализа.

Наблюдаемая во времени плоская кривая (в пространстве R^1) либо многомерная кривая (R^n), может быть формализована как многомерный временной ряд:

$$S = \begin{array}{c|ccc} & t_1 & \dots & t_N \\ \hline \overline{s_1} & s_{11} & \dots & s_{1N} \\ \dots & \dots & \dots & \dots \\ \hline \overline{s_M} & s_{M1} & \dots & s_{MN} \end{array}, \quad (1.1)$$

где $s_{ij} = s_i(t_j)$, $i = \overline{1, N}$, $j = \overline{1, M}$ – значение (отсчет) j -й кривой в момент времени i .

Ключевая специфика многомерного временного ряда состоит в синхронности измерений: значения всех компонент фиксируются в один и тот же момент времени. При этом каждый компонентный ряд, выделенный из вектора наблюдений, допустимо трактовать как одномерный временной ряд [43].

Постановка задачи классификации нередко сводится к сегментации – целенаправленному выделению во временном ряде интервалов, на которых исследуемая характеристика демонстрирует заранее заданное, шаблонное поведение.

Если шаблон задан вектором отсчетов $Q = (q_1, \dots, q_n)$, тогда он является идентичным в детерминисткой постановке фрагменту $S = (s_{i+1}, \dots, s_{i+n})$ ряда $S = (s_i, \dots, s_N)$, $n < N$ при $\forall j \in \{1, n\} \rightarrow s_{i+j} = q_j$.

При этом для поиска во временном ряде, длины N всех фрагментов, идентичных шаблону длины n , методом перебора необходимо $(N - n + 1) \cdot n$ операций сравнения.

Чаще всего в качестве меры расстояния между рядами используется евклидово расстояние, $D_E(S_1, S_2) = \sqrt{\sum_i (S_1[i] - S_2[i])^2}$, а ряды могут быть отнесены к одному классу с погрешностью $e \geq 0$, если $D_E(S_1, S_2) < e$.

Современный арсенал методов и алгоритмов классификации, применяемых на различных стадиях обработки многомерных временных рядов и их представлений, представлен в табл. 1.5.

Таблица 1.5 – Основные подходы к задаче сопоставления и классификации реализаций динамической подписи, классифицированные по характеру информации о признаках

Подходы к классификации	Методы, алгоритмы
Эвристический	Экспертные оценки (индивидуальные, коллективные). Эвристики на основе потенциальных и дискриминантных функций. Коллективы решающих правил. Нечеткие методы, системы продукций и др.
Дискриминантный (в детерминистской постановке), метрический	Метод эталонов, комбинационно-корреляционный, шаблонный дробящихся эталонов. Дискриминантные разделяющие функции Обобщенные решающие функции. Кусочно-линейные разделяющие функции. Функции расстояния в различных метриках. Метод ближайших соседей. Модификации алгоритма k -внутригрупповых средних; алгоритмы таксономии <i>FOREL</i> , <i>SKAT</i> , <i>KOLAPS</i> , <i>BIGFOR</i> , <i>KRAB</i> , <i>JOINT</i> и др. Алгоритм <i>ISODATA</i> . Метод опорных векторов. Метод потенциалов. Метод потенциальных функций. Модификации аппроксимационных алгоритмов. Алгоритм ВРгор и многослойных классификаторов МГУА. Методы на основе моделей нейронных сетей (НС) Кохонена. Методы на основе моделей НС Хопфилда и Хэмминга
Вероятностно-статистический	Байесовский классификатор. Метод последовательного анализа. Методы статистических решений (минимального риска: минимума числа ошибочных решений, минимакса, Неймана – Пирсона, максимального правдоподобия). k -ближайших соседей. Методы стохастической геометрии. Методы оценивания смеси параметрических плотностей. Скрытые марковские цепи. Байесовские сети.

Подходы к классификации	Методы, алгоритмы
	Методы классификации на основе байесовских сетей. Вероятностные классификаторы, обучаемые методами стохастической аппроксимации
Логический, искусственный интеллект	Метод сокращенного базиса. Алгоритмы вычисления оценок. Анализ высказываний, исчисление предикатов. Алгоритм распознавания арифметических таблиц; алгоритм «Coral». Деревообразные классификаторы. Алгоритм голосования по тупиковым тестам. Алгоритм голосования по логическим закономерностям. Деревья решений. Структурно-логические. Поиск в пространстве состояний
Структурно-лингвистический	Методы синтаксического анализа. Алгоритмы стохастического синтаксического анализа. Метод эталонных последовательностей. Семейство двумерных грамматик и видов грамматического разбора. Математическая лингвистика, теория формальных грамматик и др.
Моделирование	Натурное моделирование. Исследование физико-химических процессов. Аналитическое моделирование. Имитационное статистическое моделирование. Эволюционное численное моделирование. Моделирование на графах

Основная особенность большинства из упомянутых методов заключается в том, что они обрабатывают статистический, предварительно структурированный массив данных изображения наблюдаемого объекта. Это позволяет (работая с памятью) выполнять операции линейного и нелинейного дифференцирования и интегрирования в окрестности любой точки изображения (j, k) , а также использовать при анализе разложения в ряд Фурье преобразования Адамара, Хаара и др [44].

В приведенной классификации выделяют 2 основные группы часто применимых методов классификации динамических параметров подписи:

1. Методы на основе анализа глобальных признаков математического объекта (1.1). Глобальные признаки извлекаются из всей подписи, и эти подходы в основном – параметрические [45, 46].

Строкам $S_{m_{l-1}+1}, S_{m_{l-1}+2}, \dots, S_m$ соответствуют значения основного признака $y(S_i) = l$ (объекты принадлежат классу K_l), т. е. $S_{m_{i-1}+1}, S_{m_{i-1}+2}, \dots, S_{m_i} \in K_i, i = 1, 2, \dots, l, m_0 = 1, m_l = m$. В результате получим

$$\left. \begin{array}{cccc} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \cdot & \cdot & \cdot & \cdot \\ a_{m_1 1} & a_{m_1 2} & \dots & a_{m_1 n} \end{array} \right\} \in K_1, \quad \left. \begin{array}{cccc} a_{m_1+1,1} & a_{m_1+1,2} & \dots & a_{m_1+1,n} \\ a_{m_1+2,1} & a_{m_1+2,2} & \dots & a_{m_1+2,n} \\ \cdot & \cdot & \cdot & \cdot \\ a_{m_2 1} & a_{m_2 2} & \dots & a_{m_2 n} \end{array} \right\} \in K_2, \\
 \dots\dots\dots \\
 \left. \begin{array}{cccc} a_{m_{l-1}+1,1} & a_{m_{l-1}+1,2} & \dots & a_{m_{l-1}+1,n} \\ a_{m_{l-1}+2,1} & a_{m_{l-1}+2,2} & \dots & a_{m_{l-1}+2,n} \\ \cdot & \cdot & \cdot & \cdot \\ a_{m_l 1} & a_{m_l 2} & \dots & a_{m_l n} \end{array} \right\} \in K_l, \text{ где } a_{ij} = x_j(S_i). \quad (1.2)$$

В итоге, при классификации по прецедентам необходимо, опираясь на таблицу обучения T_{mnl} построить алгоритм, который корректно определяет класс предъявленного к распознаванию объекта. В формальном виде алгоритм распознавания задаётся отображением:

$$A(S) = (\alpha_1^A(S), \alpha_2^A(S), \dots, \alpha_l^A(S)), \alpha_i(S) \in \{0, 1, \Delta\}, i = 1, 2, \dots, l, \quad (1.3)$$

где $\alpha_i^A(S)$ – решение алгоритма, т.е. отнесение объекта S к классу K_i

Если $\alpha_i^A(S) = 1$ и $\alpha_j^A(S) = 0$ – то алгоритм принимает решение «объект s не принадлежит классу K_i », при $\alpha_i^A(S) = \Delta$ – трактуется как отказ от классификации объекта S данным алгоритмом относительно K_i .

Оценки условных вероятностей $P(K_i | x)$ могут быть вычислены по формуле (1.4) на основе оценок априорных вероятностей $P(K_1), \dots, P(K_l)$ и плотностей $f_1(x), \dots, f_l(x)$.

$$P(K_i | x) = \frac{f_i(x)P(K_i)}{\sum_{i=1}^l f_i(x)P(K_i)}. \quad (1.4)$$

На практике наиболее распространённым предположением является многомерное нормальное распределение, которое в общем виде записывается как:

$$f(x) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left[-\frac{1}{2}(x - \mu)' \Sigma^{-1}(x - \mu)\right], \quad (1.5)$$

где n – размерность признакового пространства, μ – математическое ожидание вектора признаков x , Σ – матрица ковариаций компонент вектора x , $|\Sigma|$ – детерминант матрицы Σ .

В рамках дискриминантных подходов (рис. 1.5) построение линейной разделяющей поверхности (гиперплоскости) сводится к нахождению функции, линейной по признакам,

$$f(x) = a_1 x_1 + a_2 x_2 + \dots + a_n x_n + a_{n+1} \quad (1.6)$$

и применению упрощённого решающего правила

$$\alpha^A(S) = \begin{cases} 1, & f(S) > 0, \\ \Delta, & f(S) = 0, \\ 0, & f(S) < 0, \end{cases} \quad (1.7)$$

Здесь решение $\alpha^A(S)=1$ означает отнесение объекта к первому классу, а $\alpha^A(S)=0$ – отнесение во второму, $\alpha^A(S)=\Delta$ – трактуется как отказ от классификации.




Рисунок 1.5 – Пример разделения двух классов гиперплоскостью:
a – безошибочное разделение двух классов гиперплоскостью; *b* –
 разделение двух классов гиперплоскостью с минимальным числом ошибок

Существуют различные формализации критериев выбора $f(x)$. Наиболее типичная постановка заключается в подборе функции $f(x)$, параметризованной неизвестными коэффициентами $a_1, a_2, \dots, a_n, a_{n+1}$, при которой минимизируется число нарушений неравенств в соответствующей системе:

$$\begin{aligned}
 a_1 x_1(S_1) + a_2 x_2(S_1) + \dots + a_n x_n(S_1) + a_{n+1} &> 0, \\
 a_1 x_1(S_2) + a_2 x_2(S_2) + \dots + a_n x_n(S_2) + a_{n+1} &> 0, \\
 &\dots \\
 a_1 x_1(S_{m_1}) + a_2 x_2(S_{m_1}) + \dots + a_n x_n(S_{m_1}) + a_{n+1} &> 0, \\
 &\dots \dots \dots \\
 a_1 x_1(S_{m_1+1}) + a_2 x_2(S_{m_1+1}) + \dots + a_n x_n(S_{m_1+1}) + a_{n+1} &< 0, \\
 a_1 x_1(S_{m_1+2}) + a_2 x_2(S_{m_1+2}) + \dots + a_n x_n(S_{m_1+2}) + a_{n+1} &< 0, \\
 &\dots \\
 a_1 x_1(S_m) + a_2 x_2(S_m) + \dots + a_n x_n(S_m) + a_{n+1} &< 0.
 \end{aligned} \tag{1.8}$$

В сочетании с правилом (1.7) обеспечивается минимизация числа ошибок классификации – как неверных отнесений, так и отказов.

Одним из методов на основе глобальных признаков является нейросетевое преобразование биометрии в ключ («биометрия→код»),

разработанное А. И. Ивановым и соавторами, описанное как практическая технология высоконадежной классификации и реализованное в их программных системах. Обучение и проверка преобразователя регламентируются линией стандартов ГОСТ и проводится на наборе реализаций, результатом служат весовые коэффициенты сети и персональный 256-битный ключ. На вход преобразователя подаётся вектор признаков, сформированный из измеряемых характеристик подписи (координаты траектории их производные и др.).

В учебно-методической среде «БиоНейроАвтограф» такой вектор включает 416 контролируемых биометрических параметров. Для каждого параметра в процессе работы поддерживаются средние значения и стандартные отклонения, а также файл с их текущими значениями. Это обеспечивает воспроизводимую предобработку и контроль корректности данных [47]. Преобразователь реализуется нейросетью, на выходах которой формируется 256-битовый код; по завершении обучения сохраняются веса нейронов, «обучающий ключ» и набор «проверочных ключей» для последующего контроля. Для оценки близости используются расстояния Хэмминга между кодом, полученным при предъявлении образца, и эталонным кодом/паролем [48].

При обучении по ГОСТ Р 52633.5 - 2011 достигается состояние, когда для случайных «чужих» входов разряды 256-битового кода распределены почти равновероятно (0/1), что соответствует высокой энтропии по Хэммингу. Вместе с тем для малых выборок важно учитывать зависимости между разрядами; поэтому к оценке энтропии Хэмминга добавляется корреляционная энтропия, вычисляемая через взаимные коэффициенты корреляции битовых последовательностей. Такая процедура повышает точность статистической валидации выходных кодов и предлагается к отражению в актуализации ГОСТ Р 52633.3 - 2011. Полученный 256-битовый код может использоваться как самостоятельный

аутентификатор, вместе с обычным паролем или как основа для формирования криптографического ключа [49].

В диссертации предложено иное построение признакового описания - базовый кортеж параметров с экстраполяцией дополнительных динамических характеристик и нормализацией по единому масштабу. Такое представление увеличивает информативность входного признакового пространства, улучшает делимость классов, а также устойчивость к смене сенсорного устройства, что потенциально может приводить к более стабильным выходным битам при кодообразовании по типу «биометрия→код» и, как следствие, к росту энтропии выходного кода и снижению ошибок классификации. Сопоставимость подтверждается тем, что и «БиоНейроАвтограф», и предложенный подход опираются на нормирование, контролируемые наборы признаков и воспроизводимое обучение/тестирование.

Вторая группа методов относится к локальным, в рамках которых вектор признаков формируется на основе обнаружения и локализации точечных особенностей многомерной кривой (рис. 1.6).



Рисунок 1.6 - Классификация детекторов простых элементов изображения
подписи

Ряд авторов придерживается мнения, что большинство существующих методов анализа и классификации разделяются в зависимости от того, какие признаки лежат в их основе. Если в основе распознавания лежат глобальные признаки, то это глобальные параметрические методы. Если в основе – локальные признаки (например, значения скорости или ускорения, радиус закругления, взятые в каждой точке подписи), то это локальные методы [34, 35, 50]. Если же в основе метода лежат и локальные, и глобальные признаки, то это гибридные методы.

Общим недостатком методов являются их не инвариантность к виду состояния носителя подписи, и, соответственно низкая достоверность

распознавания. Кроме того, снижение достоверности может быть обусловлено и размерами биометрической базы данных, что, также обуславливает снижение оперативности решения задачи, которая в ряде отраслей применения биометрических технологий является критическим фактором применения. Применение достижений современных нейросетевых технологий в части современных архитектур является одним из направлений поиска решения данной проблемы.

1.3. Обоснование нейросетевых алгоритмов как решений задач анализа и классификации многомерных сигнатур динамической подписи

В последние годы, наряду с традиционной классификацией используемых искусственных нейронных сетей (рис. 1.7), были предложены и получили широкое практическое распространение новые архитектурные подходы (рис. 1.8). К ним относятся автоэнкодеры, *LSTM*, трансформеры, генеративно-сопоставительные нейронные сети и ряд других решений [41, 51, 52].



Рисунок 1.7 – Классификация нейронных сетей

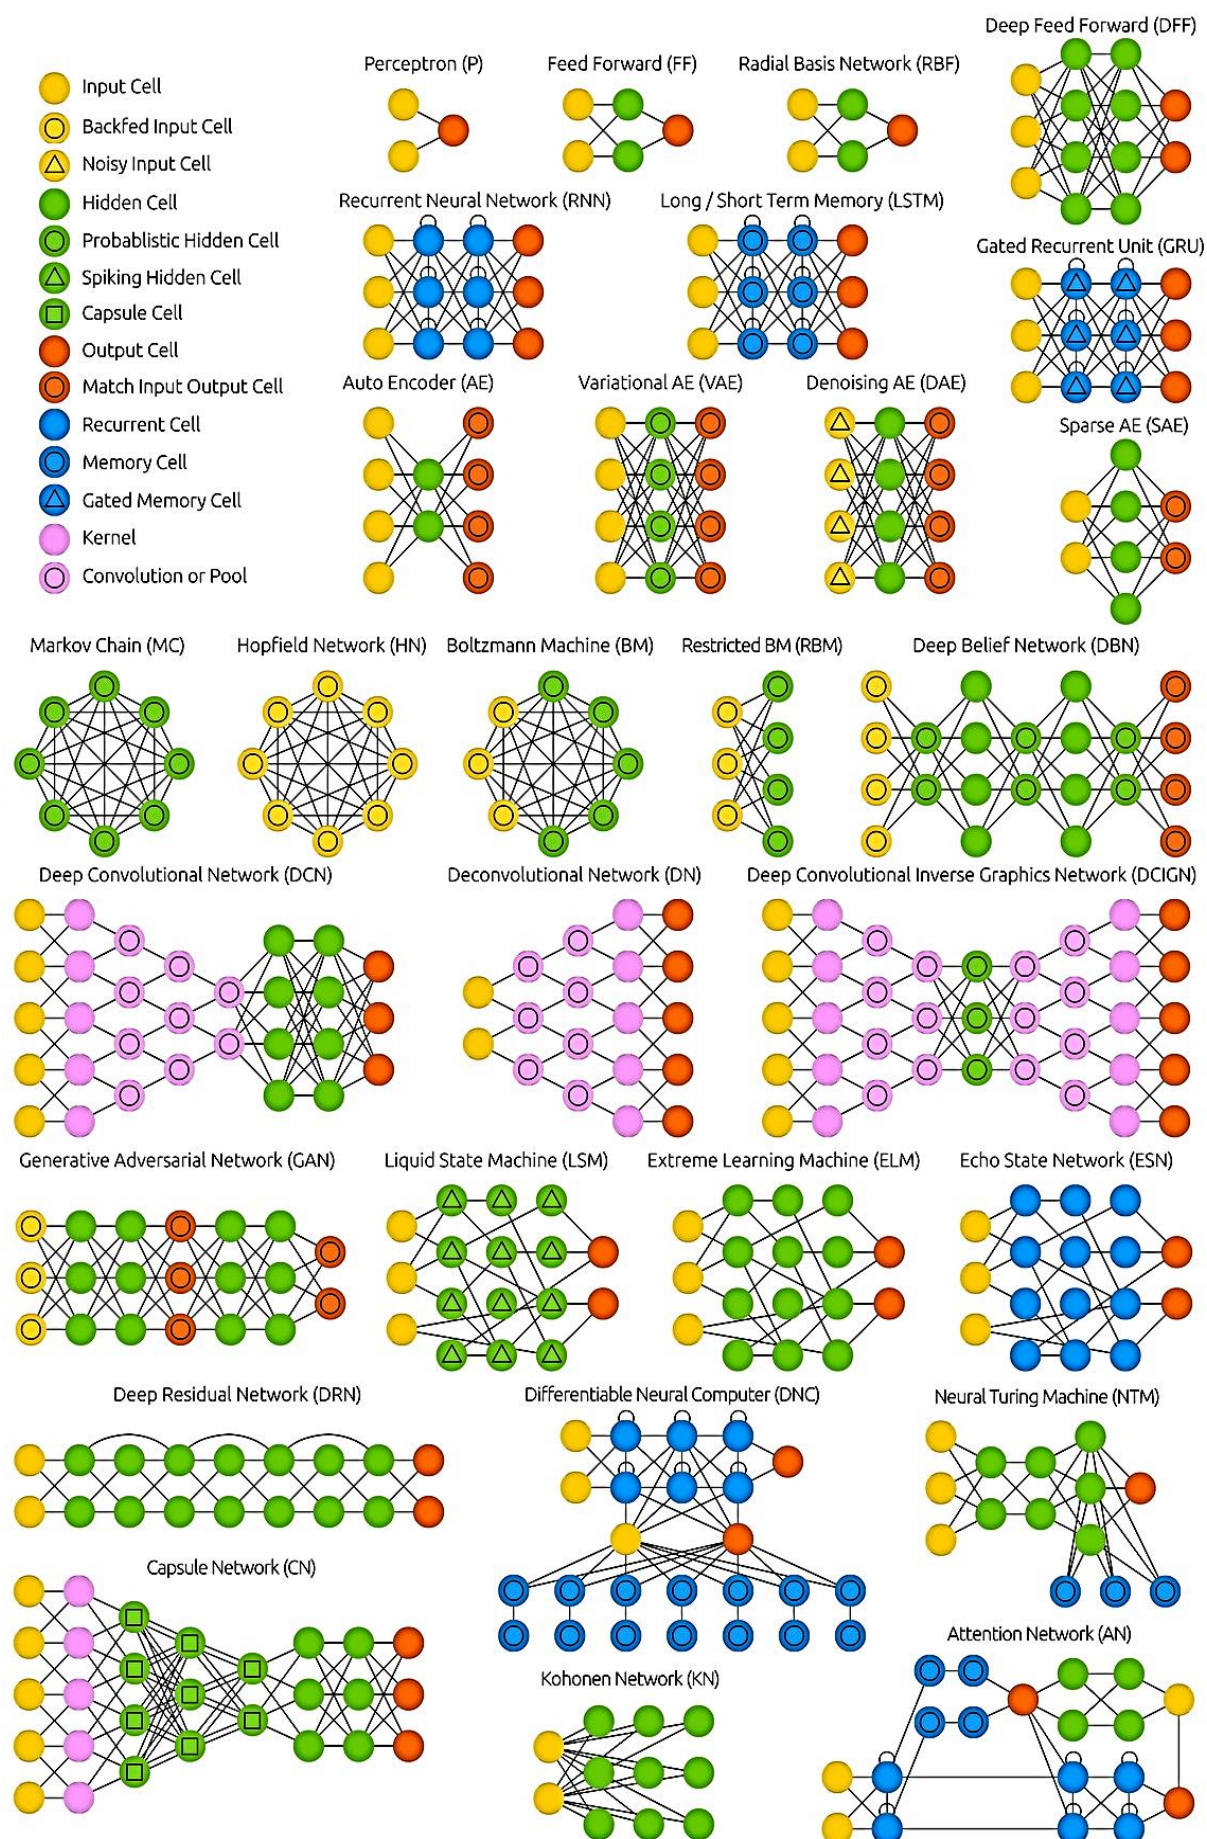


Рисунок 1.8 – Многообразие современных архитектур НС

Несмотря на нововведения, принцип их конструирования и функционирования, в основном, подобен классическим сетям распознавания образов (рис. 1.9).

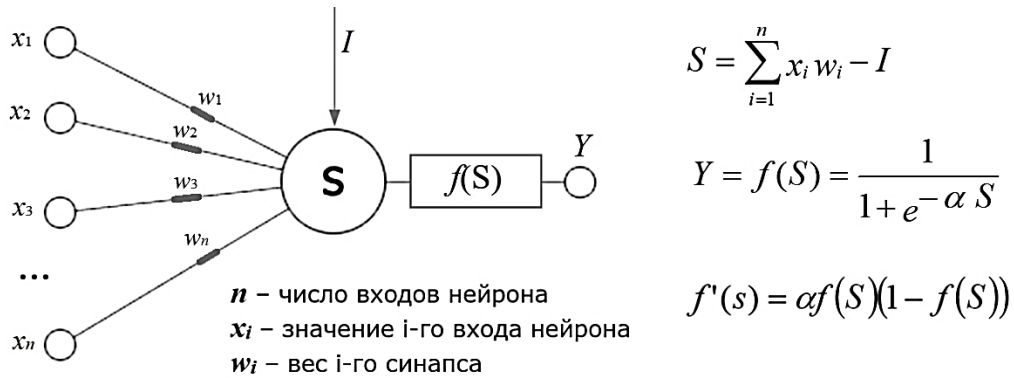


Рисунок 1.9 – Основной вычислительный элемент сети

На рис. 1.9 величина $f(S)$ обозначает функцию, выполняющую роль пороговой (активационной). На практике в качестве активационной функции чаще всего выбирают сигмоидную. В общем случае формализованная модель нейрона задаётся как отображение $R^n \rightarrow R$ вида

$$y = f\left(\sum_{i=1}^n w_i x_i - I_0\right), \quad X = \begin{bmatrix} x_1 \\ x_2 \\ \dots \\ x_N \end{bmatrix} \in R^n, \quad W = \begin{bmatrix} w_0 \\ w_1 \\ w_2 \\ \dots \\ w_n \end{bmatrix} \in R^{n+1}, \quad (1.9)$$

где f – вещественная функция активации, X – вектор входных сигналов нейрона, W – набор весовых коэффициентов (коэффициентов синаптических связей), с которыми входные сигналы участвуют во взвешивании, I_0 – сигнал смещения (пороговая константа).

Основное отличие нейросетевого алгоритма решения задач от классических, заданных в формульно-текстовом виде – это отсутствие этапа алгоритмизации, который заменяется этапом обучения при решении трудно формализуемых задач, таких, где нет научно-обоснованных численных зависимостей. А это именно тот случай, когда необходимо

распознавать многомерные сигнатуры динамической подписи в условиях ее сильной вариабельности и неопределенности состояния носителя.

Подходы к решению проблемы различны. Один из них, в рамках интенсивного направления, основан на эвристических, не до конца исследованных структурно-избыточных способах повышения достоверности функционирования различных архитектур НС, и которые сочетаются с экстенсивным направлением [53-59].

В настоящей работе предлагается разработать и применить подход к анализу и классификации динамической подписи, предполагающий использование в качестве пространства словаря признаков массива соотношений исходных признаков многомерной сигнатуры динамической подписи. Согласно выдвигаемой в работе гипотезе, такая параметризация входных образцов динамической подписи будет обладать высокой информативностью, а полученные нейросетевые модели сопоставления и классификации – высокой различительной способностью.

Фундаментальные отличия и новизна предлагаемого подхода от описанных в п. 1.2 и 1.3 заключается в следующем.

Каждый образец динамической подписи представляется семейством функционально связанных N плоских кривых, либо, что подобно: N – мерной кривой. Кривая дискретизирована во всех своих измерениях. По оси абсцисс N -мерной кривой – время (его дискретные отсчеты), затрачиваемое на выполнение подписи, по $(N-1)$ осям ординат – дискретные значения измерений физико-геометрических процессов, сопровождающих подпись: угол и мгновенные расстояния конца пера от начала координат (в полярной системе); сила нажатия пера, углы ориентации пера, скорость, ускорения конца пера. Все регистрируемые физико-геометрические процессы развернуты во времени в дискретной шкале. Существующие методы обработки такого представления динамической подписи основаны на классическом математическом аппарате цифровой обработки сигналов, причем каждая плоская кривая

(т.е. физико-геометрический процесс) обрабатывается отдельно, затем результаты распознавания (сличения) комплексуются на уровне решений.

В результате предлагаемого представления, на основе каждого образца подписи формируется групповой точечный объект, вложенный в M -мерное пространство своих статистических и событийных признаков, например: различные статистические моменты разверток кривых во времени, число и виды пиков, радиусов и др. признаков из громадного инструментария детекторов признаков на изображениях (рис. 1.10).

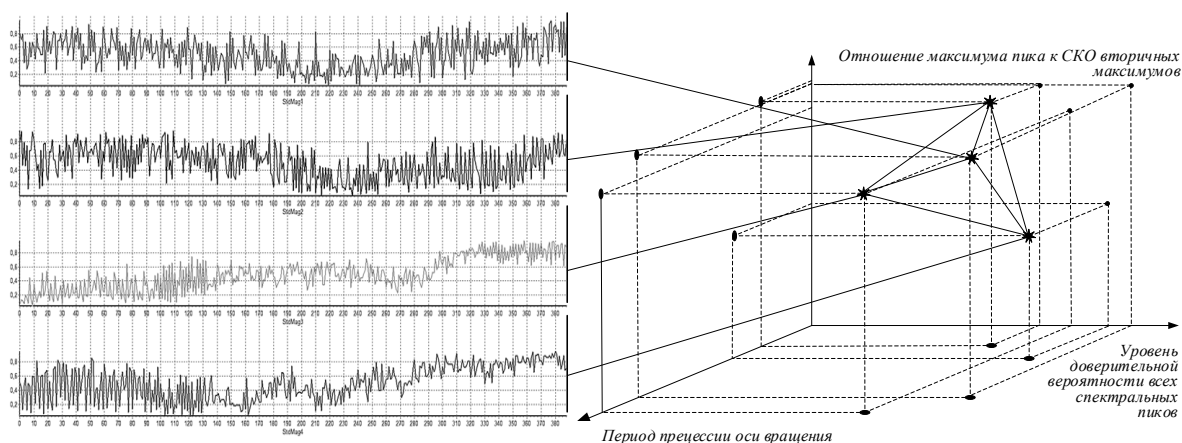


Рисунок 1.10 – Предлагаемое представление реализации динамической подписи в M -мерном пространстве

Например, для группового точечного представления с искажениями до 50% от линейного размера достоверность классификации не опускается ниже 0,85 [60, 61].

Алгоритмы чисто метрического представления и классификации показывают высокую устойчивость к искажениям групповых представлений вида смещения, поворота изменений масштаба, что целесообразно при распознавании варибельности, обусловленных физиологией человека.

В качестве индивидуально-специфической характеристики носителя динамической подписи, например, может рассматриваться матрица попарных расстояний между элементами группового точечного объекта. В

этом случае число формируемых признаков при использовании матрицы попарных расстояний не зависит от размерности пространства M :

$$n = \frac{N!}{2!(N-2)!}, \quad (1.10)$$

если же вектор признаков строится по углам и расстояниям, отсчитываемым от некоторой заранее выбранной начальной точки, то для образца группового точечного представления на плоскости ($M = 2$) получаем:

$$n = 2N - 3, \quad (1.11)$$

а для пространственного случая ($M = 3$):

$$n = (N - 1) + \frac{(N - 1)!}{3!((N - 1) - 3)!}, \quad (1.12)$$

где N – количество точек образца группового точечного представления, то есть число регистрируемых физико-геометрических процессов динамической подписи.

Как видно из выражений (1.10) - (1.12), при таком представлении из одной единственной реализации динамической подписи извлекается гигантское количество информации, несравнимой с традиционными методами цифровой обработки сигналов и статистической теории обнаружения оценивания.

Естественно предположить, что для столь высокой информативности анализируемых объектов наиболее подходящей методологией анализа, сопоставления и классификации могут стать искусственные нейронные сети, реализуемые как по принципу дообучения крупных моделей, так и в виде компактных архитектур, обеспечивающих устойчивое обобщение на новых реализациях за счёт автоматического формирования признаков представлений входных данных в нейросетевом вычислительном базисе. Соответствующую гипотезу, позволяющую существенно повысить качество сопоставления и классификации динамической подписи, предполагается доказать в настоящей работе.

Проведенный обзор источников предметной области позволяет судить, что, в данной постановке, озвученная задача еще не решена и соответствующий научно методический аппарат не разработан.

В условиях межстройственной неоднородности сенсоров и высокой внутриклассовой вариативности подписей именно целостный информационный процесс обеспечивает устойчивость сопоставления и воспроизводимость метрик качества.

На рисунке 1.11 представлен информационный процесс в предлагаемой системе анализа, сопоставления и классификации динамической подписи — это непрерывный поток преобразований данных от момента регистрации динамической подписи до формирования решения о принадлежности реализации к одному из эталонов. Он интегрирует все ключевые результаты работы: нормализацию данных с разных сенсорных устройств, экстраполяцию дополнительных динамических параметров по кортежу стандартных, эталонирование реализаций на *SOM* для учёта внутриклассовой вариативности, нейросетевое представление эталонов в виде кортежа послонных матриц весов.

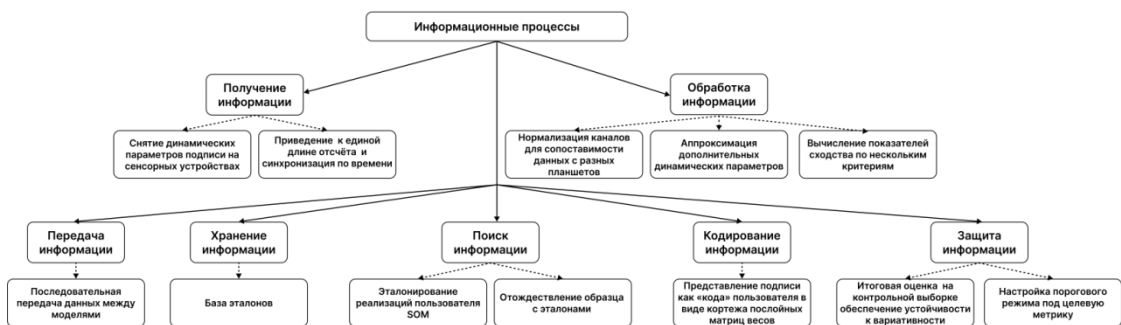


Рисунок 1.11– Схема информационного процесса и соответствие этапам диссертационной работы

Процесс предложенных в диссертации методов экстраполяции, эталонирования и анализа обеспечивает сопоставимость данных,

устойчивость к вариативности подписей и повышение точности классификации.

1.4. Выводы по первой главе и общая постановка задач исследований

В результате проведенного анализа современного методологического и технического уровня и направлений развития методов анализа, сопоставления и классификации динамической подписи установлено, что:

1. Среди методов биометрической классификации одним из дешевых и доступных по реализации является подпись. Однако статическая подпись обладает низкой различительной способностью, в силу внутриклассовой изменчивостью, низкой степенью постоянства и возможностью изучить подпись с целью получения неразличимой статическими методами подделок. Указанные выше аспекты, в том числе поведенческие вариации подписи в пределах одного класса, превращают задачи устойчивого сопоставления и классификации рукописной сигнатуры в весьма серьезную проблему.

2. Динамическая подпись частично свободна от указанных недостатков, однако и для нее остро стоит проблема устойчивости математических представлений динамических характеристик и качества классификации реализаций в прикладных системах обработки динамической подписи. Проблема заключается, с одной стороны, необходимостью внедрения в различных отраслях сравнительно дешевого и оперативного способа классификации пользователя, с другой низкой достоверностью методов, обусловленных высокой вариабельностью и неопределенностью состояния носителя. Математически это выражается в отсутствии единого сличаемого шаблона, малого количества примеров для статистических методов, многомерности и априорной неопределенности

относительно информативности признаков для тех или иных состояний носителя подписи.

3. Решение проблем анализа и классификации динамического представления подписи во многих работах находят в нейросетевых методах. Основное отличие нейросетевого алгоритма решения задач от классических, заданных в формульно-текстовом виде, – это отсутствие этапа алгоритмизации, который заменяется этапом обучения при решении трудно формализуемых задач, таких, где нет научно-обоснованных численных зависимостей. А это именно тот случай, когда необходимо сопоставлять и классифицировать многомерные сигнатуры динамической подписи в условиях ее сильной вариабельности и неопределенности условий исполнения. Однако и здесь существуют нерешенные научно-технические задачи, например, отсутствие представительной обучающей выборки, отсутствие научно-обоснованных подходов к формированию пространства признаков, а также проблема масштабируемого поиска и сопоставления по крупным базам эталонных реализаций, требующая оптимальной организации хранения структурированных определенным (на данный момент не известным) образом данных, их выборки и оперативного сопоставления.

2. МЕТОДЫ ПРЕДСТАВЛЕНИЯ БИОМЕТРИЧЕСКИХ ДАННЫХ В НЕЙРОСЕТЕВОМ ВЫЧИСЛИТЕЛЬНОМ БАЗИСЕ

2.1. Метод обработки и расширения признакового описания динамических параметров подписи на множестве функционально связанных многомерных кривых

Обзор механизмов анализа, сопоставления и классификации реализаций по динамическим параметрам подписи показал, что увеличение информативности динамических параметров I , их числа N при

необходимой точности их регистрации влечет повышение метрики качества классификации D по множеству классов (эталонов) по законам некоторой обобщенной зависимости F_1 :

$$D = F_1(N, I), \quad (2.1)$$

где N – число регистрируемых параметров, I – среднестатистическая информативность каждого из N параметров, используемых для обнаружения, различения, классификации пользователей, F_1 – рассматриваемая зависимость в обобщенном теоретико-множественном виде.

Значительное число массивов измерительных данных представляют собой либо базы данных статических изображений подписей, либо базы данных, содержащих ограниченное число регистрируемых динамических параметров – временные зависимости по осям $x(t)$, $y(t)$ и давление на холст – $p(t)$, что обусловлено распространенностью и техническими характеристиками соответствующих планшетных специализированных устройств. Назовем такие параметры – стандартными, а обучающую выборку, содержащую только стандартные параметры – выборкой сокращенного состава.

Вместе с тем, необходимая достоверность (не ниже $D_{\min}=0,95$ на тестовых данных) классификации пользователя не может быть обеспечена с использованием выборки сокращенного состава. Опыт разработок показывает, что в составе выборки необходимо иметь две или более такие дополнительные динамические характеристики, как:

- 1) $v_x(t)$ – скорость пера по оси x ;
- 2) $v_y(t)$ – скорость пера по оси y ;
- 3) $a_x(t)$ – ускорение пера по оси x ;
- 4) $a_y(t)$ – ускорение пера по оси y ;
- 5) событийный параметр отрыва пера от холста;

б) $\alpha(t)$ - 1-й параметр ориентации пера относительно плоскости планшета – угол α между продольной осью симметрии пера и нормалью к экрану;

7) $\beta(t)$ - 2-й параметр ориентации пера относительно плоскости планшета – угол β между проекцией продольной оси пера на плоскость экрана и опорным направлением в заданной области $[X, Y]$ на планшете, например, осью Y – т.н. азимутальный угол,

и другие динамических параметров, которые возможно получить на высокоинформативной, но ограниченной номенклатуре сенсорных планшетных средств регистрации биометрического образа подписи..

В соответствии с ГОСТ Р 52633.0–2006 [26] биометрическим образом считается образ человека, полученный с выходов первичных измерительных преобразователей и предназначенный для последующей масштабированной и иной первичной обработки с целью извлечения контролируемых биометрических параметров. В рамках настоящей работы под динамическим биометрическим образом подписи понимается множество синхронно регистрируемых временных рядов, получаемых с планшета/контроллера ввода и представляющих кинематику движения пера и динамику взаимодействия с поверхностью. Подготовленные таким образом данные используются для извлечения признаков, построения эталонов и обучения распознающих моделей. Принятые в работе определения и этапы первичной обработки согласованы с положениями ГОСТ Р 52633.0–2006. Доведение решения до класса «высоконадежных» в части преобразования «биометрия → код» и криптоаутентификации рассматривается как направление дальнейшего развития.

Назовем выборку, содержащую, помимо стандартных параметров, две и более дополнительные динамические характеристики – выборкой полного состава.

В силу простоты получения, широко распространены выборки сокращенного состава, и существует не более десятка датасетов баз данных, содержащие выборки полного состава.

В рамках настоящих исследований формулируется гипотеза о возможности повышения качества сопоставления и классификации реализаций динамической подписи за счет экстраполяции зависимости значений дополнительных динамических параметров от кортежа значений стандартных параметров. Тем самым, зная характеристики такой экстраполяции (аналитически построенной зависимости), можно на основе каждой выборки сокращенного состава сформировать частично синтетическую выборку полного состава и использовать ее для обучения моделей анализа и классификации динамической подписи в системах обработки динамических параметров. Логика такой гипотезы иллюстрирована на рис. 2.1-2.3.

На рис. 2.1 показана последовательность синтеза модели классификации реализаций динамической подписи по данным выборки сокращенного числа параметров $N=3$, но большого объема V_1 .

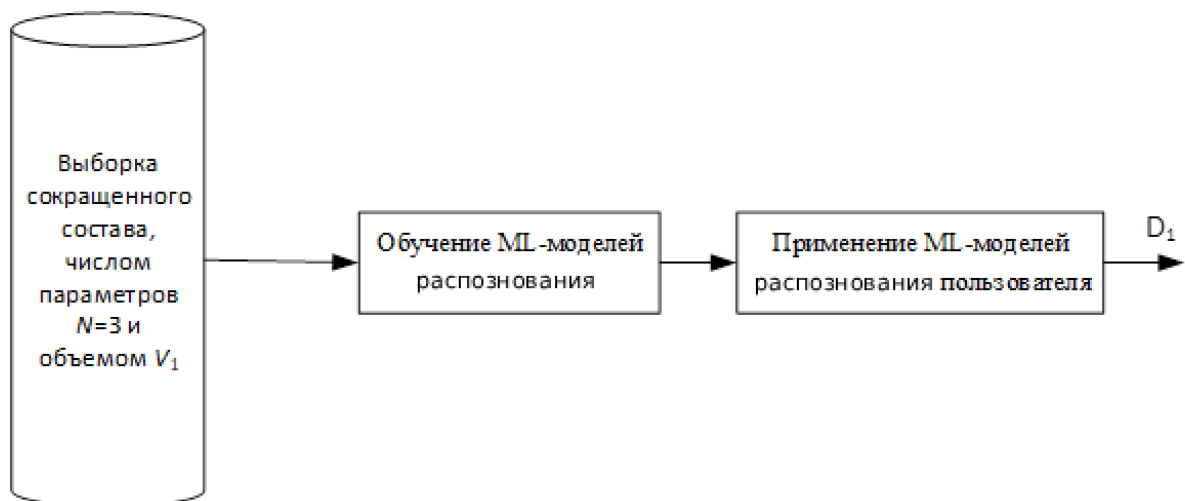


Рисунок 2.1 – Последовательность создания модели классификации по данным выборок большого объема и малого числа параметров

Результирующая достоверность такой модели, ввиду недостаточной информативности выборки сокращенного состава не велика $D_1 < D_{\min}$.

На рис. 2.2 показана последовательность синтеза модели классификации реализаций динамической подписи по данным выборки полного состава $N > 3$, но меньшего объема $V_2 < V_1$. Результирующая метрика качества такой модели, ввиду недостаточной информативности выборки малого объема, также, не велика $D_2 < D_{\min}$.



Рисунок 2.2 – Последовательность создания модели классификации с использованием выборки полного состава и малого объема

На рис. 2.3 иллюстрирована логика повышения информативности синтетического датасета на основе использования информации, содержащейся в обоих исходных выборках.

Выборка полного состава используется для извлечения зависимости между стандартными и дополнительными параметрами.

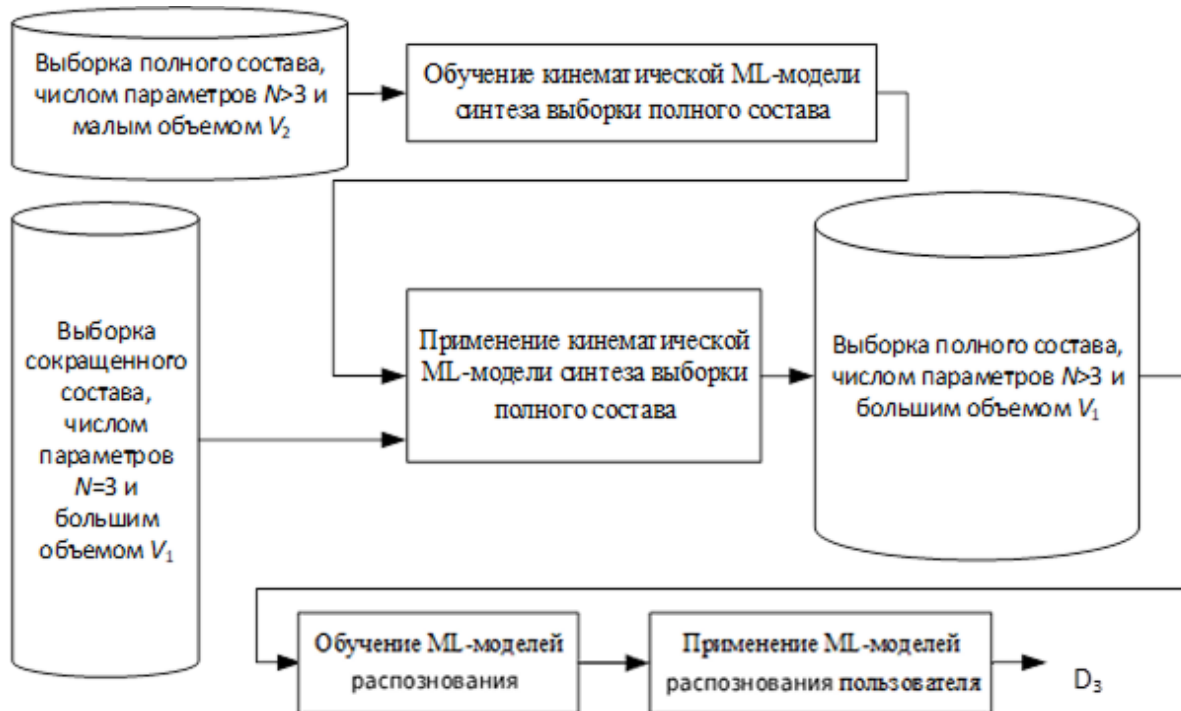


Рисунок 2.3 – Последовательность создания синтезированного датасета

Полученная зависимость описывается в виде модели F_2 , связывающей стандартные и дополнительные параметры в формате «ВХОД-ВЫХОД»:

$$(s_4, \dots, s_N) = F_2(x, y, p), \quad (2.2)$$

где N – число регистрируемых динамических параметров, s – такие дополнительные динамические характеристики, x , y , и p – временные зависимости по осям x , y и давление на холст, соответственно.

В составе общей процедуры анализа и сопоставления динамической подписи с использованием параметрически синтезированной кинематической модели на основе достаточных по объему выборок сокращенного состава создается выборка полного состава, используемая уже для построения искомой модели классификации реализаций с заданным значением метрики качества. $D_2 \geq D_{\min}$.

Учитывая характер входных-выходных данных, их размер и размерность, модель восстановления недостающих значений параметров целесообразно представить в виде многослойной нейронной сети $VProp$ (*Backpropagation*), схема подачи входных-выходных векторов, на которую иллюстрирована на рис. 2.4.




Рисунок 2.4 – Схема подачи входных-выходных векторов на нейросетевую модель в процессе ее обучения и применения

Значительное число $\approx 10^3, \dots, 10^5$ примеров обучающей выборки (для истинных и поддельных подписей всего множества пользователей) при малоразмерном входе-выходе и предполагает двух- трехслойную нейронную сеть со значительным числом нейронов в скрытых слоях.

Таким образом, кинематическая модель пользователя представляет собой нейросетевую модель процесса синтеза полного набора динамических характеристик его подписи на основе исходных стандартных данных [62].

Источниками данных для параметрического синтеза (обучения) многослойной нейронной сети кинематической модели пользователя являются следующие базы данных (табл. 2.1).

Таблица 2.1 – Источники информации для обучения кинематической модели

Наименование БД	Язык носителя подписи	Число истинных подписей/ число поддельных подписей /число подписантов	Особенности
<i>e-BioSign-DSL-Signature DB</i>	Английский	520\390\65	5 различных инструментов для письма. Снято за два сеанса
<i>MOBISIG database</i>	Английский и венгерский	3735/1660/83	Пользователи не использовали свою настоящую подпись
<i>SVC-Task1 subcorpus</i>	Китайский и английский	800/800/40	Пользователи не использовали свою настоящую подпись
<i>SVC-Task2 subcorpus</i>	Китайский и английский	800/800/40	Пользователи не использовали свою настоящую подпись
<i>Synthetic MCYT-330</i>	Английский	8250/8250/330	Имитация исполнения и внешнего вида
<i>Synthetic SUSIG-Blind</i>	Английский	820/880/88	Имитация исполнения и внешнего вида

Все датасеты в таблице 2.1 имеют более 3-х динамических параметров, сняты с различной частотой дискретизации и включают, как минимум скорости по осям x , y . Для восстановления отсчетов разница между частотами дискретизации неважна, основное требование заключается в синхронности регистрации. Основная особенность таких датасетов – редкость и, соответственно, ограниченная суммарная емкость, т.е. число примеров обучающей выборки.

В таблице 2.2 приведены более многочисленные источники, но содержащие ограниченный набор стандартных параметров (координаты x, y и давление). Эти данные подаются на вход обученной модели F_2 и на выходе формируются дополнительные параметры – скорости, ускорения и азимуты.

Таблица 2.2 – Источники информации для применения кинематической модели с целью создания синтетической выборки значительного объема

Наименование БД	Язык носителя подписи	Число истинных подписей/ число нерелевантных /число пользователей	Особенности
<i>SG-NOTE database</i>	Английский	500/0/25	Снято за два сеанса
<i>BSEC 2009</i>	Английский	6480/4320/432	Снято за два сеанса. Оцифровывающий планшет и КПК
<i>SigWlcomp 2015</i>	Английский и немецкий	450/300/30	
<i>Signature Long-Term DB</i>	Английский	1334/0/29	Данные собирались продолжительное время (подписи переменные)
<i>NDSD</i>	Персидские наречия	3575/2200/55	Снято за два сеанса профессиональными фальсификаторами

<i>Biosecur ID-SONOF</i>	Английский	2112/1584/132	Снято за четыре сеанса. Включает синтетические данные
<i>NISDCC database</i>	Английский	1200/600/100	
<i>Synthetic BiosecureID-UAM</i>	Английский	2112/1584/132	Имитация исполнения и внешнего вида
<i>Synthetic NISDCC</i>	Английский	1200/600/100	Имитация исполнения и внешнего вида
<i>Synthetic SVC2004</i>	Английский	1600/1600/80	Имитация исполнения и внешнего вида
<i>Synthetic SUSIG-Visual</i>	Английский	1880/940/94	Имитация исполнения и внешнего вида
<i>SigComp2009</i>	Английский	1260/2613/112	
<i>SigWiComp2013</i>	Английский, Датский	270/972/27	
<i>SigWiComp2013</i>	Японский	2604/2232/62	
<i>QU-PRIP</i>	Арабский	1164/582/200	В основном арабские пользователи
<i>SIGMA. Malaysian</i>	Малазийский	6000/2000/265	Снято за три сеанса
<i>Synthetic OnOff SigBengali-75</i>	Бенгальский	24/75/4	Имитация исполнения и внешнего вида
<i>Synthetic OnOff SigHindi-75</i>	Деванагари (хинди)	24/75/4	Имитация исполнения и внешнего вида
<i>GPDS-960 Signature DB</i>	Английский	21144/26430/881	
<i>GPDS-300 Signature DB</i>	Английский	7200/9000/300	Сокращенный вариант <i>GPDS-960 Signature DB</i>
<i>Brazilian (PUC-PR)</i>	Английский	6720/2280/168	
<i>BiosecurID</i>	Английский	6400/4800/400	Снято за четыре сеанса

В рамках настоящих исследований для обучения модели использовалась база данных *MOBISIG*, представляющая собой набор псевдоподписей 83 пользователей (49 мужчин, 34 женщины), полученные с помощью мобильного устройства с емкостным сенсорным экраном (планшет Nexus 9, Android 6.0) [63]. База данных была собрана за три сеанса, в результате чего у каждого пользователя было контролируемым

(осознанным) способом зафиксировано 45 подлинных подписей и 20 квалифицированных подделок. Средний возраст: пользователей: 26,03 лет, стандартное отклонение: 9,84 года.

Каждая подпись представлена в виде последовательности точек и сохранена в отдельном текстовом в файле (рис. 2.5).

```
x,y,timestamp,pressure,fingerarea,velocityx,velocityy,accelx,accely,accelz,gyrox,gyroy,gyroz
143.931,309.07544,11347508,0.83750004,0.08510638,0.0,0.0,-0.005628259,-0.02832979,-0.03575325,0.0,0.0,0.0
143.931,309.07544,11347530,0.875,0.10638297,0.0063614766,0.012534268,-0.004502607,-0.038663834,-0.044602394,4.7453127E-6,-4.7453127E-6,0.0
143.931,309.07544,11347543,0.875,0.10638297,-0.004064243,-0.009276612,-0.004502607,-0.038663834,-0.044602394,4.7453127E-6,-4.7453127E-6,0.0
150.31651,291.1034,11347563,0.8625,0.09574468,325.90872,-917.2439,-0.004502607,-0.038663834,-0.044602394,4.7453127E-6,-4.7453127E-6,0.0
174.71983,257.2716,11347580,0.8625,0.12765957,1222.7802,-2068.0803,-0.004502607,-0.038663834,-0.044602394,4.7453127E-6,-4.7453127E-6,0.0
199.9177,232.88159,11347597,0.83750004,0.09574468,1876.3077,-2411.4158,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
224.65454,215.82129,11347613,0.85,0.08510638,2168.7878,-2067.2905,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
240.44403,211.3888,11347630,0.83750004,0.08510638,1840.6852,-1143.5242,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
248.93805,217.15198,11347647,0.85,0.09574468,736.26385,524.43024,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
258.0244,232.21582,11347663,0.85,0.12765957,191.93147,1231.6318,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
266.49496,266.2771,11347680,0.85,0.09574468,191.19623,2071.5632,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
268.3905,298.70374,11347697,0.8625,0.12765957,119.946785,2710.2627,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
264.93686,335.7964,11347714,0.8625,0.11702127,-122.157906,2933.646,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
260.31213,376.16467,11347730,0.8625,0.09574468,-481.04474,2755.7817,-0.004502607,-0.038663834,-0.044602394,0.0,0.0,0.0
```

Рисунок 2.5 – Фрагмент датасета *MOBISIG*

На вход сети *VProp* подавались три значения в строке под следующими заголовками:

- 1) x – проекция текущего положения пера на ось x ;
- 2) y – проекция текущего положения пера на ось y ;
- 3) *pressure* – текущая сила давления пера на экран,

На вход при обучении сети, а при функционировании с выхода снимаются

- 1) *velocityx* – проекция вектора скорости пера на ось x ;
- 2) *velocityy* – проекция вектора скорости пера на ось y ;
- 3) *accelx* – проекция ускорения пера на ось x ;
- 4) *accely* – проекция ускорения пера на ось y .

Итоговая структура кинематической модели представлена на рис.

2.6.




Рисунок 2.6 – Архитектура кинематической модели формирования выборки полного состава на основе нейронной сети *BPProp 3-n-m-k-4*

Размерность скрытых слоёв задавалась в диапазоне от 2 до 4 нейронов. Подбор конфигурации обучения выполнялся в автоматизированном режиме на основе раздельного формирования обучающей, валидационной и тестовой подвыборок.

Параметрический синтез в данной постановке трактуется как экстраполяция неизвестной зависимости по доступным наблюдениям восстанавливается функция, позволяющая распространять выявленную закономерность на новые значения параметров. Традиционно такие задачи решаются регрессионными методами, тогда как нейросетевые модели обеспечивают более общий и гибкий класс аппроксимаций, что повышает эффективность экстраполяции при нелинейных и сложно устроенных связях.

Восстановление зависимости

$$f : A \subset R^3 \rightarrow R^4, \quad (2.3)$$

реализуется нейросетевой моделью, параметры которой настраиваются в процессе обучения на тренировочных данных полной

выборки. Архитектура сети предполагает полное соединение между соседними слоями, а нелинейность вычислительных элементов обеспечивается сигмоидной функцией активации; соответствующее преобразование схематически представлено на рис. 2.7.




Рисунок 2.7 – Основной вычислительный элемент модели *BProp*

Нейроны входного слоя фактически выполняют роль буфера, они лишь передают в сеть поступающие входные сигналы, представляя их копии.

Перед выполнением параметрического синтеза модели веса связей и значения смещений задаются начальной квазислучайной инициализацией – случайными числами, близкими к 0,5 и лежащими в пределах области определения $[0,1]$.

Работа параметрически настроенной кинематической модели опирается на теорему универсальной экстраполяции, согласно которой для любого целого $n \geq 2$ существуют непрерывные действительные функции $\psi^{pq}(x)$, определенные на единичном отрезке $E^1 = [0;1]$ и что каждая определенная на n -мерном единичном кубе E^n непрерывная действительная функция $f(x_1, x_2, \dots, x_n)$ может быть представлена в виде

$$f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{q=2n+1} x_q \left[\sum_{p=1}^n \psi^{pq}(x_p) \right], \quad (2.4)$$

где функции $x_q(*)$ – являются действительными и непрерывными.

В качестве базового метода параметрического синтеза используется алгоритм обратного распространения ошибки. Его применение возможно благодаря дифференцируемости функции активации, что позволяет записать основную операцию корректировки параметров сети в виде

$$w_j(t+1) = w_j(t) - \alpha \frac{\partial E(k)}{\partial w_j(t)}, \quad I(t+1) = I(t) - \alpha \frac{\partial E(k)}{\partial I(t)}, \quad (2.5)$$

где $j=1, \dots, n$, n – число входных элементов (размерность входного вектора), а α – скорость обучения.

Данные преобразованы и нормированы в диапазон $[0,1]$, при этом преобразование вида $x_i^{norm} = \frac{x_i - x_{i,min}}{x_{i,max} - x_{i,min}}$, $x_i^{norm} \in [0,1]$ не используется, т.к.

динамика подписи может содержать выбросы некоторых параметров, являющиеся отличительными признаками пользователя при классификации.

Поэтому в работе применяется статистическое нормирование, опирающееся на базовые статистические характеристики биометрических рядов – среднее значение и среднеквадратическое отклонение. Нормирование выполняет преобразование: $x_i \rightarrow x_i^{norm}$, $i = \overline{1, N_2}$ по соотношениям:

$$x_i^{norm} = \frac{1}{1 + e^{-\left(\frac{x_i - x_i^*}{\sigma_i}\right)}}, \quad x_i^* \equiv \frac{1}{N_1} \sum_{i=1}^{N_1} x_i, \quad \sigma_i^2 \equiv \frac{1}{N_1 - 1} \sum_{i=1}^{N_1} (x_i - x_i^*)^2. \quad (2.6)$$

Здесь N_1 – число отсчетов параметра, N_2 – количество динамических параметров подписи, x_i^* – среднее значение i -го параметра по N_1 отсчетов, σ_i – среднеквадратическое отклонение i -го параметра по N_1 отсчетов.

Обратное преобразование (денормирование) задаётся выражением:

$$x_i = x_i^* - \sigma_i \ln \left(\frac{1}{x_i^{norm}} - 1 \right). \quad (2.7)$$

При подаче данных на вход сети возможны два варианта: использовать исходные значения напрямую (рис. 2.6) либо представлять каждый динамический параметр через позиционные коды. Во втором случае структура (топология) входного слоя изменяется согласно схеме на рис. 2.8.




Рисунок 2.8 – Архитектура модели формирования выборки полного состава на основе нейронной сети *VProp*

Функционирование такой позиционной модели *VProp* описывается выражениями (2.8) - (2.9):

$$\begin{cases} c_j = f \left(\sum_{i=1}^r a_i \alpha_{ij} + \chi_j \right), \\ u_s = f \left(\sum_{j=1}^{r_1} c_j \beta_{js} + \eta_s \right), \\ q_h = f \left(\sum_{s=1}^{r_2} u_s \gamma_{sh} + \nu_h \right), \end{cases} \quad (2.8)$$

$$r = n + m + l, \quad (2.9)$$

где n - количество разрядов для кодирования текущей координаты пера по оси x ;

m - количество разрядов для кодирования текущей координаты пера по оси y ;

l - количество разрядов для кодирования текущей силы нажатия на экран.

Алгоритм формирования кинематической модели отображения или обучения сети *BProp* включает этапы.

1. Формирование архитектуры сети в соответствии с размерностью и размерами обучающих выборок.

2. Начальная инициализация весов $\{\alpha, \beta, \gamma\}$ и смещений $\{\chi, \eta, \nu\}$ датчиком случайных чисел в диапазоне $([0, 1] \pm e)$.

3. Для каждого отсчета выборки активация входного слоя сети вектором $\{X_i\}$, $i = 1, \dots, r$:

$$x_l^i = a_i, \quad i = \overline{1, N}, \quad l = \overline{1, r}. \quad (2.10)$$

4. Вычисление выходов q_h , $h = 1, \dots, n$ согласно (2.8).

5. Вычисление ошибок в выходном слое:

$$\begin{cases} e_h = q_h(1 - q_h)(y_h - q_h), \quad h = 1, \dots, n, \\ \sigma_s = u_s(1 - u_s) \sum_{h=1}^n \gamma_{sh} e_h, \\ \delta_j = c_j(1 - c_j) \sum_{s=1}^{r_2} \beta_{js} \sigma_s. \end{cases} \quad (2.11)$$

6. Корректировка весов и смещений:

$$\begin{cases} \gamma_{sh}(t+1) = \gamma_{sh} + \phi u_s e_h, & h=1, \dots, n, s=1, \dots, r_2, \\ \beta_{js}(t+1) = \beta_{js} + \phi c_j \sigma_s, & j=1, \dots, r_1, \\ \alpha_{lj}(t+1) = \alpha_{lj} + \phi a_{li} \delta_j, & l=1, \dots, r. \end{cases} \quad (2.12)$$

$$\begin{cases} v_h(t+1) = v_h + \phi e_h, & h=1, \dots, n, \\ \eta_s(t+1) = \eta_s + \phi \sigma_s, & s=1, \dots, r_2, \\ \chi_j(t+1) = \chi_j + \phi \delta_j, & j=1, \dots, r_1, \end{cases} \quad (2.13)$$

где $\phi > 0$ - скорость обучения.

7. Контроль ошибки в соответствии с выражением:

$$\forall e_h^k \leq \varepsilon, \quad h = \overline{1, n}, \quad k = \overline{1, N}, \quad (2.14)$$

где ε – абсолютная погрешность экстраполяции одного входного вектора.

При этом вопросы о том является ли найденный минимум глобальным или локальным, а также, какова область притяжения выбранного минимума, и какова частота появления минимумов, рассматриваются как предмет отдельного исследования для конкретного набора данных [64, 65].

Результаты экспериментальных исследований разработанной модели представлены в главе 4.

2.2. Метод эталонирования реализаций динамической подписи на основе SOM в пространстве функционально связанных многомерных кривых

Полученные в рамках предыдущего пункта исследований массивы реализаций динамических параметров рассматриваются в контексте задачи сопоставления и классификации реализаций динамической подписи по

множеству эталонов, а также при наличии пограничных и в нерепрезентативных реализаций. Рассмотрим основные теоретические положения эталонирования в виде кластеризации с привлечением метрического сходства или степени принадлежности.

Определение задач классификации в строгой формальной форме связано с помощью анализа сходства, аналогии (эквивалентности) и отношений, которые занимают промежуточную позицию между ними. Рассмотрим нечеткое отношение эквивалентности (подобия), обозначенное $r = \langle X, R \rangle$. Взяв конечное множество X , рассмотрим определенный на нем подграф графа. Это отношение, определенное тремя точками x, y, z принадлежащими множеству. (рис. 2.9).




Рисунок 2.9 – Подграф нечеткого отношения эквивалентности

В рамках рефлексивного свойства для каждой вершины задаётся самосвязь (петля) с максимальной степенью принадлежности, равной 1. Требование симметрии означает, что значения принадлежности для взаимно противоположных дуг должны совпадать, то есть выполняются соотношения вида:

$$m_R(x, y) = m_R(y, x), \quad m_R(y, z) = m_R(z, y), \quad m_R(x, z) = m_R(z, x). \quad (2.15)$$

что приводит к выполнению следующего соотношения:

$$\begin{aligned}
m_R(x, y) &\geq \min(m_R(x, z), m_R(z, y)), \\
m_R(x, z) &\geq \min(m_R(x, y), m_R(y, z)), \\
m_R(y, z) &\geq \min(m_R(y, x), m_R(x, z)).
\end{aligned}
\tag{2.16}$$

Из указанных аксиом следует принципиальная закономерность, определяющая характер изменения степеней принадлежности для пар вершин в графе отношения подобия. Предположим, что выполняется условие:

$$m_R(x, y) \geq m_R(x, z).$$

Тогда, подставляя в последнее соотношение транзитивности, получаем $m_R(y, x) = m_R(x, y)$, имеем $m_R(y, z) \geq m_R(x, z)$, аналогично, применяя второе соотношение транзитивности, приходим к соотношению $m_R(x, z) \geq m_R(y, z)$.

Для любой тройки точек $x, y, z \in X$ степени принадлежности пар в графе отношения подобия (то есть дуг графа подобия) удовлетворяют следующему правилу – как минимум две из трёх степеней совпадают, а третья не меньше этих значений (то есть либо превосходит их, либо равна им). Из указанного правила сразу следуют важные следствия. Если в этой тройке точка x связана с точкой y $m_R(x, y) = m_R(y, x) > 0$, то точка z оказывается либо связанной одновременно с обеими точками, либо не связанной ни с одной из них.

Если три точки x, y, z образуют взаимосвязанную группу, то для любой добавляемой точки v возможны лишь два варианта: она оказывается связанной со всеми элементами данной тройки либо не имеет связей ни с одним из них. Множество элементов X , взаимосвязанных между собой и «собранных» вокруг некоторой точки, образует класс отношения подобия.

Точка $v \in X$, не принадлежащей данному классу, формируется иной класс подобия. В результате множество X распадается на систему попарно непересекающихся классов, то есть образует разбиение, по смыслу близкое

к разбиению при отношении эквивалентности. Отличие заключается в том, что внутри каждого класса связи между элементами задаются не бинарно, а через согласованные степени принадлежности, удовлетворяющие ранее установленному правилу.

Далее вводится постановка задачи нелинейного программирования с непрерывными переменными m_{ij} , \vec{v}_i :

$$I = \sum_{i=1}^k \sum_{j=1}^N m_{ij}^2 \left\| \vec{z}^j - \vec{v}_i \right\|^2 \rightarrow \min_{\{m_{ij}\}, \{\vec{v}_i\}}. \quad (2.17)$$

где \vec{z}^j – параметрическое представление комбинации значений динамических характеристик подписи

$$\sum_{i=1}^k m_{ij} = 1, \quad j = 1, 2, \dots, N, \quad \forall i, \forall j, m_{ij} \geq 0. \quad (2.18)$$

m_{ij} – степени принадлежности j -х объектов к i -м кластеру

$$\vec{v}_i = \frac{1}{\sum_{j=1}^N m_{ij}^2} \sum_{j=1}^N m_{ij}^2 \vec{z}^j, \quad i = 1, 2, \dots, k, \quad (2.19)$$

\vec{v}_i – координаты искоемых кластеров.

Это задаёт формальную основу для решения задачи кластеризации и предполагает реализацию процесса в два этапа: подготовительный и основной.

Подготовительный этап ориентирован на первичную таксономическую группировку множества объектов $P = \{p^1, p^2, \dots, p^N\}$. Для этого на P задаётся отношение сходства \bar{r} . После чего строится его транзитивное замыкание, обеспечивающее согласованность связей и возможность формирования устойчивых групп. При этом информация о признаковых описаниях z^j временного ряда параметра динамической подписи, образующих множество $Z = \{z^1, z^2, \dots, z^N\}$, не включается в

отношение r напрямую, однако используется опосредованно — через процедуру вывода и фиксации фактов сходства между объектами.

Шаг первый. Формируется отношение сходства r на множестве P .

Шаг второй. Выполняется транзитивное замыкание, в результате чего определяется отношение подобия \bar{r} .

Шаг третий. На основе \bar{r} выполняется разбиение множества P на k классов эквивалентности (значение k выбирается по результатам содержательного анализа).

Шаг четвертый. Для каждого из k классов эквивалентности, используя отношение подобия r задаётся соответствующее ему множество кластеров; далее выделяется один кластер, например кластер с максимальной суммой степеней принадлежности объектов. Для выбранного кластера фиксируются значения m_{ij} каждого j -го объекта.

Шаг пятый. Используя векторы признаков z^j соответствующие объектам p , и значения m_{ij} по соотношению (2.19) вычисляются координаты центров кластеров \vec{v}_i^o , $i = 1, 2, \dots, k$.

Основной алгоритм кластеризации включает 3 шага.

Шаг первый. По текущим значениям m_{ij} ($i=1, 2, \dots, k$; $j=1, 2, \dots, N$) с применением (2.19) рассчитываются центры \vec{v}_i , $i = 1, 2, \dots, k$. На первой итерации этот шаг эквивалентен шагу 5 алгоритма предварительной кластеризации (определением \vec{v}_i^o , $i = 1, 2, \dots, k$).

Шаг второй. Для каждого объекта p^j ($j=1, 2, \dots, N$) по формуле

$$m_{ij} = \frac{1}{\left(\vec{z}^j - \vec{v}_i\right)^2 \sum_{i=1}^k \frac{1}{\left\|\vec{z}^j, \vec{v}_i\right\|^2}} = \frac{1}{\sum_{i=1}^k \left(\frac{\left\|\vec{z}^j, \vec{v}_i\right\|}{\left\|\vec{z}^j, \vec{v}_i\right\|} \right)^2}, \quad i = 1, \dots, k, \quad j = 1, \dots, N \quad (2.20)$$

пересчитываются степени принадлежности m_{ij} , ($i=1, 2, \dots, k$; $j=1, 2, \dots, N$). полученные значения m_{ij} сохраняются.

Шаг третий. Проверяется критерий остановки для всех m_{ij} должно выполняться условие

$$\delta(m_{ij}, m'_{ij}) \leq \varepsilon, \quad (2.21)$$

где m_{ij} – степени принадлежности текущей итерации, m'_{ij} – значения, полученные на предыдущем шаге, $\delta(m_{ij}, m'_{ij})$ – мера отклонения, $\delta(m_{ij}, m'_{ij}) = |m_{ij} - m'_{ij}|$; ε – заданный порог. Если порог превышен – итерационный процесс прекращается, иначе выполняется возврат к шагу 1.

Эталонирование динамических параметров подписи пользователя всегда предполагает кластеризацию нескольких стабильных, устойчивых, но различных реализаций.

Современной реализацией модели кластеризации, позволяющей учитывать несколько подклассов в одном эталоне, является самоорганизующаяся карта Кохонена (*Self-Organizing Maps, SOM*). Новизной подхода является не только ее использование для эталонирования пользователей в пространстве динамических параметров их подписей, но и взвешивание признаков.

Предположим, что на вход системы эталонирования поступают отсчеты трех динамических параметров одного пользователя. Все реализации различны, так как условия эксперимента обеспечивают вариабельность подписи. Пусть пользователь генерирует в l различных условиях (физиологических состояниях) множество различных по написанию типов подписей. Необходимо в пространстве отсчетов всех регистрируемых параметров определить координаты l центроидов соответствующих каждому состоянию пользователя в соответствии с критерием оптимальности – максимального правдоподобия.

Обозначим множество искомым центроидов как $G = \{g_k | k = 1, \dots, l\}$, где l – общее количество типов подписей каждого пользователя. Пусть регистрируются три динамических параметра:

- 1) координата отсчета по оси x ,
- 2) координата отсчета по оси y ,
- 3) давление на холст.

Искомая координатная матрица l центроидов, соответствующих различным вариантам подписи одного пользователя:

$$G^l = \begin{bmatrix} x_1^g & y_1^g & p_1^g \\ x_2^g & y_2^g & p_2^g \\ \dots & \dots & \dots \\ x_l^g & y_l^g & p_l^g \end{bmatrix}. \quad (2.22)$$

Тогда, в соответствии с критерием максимального правдоподобия необходимо минимизировать неотрицательную функцию стоимости вида:

$$E = \sum_{k=1}^l \sum_{x \in g_k} C_k \|H_s - G_k\|^2 = \sum_{k=1}^l \sum_{x \in c_k} c_k \sqrt{(x^h - x^c)^2 + (y^h - y^c)^2 + (p^h - p^c)^2}, \quad (2.23)$$

где c_k – коэффициент значимости параметра; h_s – обобщенное обозначение s зарегистрированных реализаций отсчетов трёх рассматриваемых параметров, объединенная координатная матрица которых выглядит как

$$H^s = \begin{bmatrix} x_1^h & y_1^h & p_1^h \\ x_2^h & y_2^h & p_2^h \\ \dots & \dots & \dots \\ x_s^h & y_s^h & p_s^h \end{bmatrix}, \quad (2.24)$$

где $H^s = \{h_1, h_2, \dots, h_s\}$ - множество реализаций подписи одним пользователем.

Фактически матрица (2.24) представляет собой математическую запись множества s . Каждый элемент которого состоит из дискретных временных реализаций трех параметров: первый столбец – отсчеты координат кривой подписи по оси x , второй столбец – отсчеты координат кривой подписи по оси y и третий столбец - отсчеты временной кривой давления p на холст.

Для s – суммарного числа реализаций подписи оценка вероятности p_k того, что r попыток будут принадлежать h_k -му центроиду определяется выражением [66]

$$p_k = \frac{1}{2^s} C_k^r, \quad (2.25)$$

где $C_k^r = \frac{s!}{r!(s-r)!}$ - число способов перекombинации выборок.

В результате изложенного представления динамической подписи по критерию минимуму среднеквадратического расстояния локализуются центроиды кластеров сгущений ее различных реализаций, так, что каждый акт постановки подписи соотносится к одному из l ее вариантов, и все варианты относятся к одному пользователю (рис. 2.10).

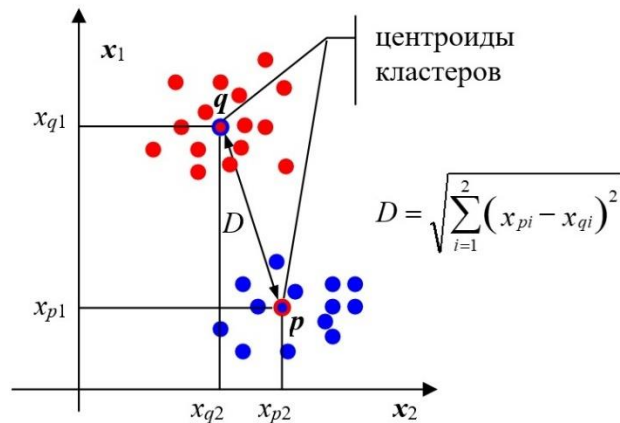


Рисунок 2.10 – Данные, формирующие два кластера на примере двумерного пространства параметров динамической подписи.

SOM-сеть относится к архитектурам искусственных нейронных сетей и, как правило, включает два слоя [67–69]: распределительный взвешенный слой и слой Кохонена. В слое Кохонена нейроны организованы по топологии ближайшего соседства и взаимодействуют через взаимоподавляющие связи.

На вход *SOM* подается вектор $H = (h_1, h_2, \dots, h_m)$ описывающий характеристики всех динамических параметров подписи – например, как точка в N -мерном пространстве, сформированная по отсчётам каждой кривой соответствующего параметра. Выходом сети является отклик слоя: определяется наиболее активный нейрон из вектора $D = (d_1, d_2, \dots, d_n)$, именно нейрон-победитель задаёт кластер (эталон), к которому относится входная реализация.

Вместо экстраполяции функции $f : A^n \subset R^{m=3} \rightarrow R^4$, производящей отображение подмножества A n -мерного евклидова пространства в m -мерное евклидово пространство посредством предварительного обучения на примерах, самоорганизующаяся карта производит непрерывное топологическое отображение $f : B \subset R^{n=3} \rightarrow C \subset R^{m=4}$ посредством самоорганизации, вызванной обучающими векторами y в C , плотность вероятности которых $p(y)$.

Каждый из N элементов сети Кохонена принимает на вход угловые координаты (φ, θ) соответствующие точке в пространстве (U, V) , при этом переход $(U, V) \rightarrow (\varphi, \theta)$ носит нелинейный характер.

Для каждого элемента сети задаётся собственный весовой вектор W_i , согласованный с входным вектором и включающий две компоненты. Дополнительно нейрон получает выходные сигналы остальных элементов сети, что обеспечивает конкурентное взаимодействие и позволяет определить нейрон-победитель.

Целью является параметрический синтез модели эталонирования, функционирующей как указатель положения точки в пространстве (U, V) , хотя на вход сети поступают не координаты (U, V) , а углы (φ, θ) . Например, если точка находится в левом верхнем углу пространства (U, V) , то в нейросети единственным узлом с выходным сигналом, равным 1, должен быть узел, находящийся в левом верхнем углу слоя Кохонена. Если точка в середине - узел в середине. Иными словами, выполняется топологически непрерывное отображение массива координат параметров реализаций динамических параметров подписи в массив координат соответствующих эталонов (кластеров).

Обучение начинается с присвоения весовым коэффициентам случайных, значений, обычно распределенных вокруг точки, являющейся центром поля (U, V) . Обучение состоит из набора шагов, на каждом из которых случайно выбирается точка (U, V) . Затем соответствующие ей угловые координаты подаются на сеть, происходит конкуренция между элементами сети для выявления W_i наиболее близкого к (φ, θ) . Выход элемента-победителя становится равным 1, остальных - 0. После этого производится модификация весов элемента - победителя и его окружения. Веса других элементов остаются без изменения. Процесс адаптации весов представляет из себя обучение Кохонена, рассмотренное ранее:

$$w_{ij}(t+1) = w_{ij}(t) + \eta(h_i(t) - w_{ij}(t)), \quad 0 \leq \eta \leq 1, \quad (2.26)$$

где $h_1 = x, h_2 = y, h_3 = p$, вектор координат реализации подписи пользователем.

Для центрального элемента победителя $\eta \approx 0.8, \dots, 0.9$, для других элементов - уменьшается с увеличением расстояния. Одновременно с ростом времени происходит сжатие окружения вокруг центрального элемента и η внутри этого блока элементов стремится к нулю. После корректировки весов для текущего входного образа на сеть подаётся следующий образ, и описанная процедура повторяется. Процесс обучения продолжается до достижения требуемого уровня согласования между весовыми векторами и входными векторами. По завершении этого этапа сеть считается обученной и может использоваться по назначению — для формирования эталонов.

В обобщенном виде последовательность шагов синтеза модели эталонирования представлена на рис. 2.11.

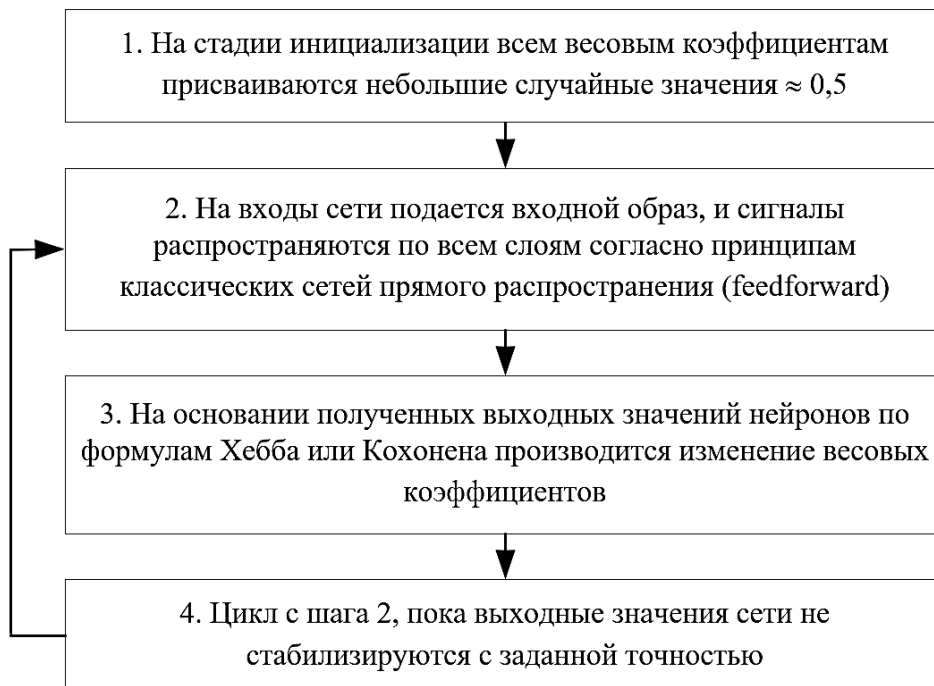


Рисунок 2.11 – Общий алгоритм параметрического синтеза нейросетевой модели эталонирования биометрических реализация

Определение числа кластеров в процедурах кластеризации как правило задается извне. При отсутствии такой информации последовательность шагов включает следующие операции.

1. Определяется критерий оптимальности кластеризации через показатель. Процедура кластеризации запускается несколько раз, после каждой вычисляется сумма квадратов внутри-кластерных расстояний (рис. 2.10):

$$d_{pq} = \sum_{i=1}^n (x_{pi} - x_{qi})^2. \quad (2.27)$$

2. Когда число эталонов различной постановки подписи одним пользователем явно не задано для их определения предлагается использовать процедуру, иллюстрированную на рис. 2.12.

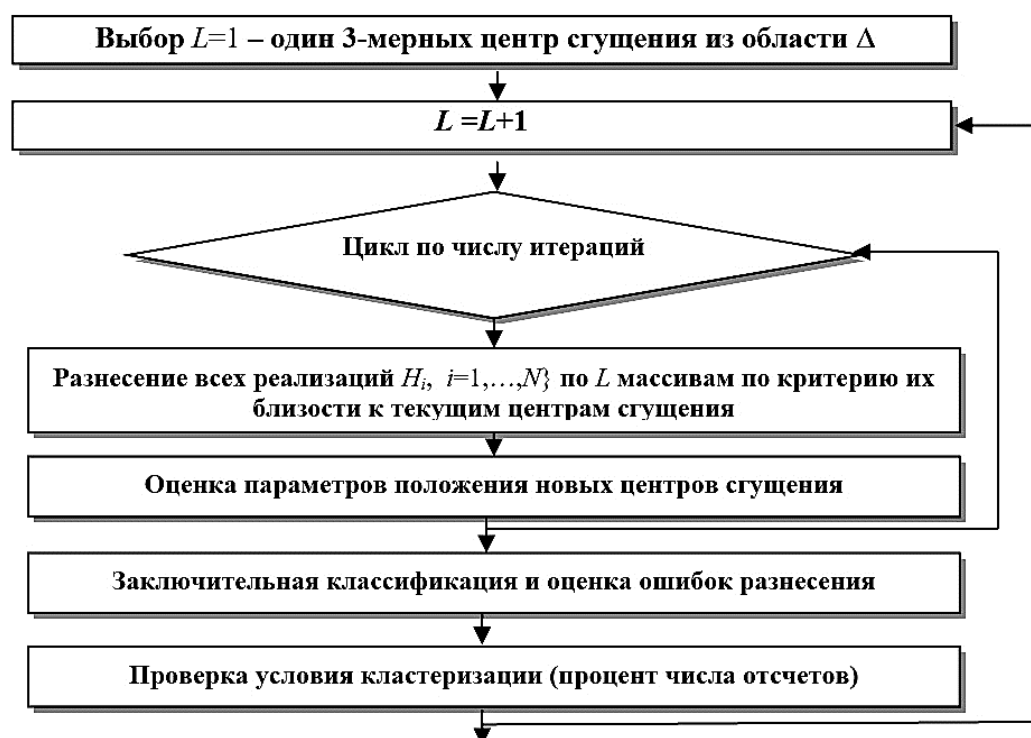


Рисунок 2.12 – Последовательность операций поиска числа центроидов сгущений различных реализаций подписи одним пользователем

Определение начальных параметров центроидов C реализуется путем случайного выбора из 3-х мерной подобласти Δ в соответствии с правилом

$$C_j = \min(\Delta_j) + [\max(\Delta_j) - \min(\Delta_j)] \cdot \text{rand}, \text{ при } \text{rand} \in U[0,1],$$

где $U[0,1]$ – случайная величина с равномерным распределением U на интервале $[0, 1]$.

Пошагово увеличивая число кластеров, контролируется выполнение условия: «численность наименьшей группы эталонированных образцов подписи не должна превышать заданную долю от общего количества». Если данное условие начинает выполняться, то в качестве искомого числа кластеров принимают количество сгущений, полученное на предыдущей итерации.

На рис. 2.13 приведена иллюстрированная последовательность разбиения на $n=5$ классов в модельном примере на плоскости (два динамических параметра подписи) при числе реализаций $s=200$.




Рисунок 2.13 – Последовательность разбиений при поиске оптимального числа классов (слева направо, сверху вниз).

На рис. 2.14. приведен пример проекции вектора весовых коэффициентов нейронов обученного слоя Кохонена, т.е. найденных центроидов (в нашем случае это координаты эталонных реализаций подписи одного пользователя) на плоскость с отмеченными координатами входных векторов – координатами полного множества реализаций подписи одного пользователя. Картина распределения у каждого пользователя своя. Равно как и число его эталонных реализаций динамической подписи.




Рисунок 2.14 – Пример проекции найденных центроидов на плоскость с отмеченными координатами входных векторов множества реализаций подписи одного пользователя

Вместо экстраполяции функции $F: A \subset \mathbb{R}^n \rightarrow \mathbb{R}^m$, производящей отображение подмножества A n -мерного евклидова пространства в m -мерное евклидово пространство посредством предварительного обучения на примерах, самоорганизующаяся карта Кохонена производит непрерывное топологическое отображение $F: B \subset \mathbb{R}^n \rightarrow C \rightarrow \mathbb{R}^m$ посредством самоорганизации, вызванной векторами H в C , плотность вероятности

которых $P(H)$. Самоорганизация сети SOM происходит без знания о нелинейных соотношениях между угловыми и евклидовыми координатами

$$H^s = \begin{bmatrix} x_1^h & y_1^h & p_1^h \\ x_2^h & y_2^h & p_2^h \\ \dots & \dots & \dots \\ x_s^h & y_s^h & p_s^h \end{bmatrix}. \quad (2.28)$$

На рис. 2.15 иллюстрирован пример эталонирования в пространстве двух координат планшета и давления на холст.




Рисунок 2.15 – Исходное распределение 50-ти реализаций подписи одним пользователем и 10 его эталонов

Дополнительно, чем примечательна модель эталонирования на основе карты Кохонена, при появлении новой реализации подписи и подаче ее координат на вход сети SOM на выходе становится активен нейрон-победитель, и его весовые коэффициенты определяют эталон, к которому данная реализация принадлежит. Иными словами, модель эталонирования может выполнять функцию сопоставления и отнесения

реализации к одному из эталонов в случае ее обучения на данных, принадлежащих нескольким классам динамической подписи, а при необходимости – выделять класс неопределенности для пограничных и в нерепрезентативных реализаций.

2.3. Основные современные архитектуры нейронных сетей для классификации различных форм представления многомерных кривых динамической подписи

Прежде чем рассмотреть применимость основных моделей нейронных сетей к решению задачи анализа, сопоставления и классификации различных форм представления многомерных кривых, рассмотрим преимущества и недостатки основных, методологически связанных направлений в классификации и обработке сигналов в таблице 2.3.

Таблица 2.3 – Преимущества и недостатки методов классификации, по массивам биометрических сигнатур

Название метода	Преимущества	Недостатки
Линейная регрессия	Проста и понятна для интерпретации	Предполагается линейная зависимость между предикторами и результатом
	Может использоваться как для классификации, так и для вывода	Может быть чувствительна к выбросам
	Может обрабатывать как числовые, так и категориальные предикторы	Не может справиться с нелинейными взаимосвязями между предикторами и результатом
Логистическая регрессия	Проста и понятна для интерпретации	Предполагается линейная зависимость между предикторами и логарифмами коэффициентов результата
	Может использоваться как для классификации, так и для вывода	Может быть чувствительна к переобучению, если модель слишком сложна
	Может давать вероятностные результаты классификации текста	Не может справиться с нелинейными зависимостями между предикторами и логарифмическими коэффициентами результата

Деревья решений	Проста и понятна для интерпретации	Могут подвергаться переобучению, если дерево слишком глубокое или набор данных слишком мал
	Могут обрабатывать как числовые, так и категориальные предикторы	Могут быть нестабильными и чувствительными к небольшим изменениям в данных
	Могут фиксировать взаимодействия между предикторами	Могут плохо обобщаться на новые данные
Метод опорных векторов (SVM)	Могут обрабатывать данные большой размерности	Вычислительно затратны для обучения и оценки, особенно с большими наборами данных
	Хорошо справляются с широким спектром задач, особенно когда данные можно разделить	Могут плохо работать с сильно несбалансированными наборами данных
	Использование ядра позволяет SVM улавливать сложные нелинейные взаимосвязи между предикторами и результатом	Выбор функции ядра и параметров может значительно повлиять на производительность модели
Наивный байесовский классификатор	Прост и легко доступен в реализации	Может не сработать должным образом, если будет нарушено предположение о независимости
	Может обрабатывать данные большой размерности	Чувствителен к выбору априорных вероятностей
	Может хорошо работать с небольшими наборами данных	Предполагает, что входные объекты условно независимы с учётом переменной класса, что может быть неверно на практике
K-ближайшие соседи (KNN)	Прост и легко доступен в реализации	Обучение и оценка могут быть дорогостоящими с точки зрения вычислений
	Может фиксировать нелинейные взаимосвязи между предикторами и результатом	Может плохо работать с данными высокой размерности
	Может хорошо работать с небольшими наборами данных	Может быть чувствителен к выбору числа K и метрики расстояния
AdaBoost	Может обрабатывать данные большой размерности	Обучение и оценка могут быть дорогостоящими с точки зрения вычислений
	Как правило, хорошо справляется с широким спектром задач	Может плохо работать с сильно коррелированными предикторами
	Может быть менее подвержен переобучению, чем отдельные слабые классификаторы	Может быть чувствителен к зашумлённым данным и выбросам
XGBoost	Как правило, хорошо справляется с широким спектром задач	Обучение и оценка могут быть дорогостоящими с точки зрения вычислений
	Может обрабатывать данные большой размерности	Может быть чувствителен к зашумлённым данным и выбросам
	Может быть менее подвержен переобучению, чем отдельные деревья решений	Может плохо работать с сильно коррелированными предикторами

Выделяют три базовые направления развития архитектур нейронных сетей:

- 1) многослойные сети с полной либо частичной межслойной связностью, обучение которых выполняется различными модификациями алгоритма обратного распространения ошибки;
- 2) самоорганизующиеся структуры, включая слои самоорганизации и карты SOM;
- 3) динамические сети.

Первые две архитектуры рассмотрены в п. 2.1 и 2.2 настоящей главы, и их особенностями являются то, что выходной вектор, получающийся в результате работы нейросети, характеризует состояние элементов сети. Он может быть либо двоичным, либо состоять из действительных чисел. Смысл, который имеют значения этого вектора, определяется в зависимости от решаемой проблемы.

Известно, что эти образы могут принадлежать к одному из 4-х классов. На выходном слое задаем 4 нейрона. В процессе предварительного обучения настраиваем сеть таким образом, чтобы, получая образ i -ого класса, состояние i -ого нейрона выходного слоя становилось = 1, остальных = 0. Возможны и другие варианты построения сетей, например, как описано в п. 2.1 – позиционное кодирование.

Возможности нейронных сетей по распознаванию образов определяются их структурой, функцией преобразования, осуществляемой элементами сети, и механизмами обучения. Так, среди однонаправленных сетей, наиболее сложную классификацию образов могут выполнять многослойные сети *VProp* и *CNN* (*Convolutional neural network*, свёрточные сети) при условии использования одной и той же функции преобразования в узлах сети).

Значительное количество примеров обучающих выборок – исходных и синтезированных с помощью кинематических моделей представления данных обуславливает применение класса многослойных *MLP* (*multilayer*

perceptron) (или *BProp*) сетей, как наиболее информационно-емких структур распознавания образов.

2.4. Методика нейросетевого отождествления образца динамической сигнатуры подписи с эталонами по кортежу уникальных матриц синаптических коэффициентов межнейронных связей

В процессе обучения нейросетевой модели анализу и классификации реализаций динамической сигнатуры подписи формируются наборы матриц синаптических коэффициентов, задающие устойчивое отображение элементов множества реализаций динамических параметров в элементы множества эталонов, соответствующих различным устойчивым вариантам исполнения подписи в условиях внутриклассовой вариативности.

Формирование значений матриц является случайным процессом в силу начальной инициализации весов и смещений случайными числами. Однако каждому пользователю, в итоге, соответствует свой уникальный набор значений коэффициентов матриц межнейронных связей.

Основная идея методики отождествления образца динамической сигнатуры подписи с эталонами по кортежу уникальных матриц синаптических коэффициентов межнейронных связей заключается в декомпозиции процедуры классификации на последовательность операций использования каждого набора матриц. В этом случае в алфавит классов необходимо ввести элемент – «отказ от распознавания», когда входная реализация не может быть отнесена ни к одному из эталонов с заданным уровнем уверенности [64].

Предполагается, что благодаря такой декомпозиции общего процесса достигается повышение качества сопоставления и устойчивости классификации, т.к. необходимо обучать не единую крупную нейронную сеть на большом числе классов и внутриклассовых реализаций, а систему

компактных сетей, на выходе которой реализуется логическая схема «и/или/нет», позволяющая методом уточнений и поэтапного принятия решения относить входную реализацию к одному из эталонов с заданным значением метрики качества. Проигрышем в данной ситуации становится оперативность процедуры классификации, однако рост вычислительных мощностей конечных устройств со временем нивелирует данный недостаток.

Дополнительно, внедрение методики отождествления эталона динамической сигнатуры подписи пользователя по кортежу уникальных матриц синаптических коэффициентов межнейронных связей повлечет изменения в систему хранения данных пользователей, т.к. понадобится использование не только специализированных баз данных временных рядов, но и системы распределенного хранения и модификации матриц синаптических связей, однозначно классифицирующих пользователей.

Помимо более оптимального, безопасного хранения и использования для классификации в последовательной уточняющей процедуре, отождествления матрицы синаптических коэффициентов межнейронных связей можно отождествлять с целью исследования зависимости их параметрической схожести со схожестью динамических и статических характеристик реализаций подписей пользователей.

В алгоритмах отождествления в качестве меры близости обычно используют среднеквадратическое расстояние между классифицируемым набором матриц w и набором объектов $W_g = (w_1, w_2, \dots, w_n)$, которые рассматриваются как представление (описание) пользователя:

$$d(w, W_g) = \sqrt{\left(\frac{1}{k_g} \sum_{g=1}^{k_g} d^2(w, w_g) \right)}, \quad (2.29)$$

Здесь k_g – количество объектов, входящих в описание пользователя W_g .

При этом конкретный способ вычисления расстояния между объектами $d(w, w_g)$ может выбираться различным образом. Например, при прямом сравнении координат (признаков) применяется евклидова метрика:

$$d(w, W_g) = \sqrt{\sum_{n=1}^N (X_{wn} - X_{w_g n})^2}, \quad (2.30)$$

где N – размерность признакового пространства.

Если же сопоставление выполняется по угловым отклонениям, то расстояние можно задавать через угол между векторами признаков:

$$d(w, W_g) = \arccos \frac{\bar{X}_w \cdot \bar{X}_{w_g}}{\|\bar{X}_w\| \cdot \|\bar{X}_{w_g}\|}, \quad (2.31)$$

где $\|\bar{X}_w\|$ и $\|\bar{X}_{w_g}\|$ – нормы соответствующих векторов.

В алгоритмах классификации с детерминированными признаками дополнительно допускается учитывать их веса V_j (как меру доверия), вследствие чего выражение для среднеквадратического расстояния переходит к взвешенному виду [64].

$$d(w, W_g) = \sqrt{\frac{1}{k_g} \sum_{j=1}^{k_g} \sum_{k=1}^N V_j^2 (X_{wn} - X_{w_g n})^2}. \quad (2.32)$$

В качестве неполного перечня примеров метрик в пространстве признаков при классификации изображений можно использовать:

- 1) метрику Минковского;
- 2) евклидово и нормализованное евклидово расстояние;
- 3) расстояние Махаланобиса;
- 4) расстояние по Манхэттену – как сумму абсолютных величин отклонений по всем измерениям;

- 5) косинусное расстояние – как единицу минус косинус от угла между объектами;
- 6) корреляционное расстояние – как единицу минус выборочный коэффициент корреляции между значениями признаков многомерной случайной величины;
- 7) расстояние Хэмминга – как процент отличающихся координат от их общего числа;
- 8) расстояние Джаккарда – как единицу минус процент отличающихся ненулевых координат от их общего числа.
- 9) расогласование Кульбака – Лейблера.

В распознающих алгоритмах, опирающихся на вероятностные признаки, роль меры близости выполняет риск (ожидаемые потери), возникающий при принятии решения о том, что объект относится к классу W_i , где i – индекс класса. ($i=1,2,\dots,m$). Описание классов задаётся набором $\{f_i(\bar{X}), P(W_i), \bar{X} = (X_1, X_2, \dots, X_n)\}$. В качестве исходной информации для вычисления такой меры используется платёжная (матрица потерь) вида

$$\left\| \begin{array}{cccc} C_{11} & C_{12} & \dots & C_{1m} \\ C_{21} & C_{22} & \dots & C_{2m} \\ \dots & \dots & \dots & \dots \\ C_{m1} & C_{m2} & \dots & C_{mm} \end{array} \right\|, \quad (2.33)$$

причём элементы главной диагонали соответствуют потерям при правильных решениях.

Пусть вектор признаков классифицируемого объекта w равен \bar{X}_w . Тогда риск, связанный с выбором класса W_g , в ситуации, когда истинная принадлежность объекта может относиться к одному из классов W_1, W_2, \dots, W_m , естественно определять как среднее (по возможным истинным классам) значение потерь из g -го столбца матрицы, т.е. $C_{1g}, C_{2g}, \dots, C_{mg}$. Соответствующий средний риск записывается как

$$R(w \in W_g / \bar{X}_w) = R(W_g / \bar{X}_w) = \sum_{i=1}^m C_{ig} P(W_i / \bar{X}_w), \quad (2.34)$$

Здесь $P(W_i / X_w)$ – апостериорная вероятность того, что $w \in W_i$. Для заданных описаний классов указанная вероятность может быть получена, например, на основе теоремы гипотез либо по формуле Байеса.

$$P(W_i / X_w) = \frac{P(W_i) f_i(\bar{X}_w)}{\sum_{i=1}^m P(W_k) f_i(\bar{X}_w)}. \quad (2.35)$$

2.5. Выводы по второй главе

В результате проведенных исследований в рамках второй главы решены следующие задачи:

1. Разработан метод обработки и расширения динамических параметров подписи по кортежу стандартных параметров сенсорного устройства, включающий в себя кинематическую модель процесса постановки подписи на множестве функционально связанных многомерных кривых динамических параметров реализаций подписи. В основу модели положена гипотеза о возможности повышения качества сопоставления и классификации реализаций динамической подписи за счет экстраполяции зависимости значений дополнительных динамических параметров от кортежа значений стандартных параметров. Выбор нейросетевой модели как многомерного нелинейного экстраполятора для определения проекций скорости и ускорения при известных данных изменения координат по времени, т.е. недостающих параметров динамического портрета подписи, обусловлен размерностью и размерами обучающей выборки при внутриклассовой вариабельности реальных данных.

2. Разработан метод эталонирования реализаций динамической подписи в пространстве функционально связанных многомерных кривых.

Разработка данного метода продиктована выраженной внутриклассовой вариативностью, когда в рамках одного эталона могут формироваться несколько устойчивых вариантов выполнения подписи, что требует их отдельного выделения и кластеризации. Современной реализацией модели кластеризации, позволяющей учитывать несколько устойчивых вариантов в одном эталоне, является сеть *SOM*.

3. Рассмотрены преимущества и недостатки основных, методологически связанных направлений в классификации и обработке многомерных временных рядов, а также основные модели нейронных сетей и их применимость к решению задачи анализа и классификации различных форм представления многомерных кривых динамических параметров подписи. Значительное количество примеров обучающих выборок, исходных и синтезированных с помощью кинематических моделей представления данных, обуславливает применение класса многослойных *MLP (multilayer perceptron)* (или *BProp*) сетей как наиболее информационно-емких структур классификации многомерных сигналов.

4. Представлена декомпозированная методика нейросетевого отождествления образца динамической сигнатуры подписи с эталонами по кортежу уникальных матриц синаптических коэффициентов межнейронных связей. Основная идея заключается в декомпозиции процедуры классификации на последовательность операций использования каждого набора матриц. В этот алфавит классов необходимо ввести элемент – «отказ от распознавания», когда входная реализация не может быть отнесена ни к одному из эталонов с заданным уровнем уверенности. Благодаря такой декомпозиции достигается повышение качества сопоставления и устойчивости классификации при ограничениях на оперативность процедуры классификации.

3. МЕТОДИКИ И АЛГОРИТМЫ АНАЛИЗА, СОПОСТАВЛЕНИЯ И КЛАССИФИКАЦИИ РЕАЛИЗАЦИЙ ДИНАМИЧЕСКОЙ ПОДПИСИ НА ОСНОВЕ НЕЙРОСЕТЕВОГО ВЫЧИСЛИТЕЛЬНОГО БАЗИСА

3.1. Постановка задач анализа и классификации динамической сигнатуры подписи на основе функционального подхода и многоточечного представления статистических характеристик семейства кривых

С учетом выводов второй главы, исходными данными для решения задачи сопоставления и классификации реализаций динамической подписи являются эталоны динамической сигнатуры подписи, представленные в виде многомерной кривой. В качестве исходных данных для синтеза таких шаблонов используются открытые БД, содержащие до десятка параметров динамической реализации подписи, зарегистрированной в различных условиях. Шаблон (эталон) представляет собой математическую кривую, вложенную в многомерное (по числу параметров) пространство, как результат кластеризации (таксономии) множества реализаций динамической подписи в рамках одного класса.

Таким образом алфавит классов представлен множеством шаблонов Ω_1 . Задача анализа и классификации динамической сигнатуры подписи на основе функционального подхода к сопоставлению кривых и многоточечного представления статистических характеристик семейства кривых выглядит следующим образом.

Фактографические сведения о том, какому пользователю принадлежит каждый шаблон, задаются через прецедент-подмножество из L пар «вход–выход»: входами выступают многомерные кривые реализаций подписи $\left\{ X^i \right\}_{i=1}^L$ а выходами — кодовые обозначения владельцев $\left\{ Z^i \right\}_{i=1}^L$,

$t_i, i = \overline{1, L}$ Обучающие векторы фиксируются в моменты времени $t_i, i = \overline{1, L}$, причём в общем случае временная дискретизация может быть неравномерной.

Требуется определить:

1. Многомерную модель F_2 (из множества Φ) отображения

$$\Psi: X \rightarrow Z$$

переводящую входные векторы $X^i \in \Omega_1$ из конечного набора $\{X^i\}_{i=1}^L$ в соответствующие выходные $Z^i \in \Omega_1$ из множества $\{Z^i\}_{i=1}^L, i = \overline{1, L}$. Построение выполняется на основе многомерной экстраполяции конечного числа прецедентов обучающей выборки (принадлежащей Ω_1) с вероятностью p_1 не меньшей минимально допустимой вероятности корректного восстановления вектора $\{Z^i\}_{i=1}^L, i = \overline{1, L}$ при ограничении сверху на максимально допустимую погрешность Δ_1 восстановления каждого параметра динамической подписи.

2. Используя найденную F_2 по прецедент-подмножеству из M абочих входных векторов, $\{X^i\}_{i=1}^M, t_i, i = \overline{1, M}$ зарегистрированных в моменты $t_i, i = \overline{1, M}$, при неравномерном шаге дискретизации и принадлежащих Ω_2 , (при условии $\Omega_1 \cap \Omega_2 = \emptyset$), вычислить соответствующее множество выходов $\{Z^i\}_{i=1}^M, i = \overline{1, M}$, с вероятностью p_2 не ниже минимально допустимой вероятности правильного распознавания вектора $\{Z^i\}_{i=1}^L, i = \overline{1, L}$ с учетом ограничения сверху на максимально допустимую погрешность Δ_2 распознавания каждого параметра динамической подписи. Иными словами, необходимо выполнить многократную классификацию подписи на ранее не встречавшихся примерах и оценить качество полученного распознавания.

3.2. Структурный синтез нейросетевых архитектур анализа и классификации динамических параметров подписи в пространстве отсчетов многомерных кривых

В общем виде модель постановки динамической подписи на интервале времени ее реализации $[t_0, t)$ представляется в виде

$$F : \{U\} \times \{N\} \times \{K\} \times [t_0, t) \rightarrow \{X\} \times [t_0, t), \quad (3.1)$$

где: $\{U\}$ – множество характеристик $U = (u_1, u_2, u_3, \dots, u_m)$, моторных воздействий пользователя на перо стилуса планшета;

$\{N\}$ – множество значений вектора $N = (n_1, n_2, n_3, \dots, n_l)$, физиологических помех с неизвестными статистическими характеристиками, благодаря которым человеческая подпись всегда вариабельна;

$\{K\}$ – множество параметров высокочастотных помех регистрации динамической подписи электроникой планшета $K = (k_1, k_2, k_3, \dots, k_r)$, с известными статистическими характеристиками;

$\{X\}$ – множество значений совокупности кривых подписи $X = (x_1, x_2, x_3, \dots, x_q)$;

F – однозначное отображение элементов множеств $\{U\}$, $\{N\}$, $\{K\}$ в элементы множества $\{X\}$.

Показатель качества постановки подписи, в таком случае, задается в виде векторного функционала $\Phi = (\varphi_1, \varphi_2, \varphi_3, \dots, \varphi_v)$.

Координаты Φ являются независимыми и задаются двумя эквивалентными способами:

- на множествах $\{U\}$, $\{N\}$, $\{K\}$ в виде:

$$\Phi: \{U\} \times \{N\} \times \{K\} \times [t_0, t) \rightarrow R^v, \quad (3.2)$$

где R^v – пространство действительных чисел;

- на множествах $\{U\}$, $\{N\}$, $\{X\}$ в виде:

$$\Phi: \{U\} \times \{N\} \times \{X\} \times [t_0, t) \rightarrow R^v. \quad (3.3)$$

Эквивалентность способов (3.2) и (3.3) обусловлена однозначным отображением F .

Элементы $\{\Phi\}$ по определениям (3.2) и (3.3) удовлетворяют аксиомам и операциям линейного нормированного пространства L_Φ , которое определяется в качестве пространства состояний системы «пользователь–рука–стилус–планшет».

По заданным статистическим характеристикам U и неконтролируемых возмущений при известной модели (3.1) методами теории оценивания и оптимального управления определяются номинальные значения вектора параметров K^H , показателя качества $\Phi^* \in [\Phi^1, \Phi^2]$ и эталонные выходные реакции X^s .

В процессе постановки подписи одним пользователем статистические моменты входных воздействий принимают любые заранее неизвестные значения $U \in \{U\}$ и $N \in \{N\}$.

Особенно такая ситуация характерна для постановки подписи в нестационарных условиях применения, в условиях неизвестных входных воздействий U , в условиях дестабилизирующих факторов N . Для таких ситуаций показатель качества Φ , заданный в виде (3.2) и (3.3), и выходные реакции X , согласно модели (3.1), зависят от неизвестных U , N и K , что является главным отличием задачи распознавания при контроле процессов постановки подписи от тестовых процедур постановки или подделки подписи.

Система (3.1) обладает естественной избыточностью, если размерность X больше суммарной размерности U и N и ранг матрицы

$$\text{rank} \left[\frac{\partial F_i}{\partial U_j} : \frac{\partial F_i}{\partial n_j} \right] \geq m+l, \quad i=1, \dots, q, \quad j=1, \dots, (m+l) \quad (3.4)$$

$q > m+l$ для любых $U \in \{U\}, N \in \{N\}$.

Выполнение условия (3.4) позволяет представить (3.1) в виде системы уравнений

$$x_i = f_i(K, N, U, t), \quad i=1, \dots, q \quad (3.5)$$

и разрешить первые $m+l$ уравнений относительно U и N

$$U_j = U_j(K, X, t), \quad j=1, \dots, m, \quad (3.6)$$

$$N_j = N_j(K, X, t), \quad j=1, \dots, l. \quad (3.7)$$

Уравнения (3.6), (3.7) подставляются в оставшиеся $q - (m+l)$ уравнений (3.5) вместо N и U и получаются $q - (m+l)$ контрольных условий, инвариантных к N и U в виде

$$x_i = f_i(K, X, t), \quad i=1, \dots, (q - (m+l)). \quad (3.8)$$

Если размерность K , равная $r \leq q - (m+l)$, и ранг матрицы

$$\text{rank} \left[\frac{\partial f_i(*)}{\partial k_j} \right] \geq r, \quad i=1, \dots, (q - (m+l)), \quad j=1, \dots, r \quad (3.9)$$

для любых $K \in \{K\}$, то в результате измерения X однозначно определяются координаты K . т.е. обеспечивается заданная глубина диагностирования.

Средние интегральные затраты на реализацию процедуры распознавания в себя затраты на измерения X и организацию вычислительной процедуры определения K .

Описание модели постановки динамической подписи и ее анализа и классификации (для повышения качества сопоставления и устойчивости результатов) несколькими алгоритмами и последующим мажоритарным голосованием организуется в соответствии со схемой на рис. 3.1.



Рисунок 3.1 – Общая схема применения алгоритмов классификации динамической подписи

Для осуществления сопоставления и классификации на вычислительных средствах системы анализа динамической подписи следует реализовать оптимальные (по выбранным критериям) алгоритмы классификации. При решении этой задачи возникают обычные для

многокритериальной оптимизации трудности, усложняющие математическое обеспечение системы. Алгоритм классификации должен в некотором смысле оптимально сопоставлять апостериорные данные о неизвестной реализации подписи с формализованной априорной информацией и на основе этого сопоставления определять, к какому классу она может быть отнесена.

В связи с задачей определения наиболее полного перечня признаков необходимо отметить, что при неограниченном увеличении количества признаков (в условиях определенных ограничений, накладываемых на используемые признаки) вероятность однозначного решения задачи классификации стремится к единице. Кроме того, в системах анализа динамической подписи увеличение количества измеряемых признаков повышает устойчивость сопоставления и классификации в условиях существенной вариативности и неполноты данных, когда отдельные признаки невозможно определить совсем либо их значения искажаются настолько, что возникает риск ошибочного отнесения реализации к классу.

В настоящих алгоритмах используются детерминированные и вероятностные системы представления признаков. Признаки, принятые в этих системах, соответственно подразделяются на детерминированные и вероятностные.

Детерминированная система признаков является наиболее простой. Ее применение целесообразно на первоначальном этапе синтеза системы распознавания, когда имеющаяся априорная информация еще не позволяет проанализировать ошибки измерений отдельных признаков, а также установить существенные логические связи и иерархическую структуру объектов распознавания. Таким образом, если объекты классификации характеризуются только набором конкретных числовых значений, выраженных в той или иной шкале, следует использовать детерминированные признаки, что реализовано в первом алгоритме настоящей главы.

Наиболее информационно-емкой архитектурой для анализа и классификации многомерной реализации динамической подписи в пространстве временных отсчетов многомерной кривой является многослойная нейронная сеть (как правило, с архитектурой *VProp* или *MLP*). Число входных нейронов соответствует конкатенации векторов временных отсчетов кривых вдоль главной размерности (рис. 3.2). Число нейронов выходного слоя соответствует разрядности позиционного кода, однозначно указывающего на владельца подлинной подписи.

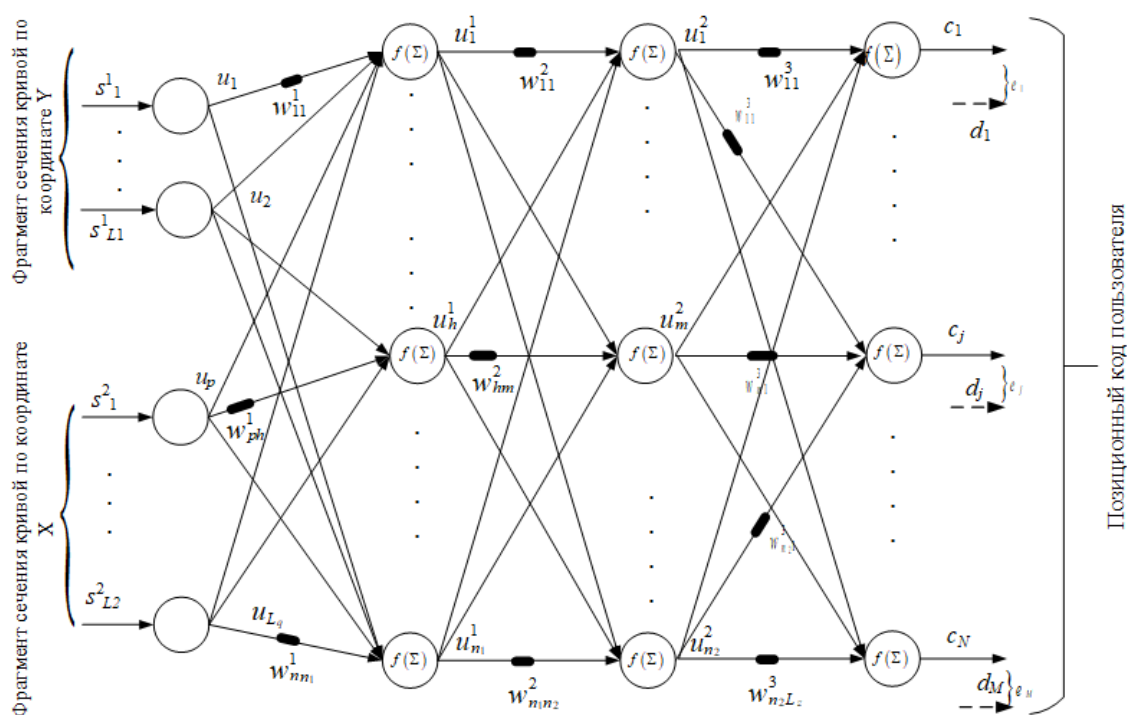


Рисунок 3.2 – Пример архитектуры НС *VProp* для случая двумерной кривой динамической подписи (первое измерение – координата пера по оси X , второе – по оси Y)

Оценка числа межэлементных связей N_w для многослойной сети с сигмоидальными передаточными функциями получается как следствие теорем Арнольда–Колмогорова–Хехт–Нильсена [70 и 71] и выражается соотношением:

$$\frac{L_z L}{1 + \log_2(L)} \leq N_w \leq L_z \left(\frac{L}{n} + 1 \right) (n + L_z + 1) + L_z, \quad (3.10)$$

Здесь L_z – задаёт разрядность позиционного кода пользователей, L – соответствует объёму обучающей выборки протокола наблюдений Ω_1 , а n обозначает число переменных, выбранных в качестве диагностических признаков при распознавании подписи.

С учетом искусственно введенной избыточности для повышения обобщающей способности по данным протокола Ω_1 :

$$f(p_s) \left(\frac{L_z L}{1 + \log_2(L)} \right) \leq N_w \leq f(p_s) L_z \left(\left(\frac{L}{n} + 1 \right) (n + L_z + 1) + L_z \right), \quad (3.11)$$

где $f(p_s)$ – значение некоторой функции от вероятности стохастического подобию реализаций подписи, фактографические данные которых содержатся в протоколе наблюдений Ω_1 .

3.3. Структурный синтез нейросетевых архитектур анализа и классификации динамических параметров подписи в пространстве вторичных признаков многомерных кривых

Под вторичными признаками многомерных кривых динамической подписи подразумеваются различные статистические, спектральные признаки данных кривых, предварительно вычисляемые и подаваемые на вход классифицирующей многослойно НС типа *BProp* или *MLP*.

Механизм сопоставления и классификации должен обеспечивать такое принятие решений, при котором риск оказывается минимальным. Конкретный выбор процедуры определяется тем, какая априорная информация доступна о классах (эталонах) и реализациях, а также тем, как задана функция риска; поэтому в зависимости от условий применяют одну

из стандартных стратегий — байесовскую, минимаксную или стратегию Неймана–Пирсона.

Для простейших постановок известно, что все три подхода приводят к одному и тому же решающему правилу; различия проявляются лишь в том, как выбираются пороговые уровни. В случае многослойных нейронных сетей фактически реализуется байесовское решающее правило, поскольку в задачах распознавания априорные вероятности можно задать заранее на этапе обучения, опираясь на сбор и обработку достоверных данных обо всём множестве объектов классификации.

Предположим, выборка организована в виде непрерывной последовательности реализации динамических параметров подписи, тогда для обнаружения фактов изменения принадлежности подписи возможно использовать большой спектр статистических характеристик как каждой кривой в отдельности, так и их совокупности.

Далее классификация выполняется в квази-реальном времени: требуется лишь интервал, достаточный для получения всех кривых и вычисления их статистических характеристик. В качестве входных данных для НС используются следующие параметры:

- 1) математическое ожидание m_x каждой кривой и оценка его ошибки

$$m_x = \frac{1}{n} \sum_{i=1}^n x_i, \quad e_{mx} = \frac{\sigma}{\sqrt{n}}, \quad (3.12)$$

где n – число отсчётов измеряемого параметра динамической подписи, σ – среднеквадратическое отклонение данного параметра.

- 2) среднеквадратическое отклонение σ :

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - m_x)^2}, \quad e_\sigma = \frac{\sigma}{\sqrt{2n}}, \quad (3.13)$$

- 3) Коэффициент вариации и его ошибка e_g :

$$g = \frac{\sigma}{m_x} 100\%, \quad e_g = g \sqrt{\frac{0,5 + 0,0001g^2}{n}}, \quad (3.14)$$

4) средняя разность Джинни:

$$g = \frac{1}{n(n-1)} \sum_{\substack{i,j=1 \\ i \neq j}}^n |x_i - x_j|, \quad (3.15)$$

5) удельная энтропия кривой H :

$$H = \frac{1}{n} \sum_{i=1}^k a_i \log_2 a_i, \quad k = 3,32 \lg n + 1 = 1,44 \ln n + 1, \quad (3.16)$$

при этом параметр k задаётся через логарифмическую зависимость от n

6) показатель точности регистрации кривой:

$$p = \frac{1}{N} \sum_{s=1}^N \left(\frac{e_{s mx}}{m_{s x}} 100\% \right), \quad e_p = p \sqrt{\frac{1}{2n} + \left(\frac{p}{100} \right)^2}, \quad (3.17)$$

где N – количество измеряемых параметров динамической подписи, s – индекс измеряемого параметра, $m_{s x}$ – математическое ожидание s -го измеряемого параметра, $e_{s mx}$ – ошибка математического ожидания s -го измеряемого параметра.

7) параметр эквивокации для двух реализаций постановки подписи – №1 (соответствующей состоянию покоя пользователя) и №2 (предъявляемой к распознаванию) – определяется как величина, рассчитываемая по выражению:

$$D = \frac{1}{N} \sum_{s=1}^N |I_s^1 - I_s^2|, \quad (3.18)$$

где N - количество измеряемых параметров динамической подписи, I_s^1 - избыточность первой реализации многомерной кривой, I_s^2 - избыточность второй реализации многомерной кривой.

Параметр эквивокации отражает степень структурных изменений процесса постановки подписи в пространстве измеряемых признаков при сопоставлении двух условных состояний одного и того же классифицируемого пользователя. Его можно определить на основе двух векторов статистических признаков динамической подписи: первый формируется по данным, рассчитанным на протяжении первого временного интервала, второй — по данным второго интервала. При этом в каждом из этих интервалов пользователь находится в одном и том же состоянии.

В качестве рабочей гипотезы рассматривалась идея о том, что при переводе анализируемых данных из амплитудной в частотную область могут проявиться характерные признаки или устойчивые взаимосвязи параметров, которые могут быть использованы в качестве показателей для выработки критериев — базовых элементов разрабатываемых классификаторов.

Основные преобразования исходных данных реализованы на базе дискретного преобразования Фурье (ДПФ).

Исследование параметров, преобразованных методом Фурье (в том числе не приведённых на графиках: координаты по оси X , координаты по оси Y , давление на экран, скорость по оси X , скорость по оси Y , ускорение по оси X , ускорение по оси Y), выявило неустойчивость результатов, проявляющуюся в заметных колебаниях от одной выборки к другой. Сходный эффект был получен и при применении дискретного косинусного преобразования (ДКП) согласно выражениям [72].

$$\text{ДКП-I: } \sqrt{\frac{2}{n-1}} \left(\frac{u_1}{2} + \sum_{r=2}^{n-1} u_r \cos \left(\frac{\pi}{n-1} (r-1)(s-1) \right) + (-1)^{s-1} \frac{u_n}{2} \right) \quad (3.19)$$

$$\text{ДКП-II: } \frac{1}{\sqrt{n}} \sum_{r=1}^n u_r \cos \left(\frac{\pi}{n} \left(r - \frac{1}{2} \right) (s-1) \right) \quad (3.20)$$

$$\text{ДКП-III: } \frac{1}{\sqrt{n}} \left(u_1 + 2 \sum_{r=2}^n u_r \cos \left(\frac{\pi}{n} (r-1) \left(s - \frac{1}{2} \right) \right) \right) \quad (3.21)$$

$$\text{ДКП-IV: } \sqrt{\frac{2}{n}} \left(\sum_{r=1}^n u_r \cos \left(\frac{\pi}{n} \left(r - \frac{1}{2} \right) \left(s - \frac{1}{2} \right) \right) \right) \quad (3.22)$$

Коэффициенты гармонических преобразований, также как и статистические моменты показали статистическую устойчивость при разделении пространства признаков на классы классифицируемых пользователей [73].

Следовательно, применение частотного анализа для выделения характерных признаков исследуемого сигнала является оправданным. К области гармонического анализа относят различные формы временно-частотных представлений, включая, в частности, вейвлет-преобразования [74].

С учётом дискретной природы обрабатываемого сигнала для него был апробирован аппарат дискретного вейвлет-преобразования (ДВП):

$$y[n] = (x * g)[n] = \sum_{k=-\infty}^{\infty} x[k] g[n-k] \quad (3.23)$$

В результате вычисляются детализирующие коэффициенты и коэффициенты экстраполяции, которые затем использовались как вторичные признаки и подавались на вход НС.

Путем отбрасывания ряда коэффициентов (детализирующих или, напротив экстраполирующих) имеется возможность реализовать низко- или высокочастотную фильтрацию входного сигнала.

Предположительно, данные преобразования, будучи разновидностью временно-частотного представления должны позволить локализовать искомый фрагмент сигнала на временной оси, что, в конечном счете, позволит решить задачу распознавания и классификации образцов подписи.

Применительно к классу решаемых задач наиболее эффективными являются вейвлет-сглаживание, удаление шума и компрессия сигналов при выборе оптимального базиса и при изменяемом пороге удаления части вейвлет-коэффициентов.

Очистка сигнала выполняется функцией с разными типами порогов, определяющих условия удаления вейвлет-коэффициентов. Эти пороги характеризуются видом их передаточной характеристики.

В дальнейшем, вейвлет-коэффициенты или статистические признаки кривых подаются на вход НС для последующей классификации подписи.

Протокол наблюдений Ω_1 прецедентов вида (3.12) представляет собой матрицу обучающей выборки вида "объект-признак":

$$\Omega_1 = \begin{bmatrix} k_1^1 & \dots & k_{L_k}^1 & v_1^1 & \dots & v_{L_v}^1 & y_1^1 & \dots & y_m^1 & p_1^1 & \dots & p_{L_p}^1 & z_1^1 & \dots & z_{L_z}^1 & q_1^1 & \dots & q_N^1 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ k_1^i & \dots & k_{L_k}^i & v_1^i & \dots & v_{L_v}^i & y_1^i & \dots & y_m^i & p_1^i & \dots & p_{L_p}^i & z_1^i & \dots & z_{L_z}^i & q_1^i & \dots & q_N^i \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ k_1^L & \dots & k_{L_k}^L & v_1^L & \dots & v_{L_v}^L & y_1^L & \dots & y_m^L & p_1^L & \dots & p_{L_p}^L & z_1^L & \dots & z_{L_z}^L & q_1^L & \dots & q_N^L \end{bmatrix}, \quad (3.24)$$

где $(n+L_z+N)$ – размер параметрического описания каждого прецедента;

L – количество строк матрицы, характеризует объем обучающей выборки.

Каждый из векторов $\{Z^i\}_{i=1}^L$, зафиксированный в момент времени $t_i, i = \overline{1, L}$ содержит параметрическое описание кривых подписи в виде:

$$Z^i = (z_1^i, z_2^i, \dots, z_j^i, \dots, z_{L_z}^i), \quad i = \overline{1, L}, \quad j = \overline{1, L_z}, \quad (3.25)$$

где z_j^i – j -й параметр описания подписи, определенный в i -й момент времени;

L_z – общее количество признакового пространства описания подписи.

На этапе синтеза модели распознавания вида подписи (т.е. ее принадлежность) вектор $\{Z^i\}_{i=1}^L$ является выходным для отображения $\Psi_1: \{X\} \rightarrow \{Z\}$ и входным для отображения $\Psi_2: \{P, Z\} \rightarrow \{Q\}$.

Каждая подпись описывается выходным вектором

$$\{Q_j^i\}_{j=1}^N = (q_1^i, q_2^i, \dots, q_j^i, \dots, q_N^i), \quad j = \overline{1, N}, \quad i = \overline{1, L}. \quad (3.26)$$

Множество кортежей элементов вектора $\{Q_j^i\}_{j=1}^N, j = \overline{1, N}, i = \overline{1, L}$ составляет алфавит классов подписи.

Этап формирования протокола матрицы Ω_1 завершается предобработкой значений матрицы (3.24). Как входами, так и выходами модели классификации вида подписи могут быть совершенно разнородные величины. Результаты синтеза и использования модели не должны зависеть от единиц измерения этих величин.

Основной операцией предварительной обработки является приведение значений $\{X^i\}_{i=1}^L$ к единичному масштабу, что обеспечивается нормировкой каждой j -й переменной $x_1^i, x_2^i, \dots, x_p^i, \dots, x_n^i, p = \overline{1, n}, i = \overline{1, L}$ на диапазон разброса ее значений по всем отсчетам $i = \overline{1, L}$.

Этап структурного синтеза модели классификации и анализа заключается в определении количества слоев MLP-классификатора, числа

рабочих и избыточных нейронов в каждом слое, задание вида функции активации в каждом слое, количества избыточных нелинейных преобразователей в каждом слое. Основной принцип использования модели на основе *MLP*-классификатора состоит в неизменности форматов данных, используемых для параметрического синтеза и данных, на основе которых осуществляется распознавание вида подписи.

Так как модель реализует два отображения: $\Psi_1: \{X\} \rightarrow \{Z\}$ и $\Psi_2: \{P, Z\} \rightarrow \{Q\}$, рассмотрим структуру нейроклассификатора каждого из них.

Общая структура нейроклассификатора, осуществляющего распознавание одного из N видов подписи по вектору фактографических данных X на входе с учетом данных P показана на рис. 3.3.




Рисунок 3.3 – Структура нейроклассификатора для отображений отсчетов кривых во множество идентификаторов пользователей

Таким образом, определённая структура *MLP*-классификатора для отображений $\Psi_1: \{X\} \rightarrow \{Z\}$, $\Psi_2: \{P, Z\} \rightarrow \{Q\}$ и сформированные по данным протокола Ω_1 обучающие выборки позволяют перейти к параметрическому синтезу модели классификации вида подписи и ее принадлежности.

Параметрический синтез модели осуществляется отдельно для каждого отображения, а также может быть отдельным для каждой кривой

с последующим комплексированием результатов по технологиям «*Multi-sensor fusion*» или «*Data fusion*».

3.4. Методика классификации динамической сигнатуры в пространстве многоточечного представления инвариантов

Многоточечный объект (МТО) представляет собой множество упорядоченных (индексированных) точек, представленных в общем случае, в N -мерном пространстве. Известно, что групповые признаки по сравнению с признаками отдельных объектов обладают большей устойчивостью к действию мешающих факторов и имеют более высокую информативность. Информативность повышается не только за счет информативности значений координат каждой точки в отдельности, но и за счет использования информации об их взаимном расположении в пространстве.

Многоточечные объекты – это объекты классификации, регистрируемые с использованием информационных процедуры регистрации динамической подписи. Каждая точка представляет собой значение статистической или иной характеристик каждой кривой, таким образом, число точек соответствует числу кривых динамической подписи, а размерность пространства вложения – числу статистических характеристик, вычисляемых по каждой кривой.

Элемент МТО – индексированная (упорядоченная) точка ξ_j , $j = \overline{1, M}$ – нульмерный пространственный (именованный) объект, характеризующийся, например в декартовой системе координат уникальным вектором $[x_{1j}, x_{2j}, \dots, x_{ij}, \dots, x_{Nj}]^T$, $i = \overline{1, N}$, $j = \overline{1, M}$ размера $1 \times N$, где x_{ij} – проекция j -го вектора из начала системы координат или полюса на i -ю ось.

Если пронумеровать векторы ортонормированного базиса от 1 до N , то в основе матричной модели будет последовательная запись координат точек:

$$\left\{ x_{ij} \right\}_{i=1}^N = \begin{bmatrix} x_{11} & x_{21} & \cdots & x_{i1} & \cdots & x_{N1} \\ x_{12} & x_{22} & \cdots & x_{i2} & \cdots & x_{N2} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ x_{1j} & x_{2j} & \cdots & x_{ij} & \cdots & x_{Nj} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ x_{1M} & x_{2M} & \cdots & x_{iM} & \cdots & x_{NM} \end{bmatrix}. \quad (3.27)$$

Каждая строка задает точку $\xi_j, j = \overline{1, M}$, в N -мерной системе координат. Один из способов их нумерации выполняется в соответствии с порядком появления точки при сканировании области наблюдения.

Алгоритм распознавания МТО можно представить семью основными шагами [75].

1. На первом этапе метода осуществляется нормировка всех шкал, в которых измерены характеристики точек в единый диапазон $[a \ b]$:

$$x_i^{\text{norm}} = \frac{x_i - x_{i,\min}}{x_{i,\max} - x_{i,\min}}(b - a) + a, \quad i = \overline{1, N}, \quad (3.28)$$

2. Фиксация типа интегрального геометрического инварианта в N -мерном пространстве.

3. Вычисляется матрица попарных расстояний между точками:

$$[D_{ij}] = \begin{bmatrix} 0 & D(\xi_2/\xi_1) & D(\xi_j/\xi_1) & D(\xi_M/\xi_1) \\ D(\xi_1/\xi_2) & 0 & D(\xi_j/\xi_2) & D(\xi_M/\xi_2) \\ D(\xi_1/\xi_i) & D(\xi_2/\xi_i) & 0 & D(\xi_M/\xi_i) \\ D(\xi_1/\xi_m) & D(\xi_2/\xi_m) & D(\xi_j/\xi_m) & 0 \end{bmatrix}, \quad (3.29)$$

где $D(\xi_j/\xi_i)$ – расстояние между точками i, j , $D(\xi_j/\xi_i) = D(\xi_i/\xi_j)$. Поскольку обработка МТО включает процедуры выделения отдельных точечных объектов и их последующей локализации, корректно использовать такую формулу расстояния между точками i, j , в которой в качестве аргумента учитывается достоверность локализации (или распознавания) i -й точки образца МТО:

$$D(\xi_j/\xi_i) = \left(\frac{1}{\rho_i} \sum_{r=1}^N |\xi_{ir} - \xi_{jr}|^2 \right)^{\frac{1}{2}}, \quad (3.30)$$

ρ_i – достоверность классификации i -й точки образца, N – размерность пространства признаков МТО.

4. На основе $[D_{ij}]$ формируется вектор $[Y]$ элементов треугольной полуматрицы попарных расстояний между точками образца МТО:

$$\begin{aligned} X = [D(\xi_2/\xi_1), \dots, D(\xi_j/\xi_1), \dots, D(\xi_M/\xi_1), D(\xi_j/\xi_2), \dots \\ D(\xi_M/\xi_2), \dots, D(\xi_M/\xi_i), \dots, D(\xi_M/\xi_{M-1})] = [y_1, \dots, y_n], \end{aligned} \quad (3.31)$$

где n – число попарных расстояний между точками образца МТО, $n = M!/(2!(M-2)!)$, а m – число точек образца МТО.

5. Далее формируется двумерный массив индексов, предназначенный для построения r фрагментов каждого из L_k векторов попарных расстояний $X_l, l = \overline{1, L_k}$ для шаблонов алфавита классов, при этом число точек в шаблонах принимается равным числу точек распознаваемого образца МТО.

6. Затем выполняется перестановка индексов точек для каждой перестановки в евклидовой метрике вычисляется показатель близости (сходства) векторов X для матрицы шаблонов и распознаваемого образа.

7. Решение о классе принадлежности принимается по минимуму критерия:

$$E_k^l = \sqrt{(x_{k1} - x_{k1}^l)^2 + (x_{k2} - x_{k2}^l)^2 + \dots + (x_{kn} - x_{kn}^l)^2} = \sqrt{\sum_{i=1}^n (x_{ki} - x_{ki}^l)^2}, \quad (3.32)$$

$$C = \arg \min(\arg \min(E_r^l)), \quad r = \overline{1, R}, \quad l = \overline{1, L_k},$$

где R число допустимых комбинаций точек l -го шаблона соразмерного распознаваемому образцу, L_k – количество шаблонов на k -м уровне представления (рис. 3.4).

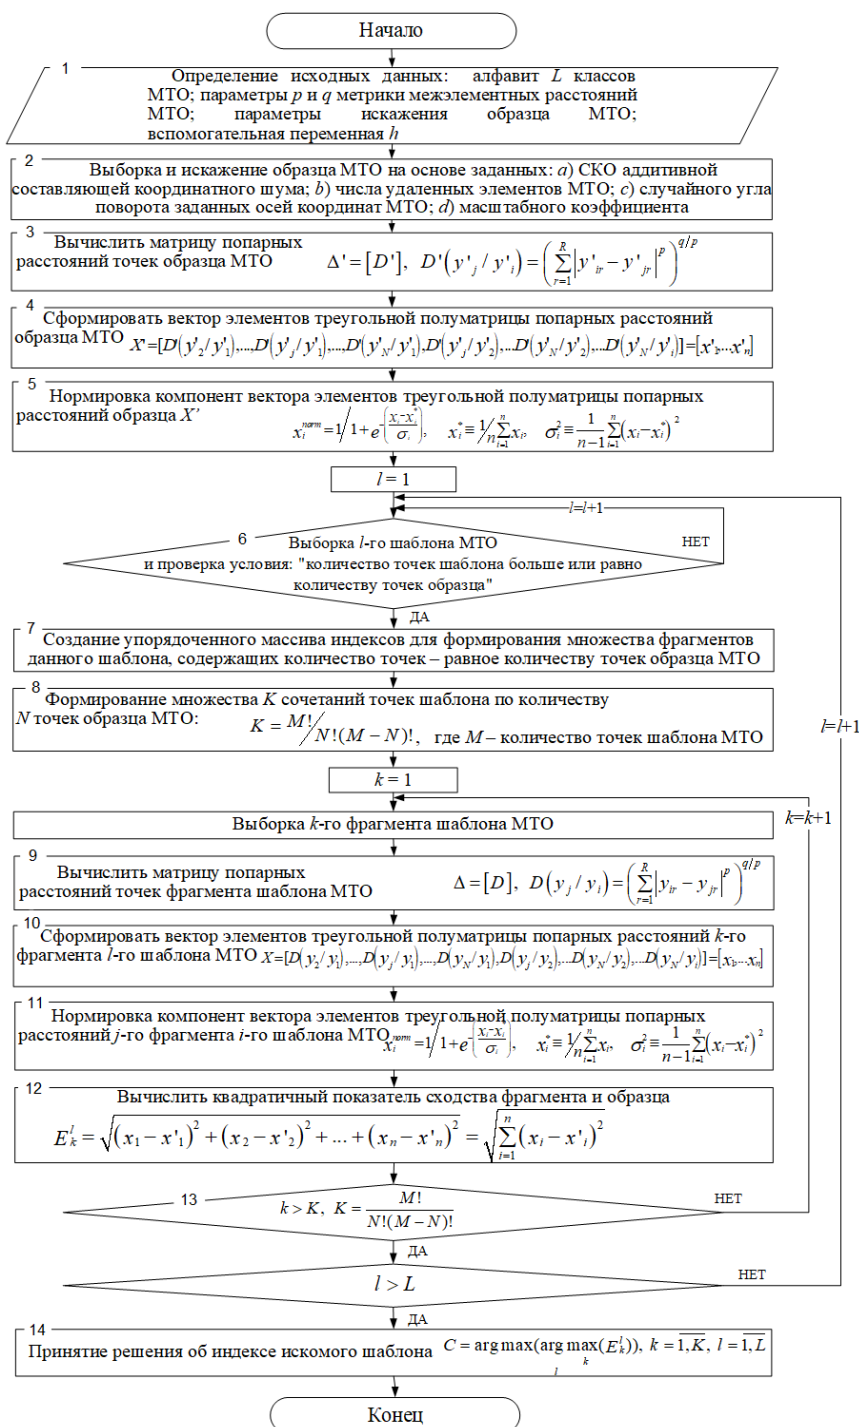


Рисунок 3.4 – Алгоритм методики нейросетевого анализа и классификации динамической сигнатуры подписи пользователя

3.5. Алгоритм комплексного анализа и классификации динамической сигнатуры подписи в пространстве отсчетов многомерных кривых

Под алгоритмом комплексного анализа и классификации понимается схема, при которой многомерный фрагмент кривой параллельно обрабатывается несколькими различными обнаружителями, а затем их частные решения объединяются на этапе комплексирования.

Рассматриваемый алгоритм строится на интеграции нескольких групп признаков, отличающихся по масштабам измерения и характерным временным изменениям. Такая организация входных данных приводит к тому, что процедура идентификации подписи фактически реализует принципы объединения информации из разных источников, характерные для подходов *Multi-sensor fusion* или *Data fusion*, применяемых при вынесении классификационного решения [76]. Существенным элементом является унификация представления измерений и перевод исходных параметров в общее метрическое пространство, что повышает устойчивость к помехам, а также позволяет компенсировать вклад менее надёжных каналов за счёт согласования и взаимной поддержки признаков [77, 78].

Алгоритм классификации относится к методам машинного обучения и включает этапы формирования модели на данных и последующего использования при обработке поступающей информации в режиме, приближенном к реальному времени [79]. Единое пространство признаков обеспечивает совместимость с широким спектром инструментов распознавания образов — от классических алгоритмов до параллельных реализаций, включая нейросетевые архитектуры, что расширяет возможности выбора и адаптации алгоритмического базиса под конкретные ограничения задачи [80].

В рамках этапа интеграции признаков оценка степени принадлежности реализовывалась несколькими группами методов. Во-первых, использовались расстояния в метрических пространствах, где решение формировалось по принципу минимизации меры близости. В качестве метрик рассматривались евклидова, Чебышёва, а также метрика

Минковского третьего порядка с возможностью изменения параметра степени. Во-вторых, применялся статистический критерий, основанный на величине расхождения по Кульбаку—Лейблеру. Дополнительно принадлежность определялась по максимуму нормированной кросс-корреляционной функции. Наконец, в качестве альтернативного механизма использовалась нейросетевая модель – многослойная сеть прямого распространения, формирующая векторный выходной отклик (рис. 3.5).

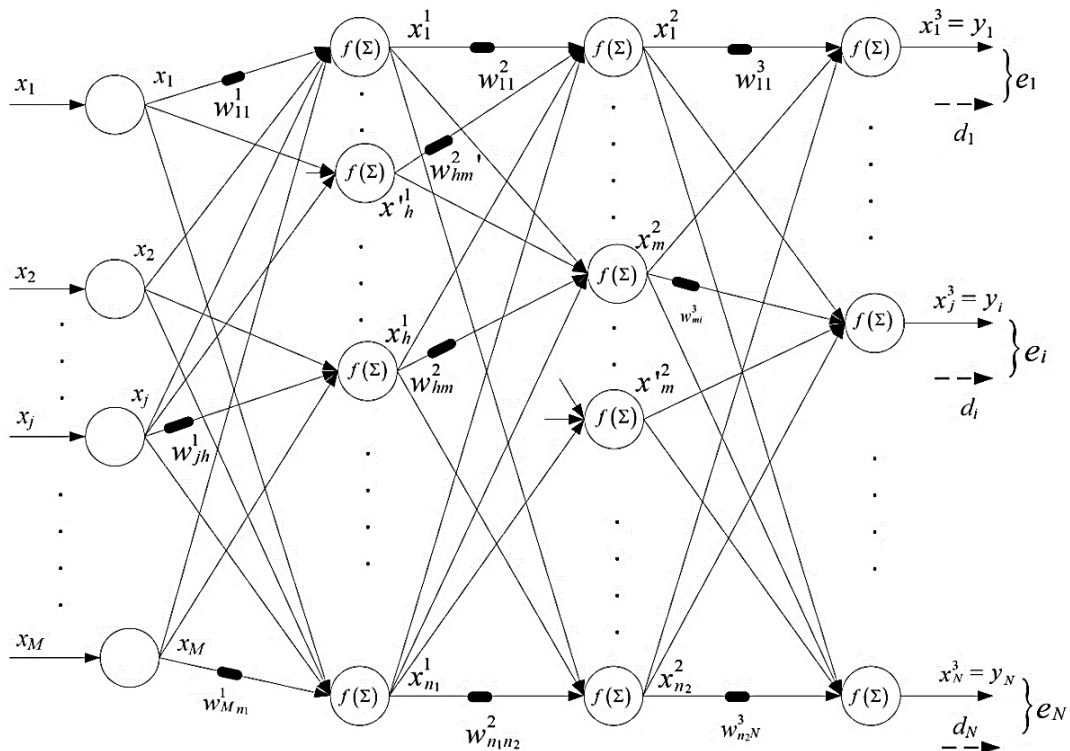


Рисунок 3.5 – Типовая MLP НС для комплексирования результатов классификации подписи с другими обнаружителями

Использование нейросетевой модели для выявления и последующей интерпретации участка многомерной траектории, соответствующей рассматриваемому пользователю, целесообразно формализовать в рамках классической архитектуры многослойного персептрона:

$$y_j = f_j^{[3]} \left(\sum_{m=1}^{n_2} w_{mj}^{[3]} \left(f_m^{[2]} \left(\sum_{h=1}^{m_1} w_{hm}^{[2]} \left(f_h^{[1]} \left(\sum_{i=1}^n w_{ih}^{[1]} x_i \right) \right) \right) \right) \right), \quad (3.33)$$

Функция f – в этом случае выступает передаточной (активационной) функцией нейронов MLP -классификатора. Если два различаемых фрагмента в N -мерном признаковом пространстве представить точками X и A , то расстояние между ними в евклидовой метрике задаётся выражением

$$l_2(X, A) = \sqrt{(x_1 - a_1)^2 + (x_2 - a_2)^2 + \dots + (x_n - a_n)^2} = \sqrt{\sum_{i=1}^N (x_i - a_i)^2}. \quad (3.34)$$

Если использовать квадрат евклидова расстояния, то при классификации более удалённые друг от друга объекты получают больший вес по сравнению с ближайшими.

В рамках метрики Минковского $l_v^{\mu}(X, A) = \left(\sum_{j=1}^N |x_j - a_j|^v \right)^{\frac{\mu}{v}}$, при $v \rightarrow \infty$ она переходит в расстояние Чебышёва: $l_{\infty} = \max_{1 \leq j \leq N} |x_j - a_j|$, то есть определяется максимальным отклонением по одной из координат.

Например, для точек $A(x_1, y_1, z_1) = A(2, 3, 4)$ и $X(x_2, y_2, z_2) = X(5, 9, 11)$, получаем:

$$l_{\infty}(X, A) = \max \{ |x_2 - x_1|, |y_2 - y_1|, |z_2 - z_1| \} = \max \{ |2 - 5|, |3 - 9|, |4 - 11| \} = \max \{ 3, 6, 7 \} = 7.$$

Для оценки степени линейной зависимости между двумя кривыми X и A используется коэффициент корреляции

$$r_{xa} = \frac{\mu_{xa}}{\sigma_x \sigma_a}, \quad (3.35)$$

При наличии k наблюдений в каждом фрагменте ковариация для парных выборок X и A вычисляется по формуле:

$$\mu(X, A) = \frac{1}{k} \sum_{i=1}^k (x_i - \bar{x})(a_i - \bar{a}). \quad (3.36)$$

В качестве нормированной корреляционной функции использовались выражения:

$$p_I(t_1, t_2) = \frac{K_I(t_1, t_2)}{\sigma_I(t_1)\sigma_J(t_2)} \text{ или } p_I(t_1, t_2) = \frac{K_I(t_1, t_2)}{\sqrt{K_I(t_1, t_1)}\sqrt{K_J(t_2, t_2)}}, \quad (3.37)$$

Для сопоставления двух сигнатурных кривых оценка их сходства выполнялась посредством взаимной корреляции. Для двух рассматриваемых фрагментов – окна анализируемой последовательности x_t и a_{t+k} в зависимости от номера отсчета k вычислялась корреляционная характеристика (параметр сходства):

$$r_k = \frac{\sum_{t=1}^{n-k} X_t A_{t+k} - \sum_{t=1}^{n-k} A_t \sum_{t=1}^{n-k} X_{t+k} / (n-k)}{\sqrt{\left[\sum_{t=k}^{n-k} A_t^2 - \sum_{t=k}^{n-k} A_t^2 / (n-k) \right] \left[\sum_{t=k+1}^n X_t^2 - \sum_{t=k+1}^n X_t^2 / (n-k) \right]}}. \quad (3.38)$$

Положение, соответствующее максимуму выражения (3.38) рассматривалось как момент начала участка, содержащего целевую сигнатуру.

В непрерывной постановке дивергенция Кульбака–Лейблера задаётся интегральным выражением:

$$D_{KL}(P \parallel Q) = \int p(x) \ln(p(x)/q(x)) dx, \quad (3.30)$$

для дискретного случая используется суммирование по отсчётам:

$$D_{KL}(P \parallel Q) = \sum_{i=1}^n P_i \ln(P_i/Q_i), \quad (3.40)$$

Достоверность комплексной классификации типа динамической сигнатуры подписи можно трактовать как вероятность корректного вывода о принадлежности классифицируемой ситуации к определённому классу по результатам наблюдений. Наиболее простой способ её оценки основан на подсчёте числа верных решений:

$$D = \frac{N_1}{N}, \quad (3.41)$$

где N_1 - количества правильных ответов, N – общее число решений, выданных системой классификации ситуаций.

Величину ошибки можно характеризовать следующими вероятностями:

$$P(r_j / s_i), P(s_i / r_j), P(s_i r_j). \quad (3.42)$$

Аналогичным образом вводятся и показатели достоверности: априорная $P(r_i / s_i)$, апостериорную $P(s_i / r_i)$ и безусловную $P(s_i r_i)$ достоверности.

Апостериорные характеристики качества – ошибки и показатели достоверности – задаются через вероятности состояний при фиксированном (наблюдаемом) результате распознавания. Принятая система обозначений для ошибок и достоверностей при произвольном числе различаемых состояний представлена на рис. 3.6.

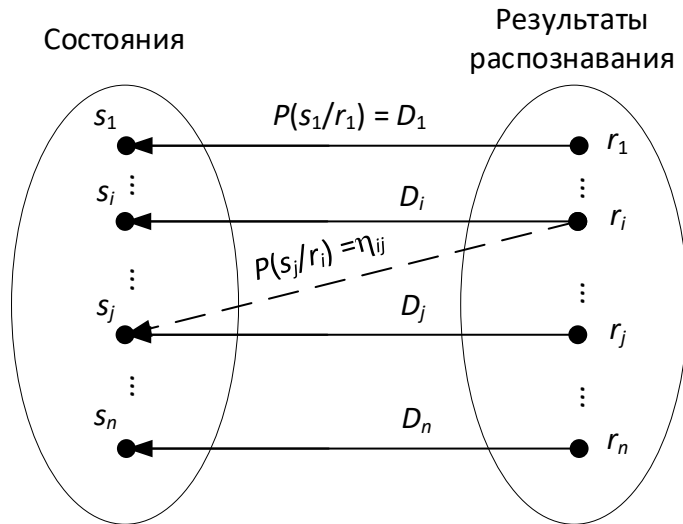


Рисунок 3.6 – Диаграмма отражения состояний ситуации с апостериорными ошибками и достоверностями

Достоверность распознавания в условиях ошибок, обусловленных недостаточной полнотой алфавита классов ситуаций, задаётся соотношением

$$D = \frac{P}{P + Q(1 - H)} = \frac{P}{1 - QH}, \quad (3.43)$$

где Q – вероятность появления нераспознанной ситуации, H – вероятностный показатель глубины распознавания, P – вероятность распознавания.

Обобщённая схема алгоритма комплексной классификации представлена на рис. 3.7.

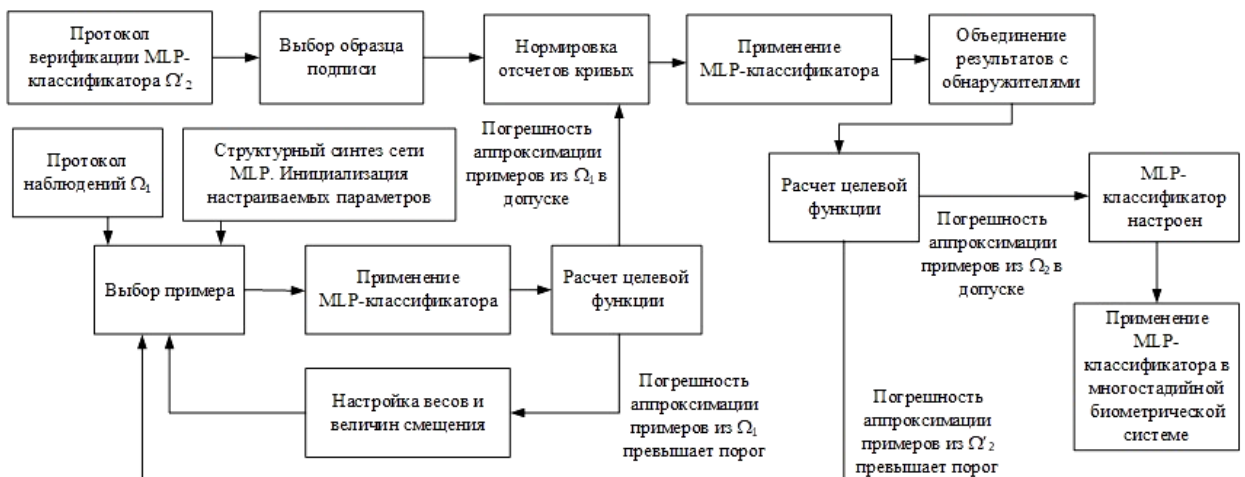


Рисунок 3.7 – Обобщенная схема алгоритма комплексной классификации

3.6. Выводы по третьей главе

В результате проведенных исследований в рамках разработки методики и алгоритмического обеспечения анализа, сопоставления и классификации многомерных кривых динамической подписи:

1. Осуществлена постановка задач анализа и классификации динамической сигнатуры подписи на основе функционального подхода и многоточечного представления статистических характеристик семейства кривых. В качестве исходных данных для синтеза таких эталонов используются открытые БД, содержащие до десятка параметров динамической реализации подписи, зарегистрированной в различных условиях. Эталон представляет собой многомерную (по числу параметров) кривую как результат кластеризации множества реализаций динамической подписи в рамках одного класса (эталона).

2. Описаны процедуры структурного синтеза нейросетевых архитектур для анализа, сопоставления и классификации по динамической подписи в двух представлениях, в пространстве отсчетов многомерных кривых и в пространстве вторичных признаков. Алгоритм определения принадлежности реализации подписи к классу (эталону), основанный на теореме разделения, обеспечивает практическую реализуемость программно-аппаратных средств с заданным значением метрики качества. Для классификации в пространстве временных отсчетов наилучшей показала себя многослойная нейронная сеть (*BProp/MLP*). Во втором варианте используются заранее вычисленные статистические и спектральные признаки многомерных кривых, подаваемые на вход классифицирующей многослойной НС.

3. Усовершенствована методика классификации динамической сигнатуры подписи в пространстве многоточечного представления статистических характеристик семейства кривых. Каждая точка представляет собой значение статистической или иной характеристики каждой кривой; таким образом, число точек соответствует числу кривых динамической подписи, а размерность пространства вложения – числу статистических характеристик, вычисляемых по каждой кривой. Особенностью разработанного алгоритма методики является высокая устойчивость к искажениям статистических характеристик параметров динамической подписи при внутриклассовой вариативности реализаций.

4. Разработан алгоритм комплексного анализа и классификации динамической сигнатуры подписи в пространстве отсчетов многомерных кривых. Подразумевается параллельная обработка многомерного фрагмента кривой различными классификаторами (детекторами) с последующим объединением полученных результатов.

Разработанные методики и алгоритмы исследуются по метрикам качества в четвертой главе в рамках разрабатываемых элементов исследовательского программного комплекса.

4. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТАЛЬНЫХ ИССЛЕДОВАНИЙ И ПРЕДЛОЖЕНИЯ ПО ПРАКТИЧЕСКОЙ РЕАЛИЗАЦИИ РАЗРАБОТАННЫХ МЕТОДОВ

4.1. Программные реализации макета программного комплекса моделирования, эталонирования, сопоставления и классификации динамической сигнатуры подписи

В качестве базовой технологической платформы для реализации разработанных методов и алгоритмов анализа, сопоставления и классификации динамической сигнатуры подписи были выбраны *MATLAB* (как система математических вычислений) и среда разработки *C++*.

Использование *MATLAB* связано со следующими особенностями:

1. Вычислительное ядро *MATLAB* ориентировано на матричные операции, поэтому эффективно выполняет трудоёмкие численные расчёты для сигнатур, представимых как многомерные временные ряды. Возможность быстро обрабатывать большие массивы данных и решать сложные математические задачи делает *MATLAB* удобным инструментом численного моделирования.

2. *MATLAB* располагает развитым набором встроенных функций и специализированных пакетов, охватывающих широкий круг задач, включая обработку многомерных сигналов, машинное обучение, а также матричные и комбинаторные операции.

При этом для вычислительно-нагруженных процедур – например, поэлементной обработки отсчётов временных рядов параметров динамической подписи – более высокую производительность обеспечивают языки уровня *C/C++* при использовании профильных библиотек. Поэтому для части задач в рамках разработки алгоритмов анализа, сопоставления и классификации многомерной динамической

сигнатуры применялась среда C++, обеспечивающая чтение данных, их обработку и требуемую визуализацию для файлов.

В основе исследовательской базы данных и доказательной фактуры настоящих исследований лежит база данных *MOBISIG*, представляющая собой набор динамических подписей 83 пользователей (49 мужчин, 34 женщины), полученные с помощью мобильного устройства с емкостным сенсорным экраном (планшет *Nexus 9*, *Android 6.0*) [63]. Данные каждого пользователя содержат 45 истинных и 20 поддельных реализаций его подписи, каждая из которых представлена в формате файла «*.csv» (рис. 4.1).



Рисунок 4.1 – Исходное файловое представление динамической подписи

Общая структура макета программного комплекса моделирования процессов эталонирования и классификации реализаций динамической подписи пользователя иллюстрирована на рис. 4.2.




Рисунок 4.2 - Общая структура макета программного комплекса

Специальное программное обеспечения моделирования эталонирования многомерного представления динамической подписи каждого пользователя основано на программной реализации (C++) НС Кохонена (слоя Кохонена) и использует одноточечное представление

эталона в пространстве статистических реализаций кривых, описанных в главе 3 настоящего исследования. Функциональная схема использования СПО эталонирования и классификации иллюстрирован на рис. 4.3.

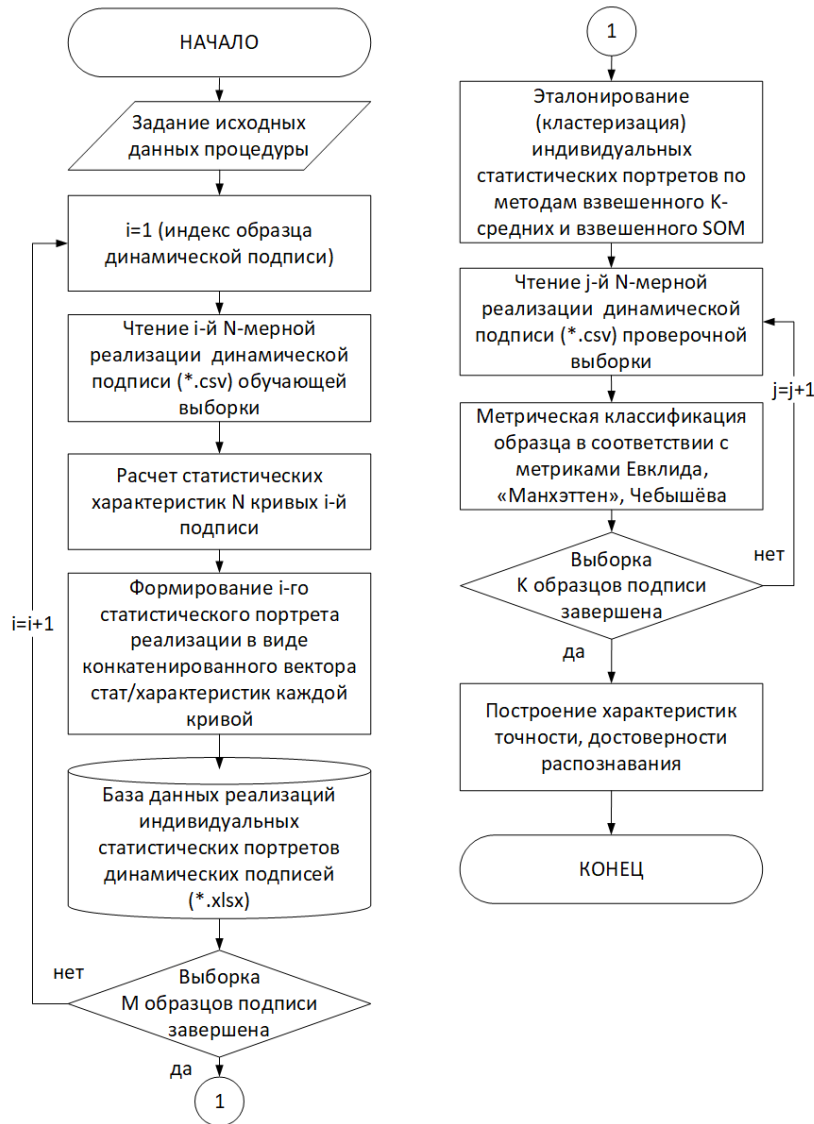
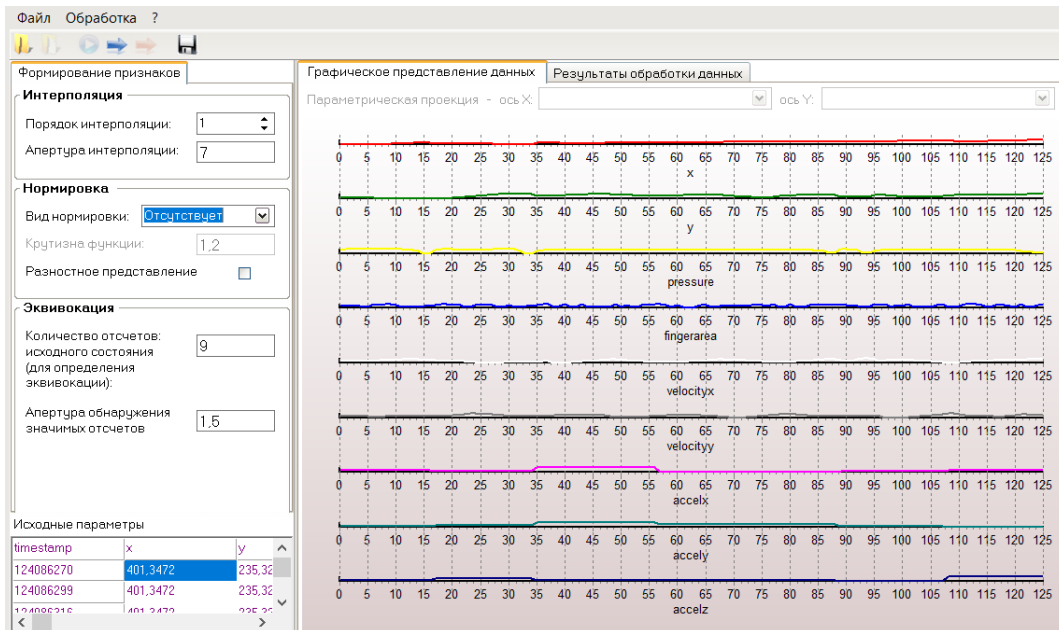
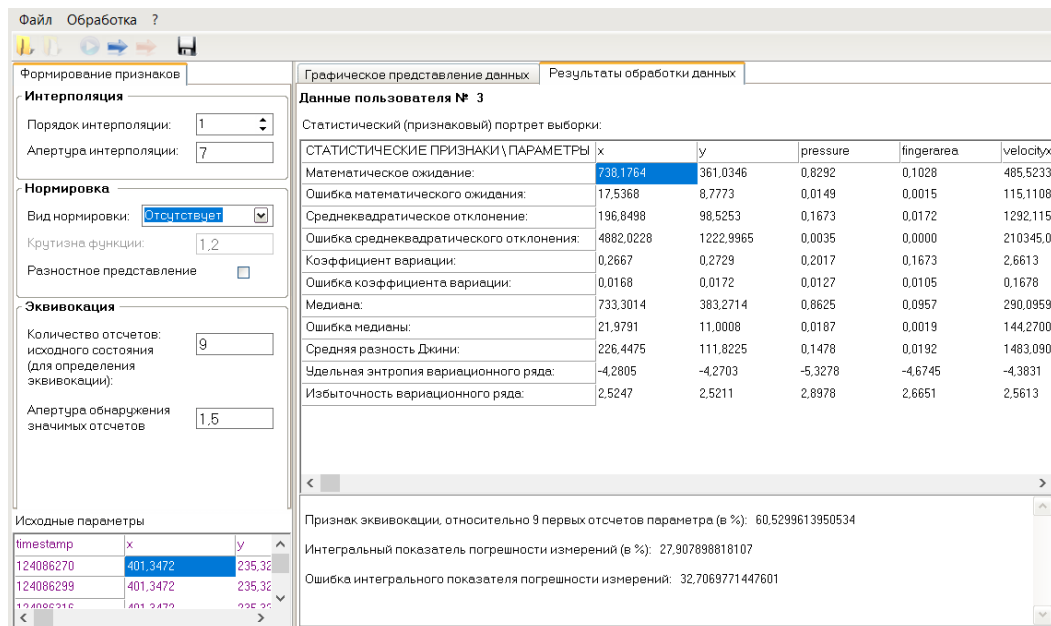


Рисунок 4.3 - Функциональная схема СПО эталонирования и классификации (C++) многомерных кривых динамической подписи (N – число кривых в динамической подписи, M – число обучающих реализаций, K - проверочных)

Интерфейс окон программы в режимах чтения многомерных кривых подписи и расчета их статистических характеристик показан на рис. 4.4.



a)



b)

Рисунок 4.4 – Визуализация расчетов индивидуального статистического портрета каждой реализации динамической подписи: *a)* в графическом виде, *b)* в текстовом

В ходе метрической авто-классификации, т.е., когда моделируется распознавание образца подписи в автоматическом режиме, рассчитывается параметр достоверности каждого акта классификации (рис. 4.5). Так как параметр представляет собой расстояние от образца до эталона в

нормированном пространстве обучающей выборки, то на образцах проверочной выборки и новой нормировки он может превышать единицу.

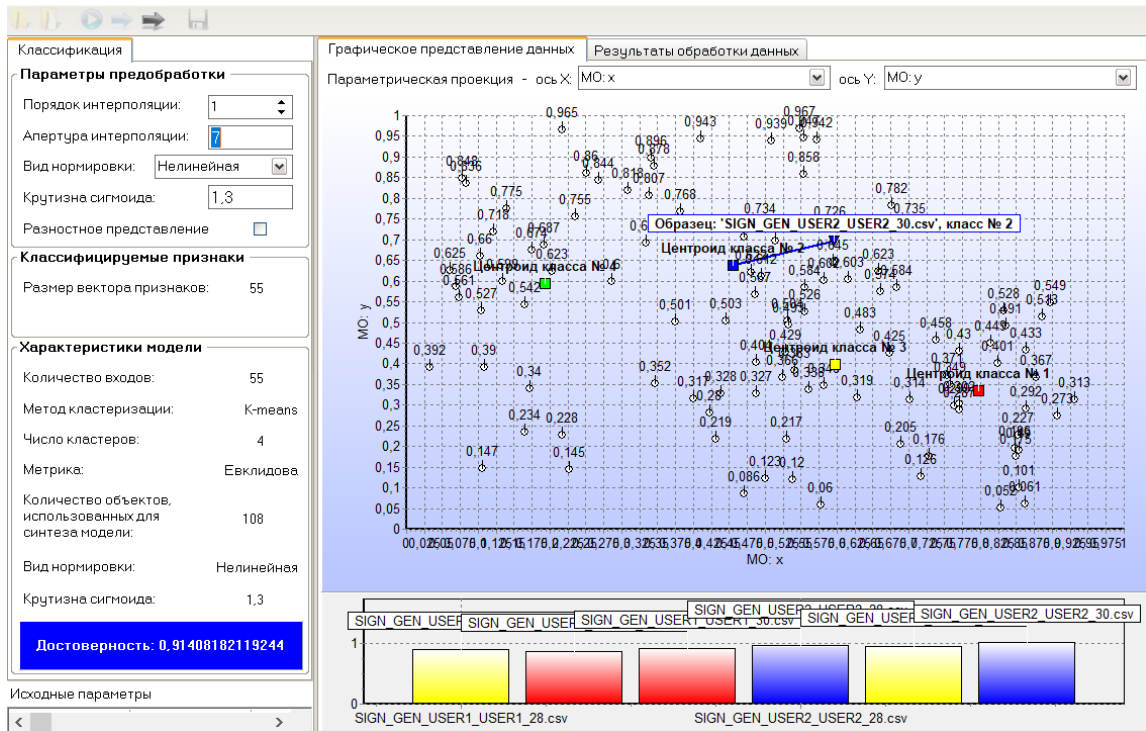


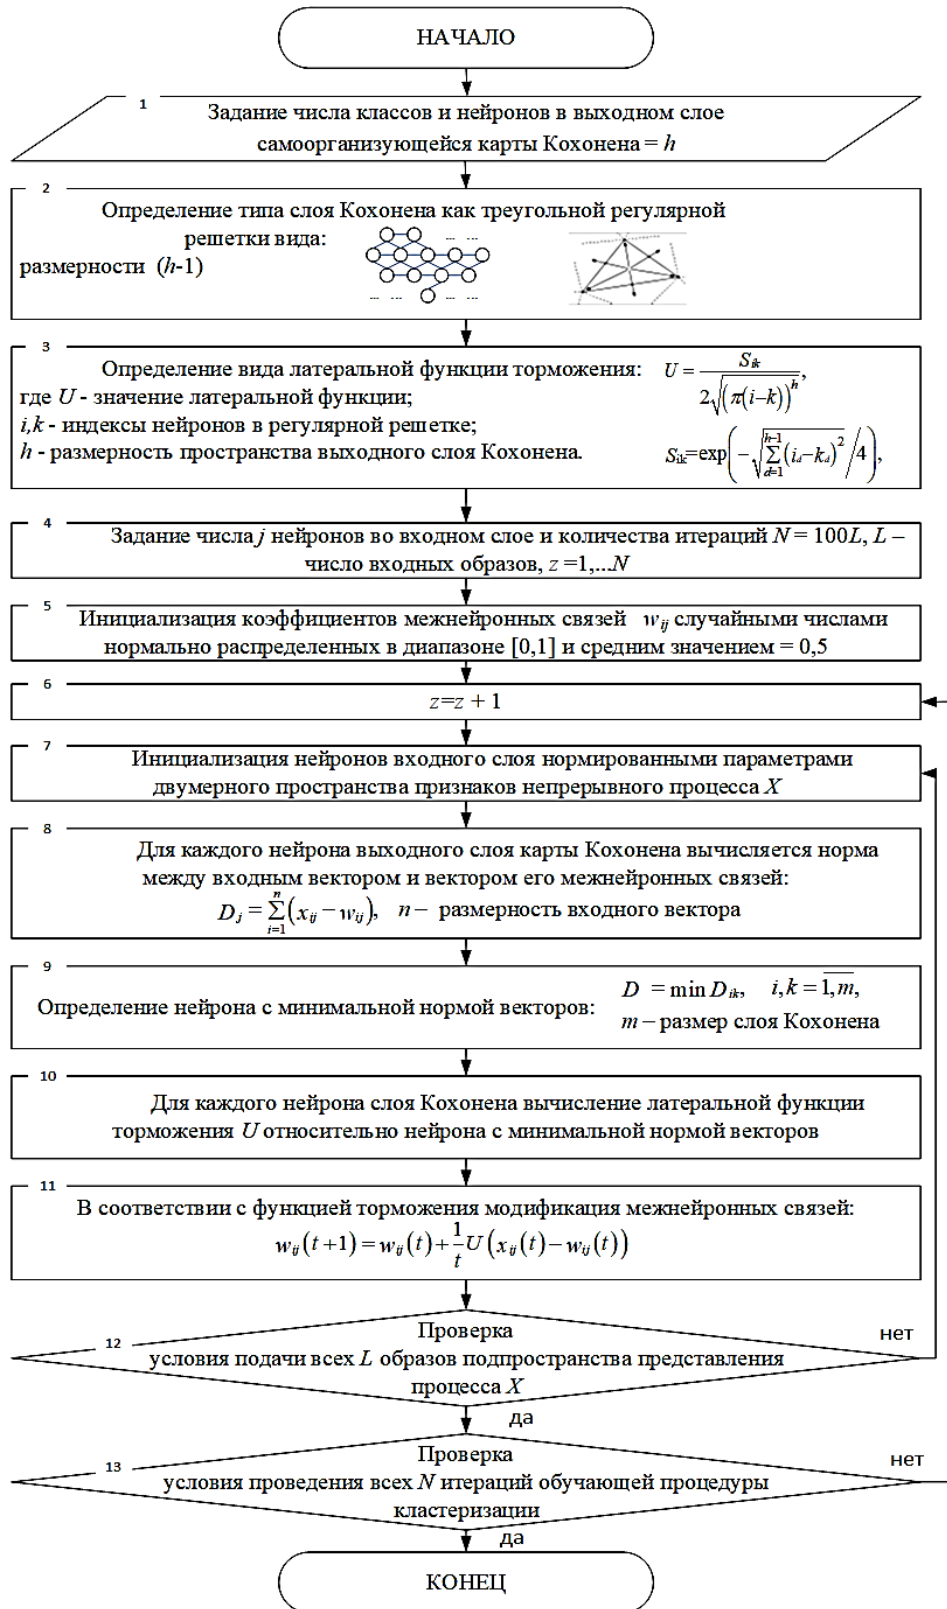
Рисунок 4.5 – Интерфейс СПО (C++) моделирования процессов эталонирования и классификации в режиме автоматической классификации

Особенность реализации СПО заключается в возможности исследовать структуру кластеров динамической подписи в L -мерном пространстве:

$$L = N \cdot R, \quad (4.1)$$

где N - число кривых в динамической подписи, R – число статистических характеристик, используемых, для представления каждой кривой подписи.

Алгоритм эталонирования на основе НС Кохонена приведен на рис. 4.6.

Рисунок 4.6 – Алгоритм эталонирования на основе НС Кохонена (*SOM*)

Специальное программное обеспечение комплексного анализа и классификации динамической сигнатуры подписи в пространстве отсчетов многомерных кривых (*MATLAB*) состоит из нескольких сценариев,

запускаемых на исполнение в заданной последовательности. Функциональная структура СПО (MATLAB) представлена на рис. 4.7.

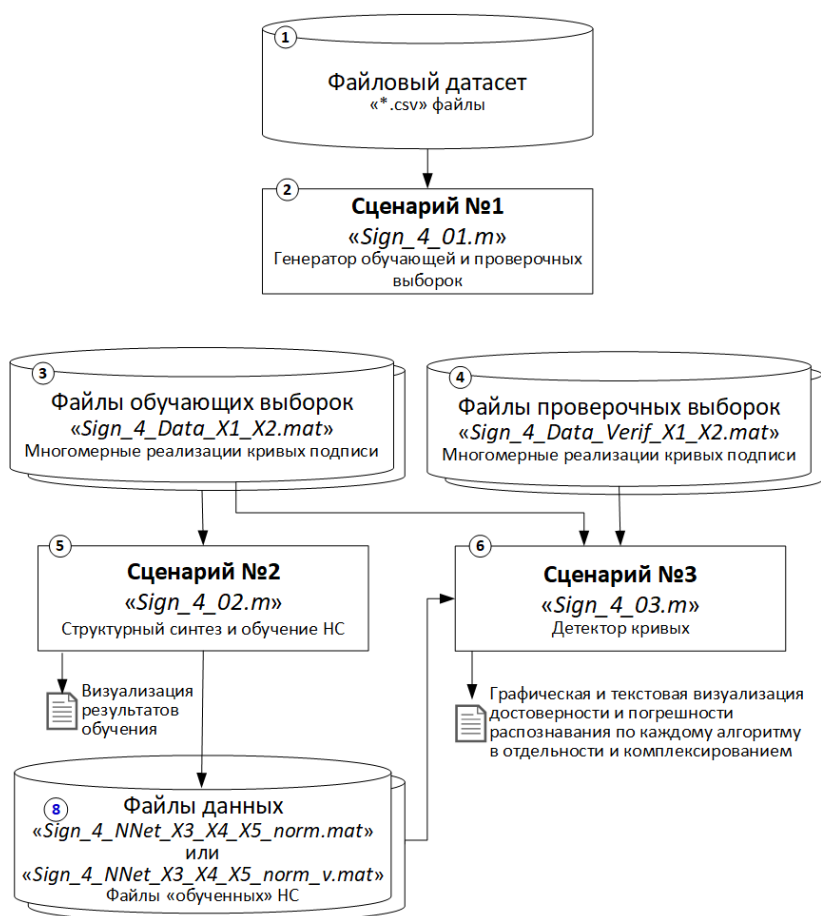


Рисунок 4.7 – Взаимосвязь исполняемых сценариев комплексного анализа и классификации динамической сигнатуры подписи

К ключевым особенностям алгоритмов анализа и классификации относится масштабируемость признакового пространства, то есть возможность привлекать произвольное (фактически не ограниченное сверху) число плоских кривых для сопоставления и отнесения реализации подписи к соответствующему классу (эталону).

Такой анализ выполняется для выбора оптимальных характеристик средств анализа и классификации, направленных на повышение эффективности обработки данных динамической подписи.

Нейросетевые алгоритмы классификации основаны на двух сетях – со скалярной и с векторной функцией выхода (рис. 4.8).




Рисунок 4.8 – Архитектуры НС вида MLP для классификации многомерной реализации динамической подписи

Алгоритм синтеза и применения НС иллюстрирован на рис. 4.9-4.10.

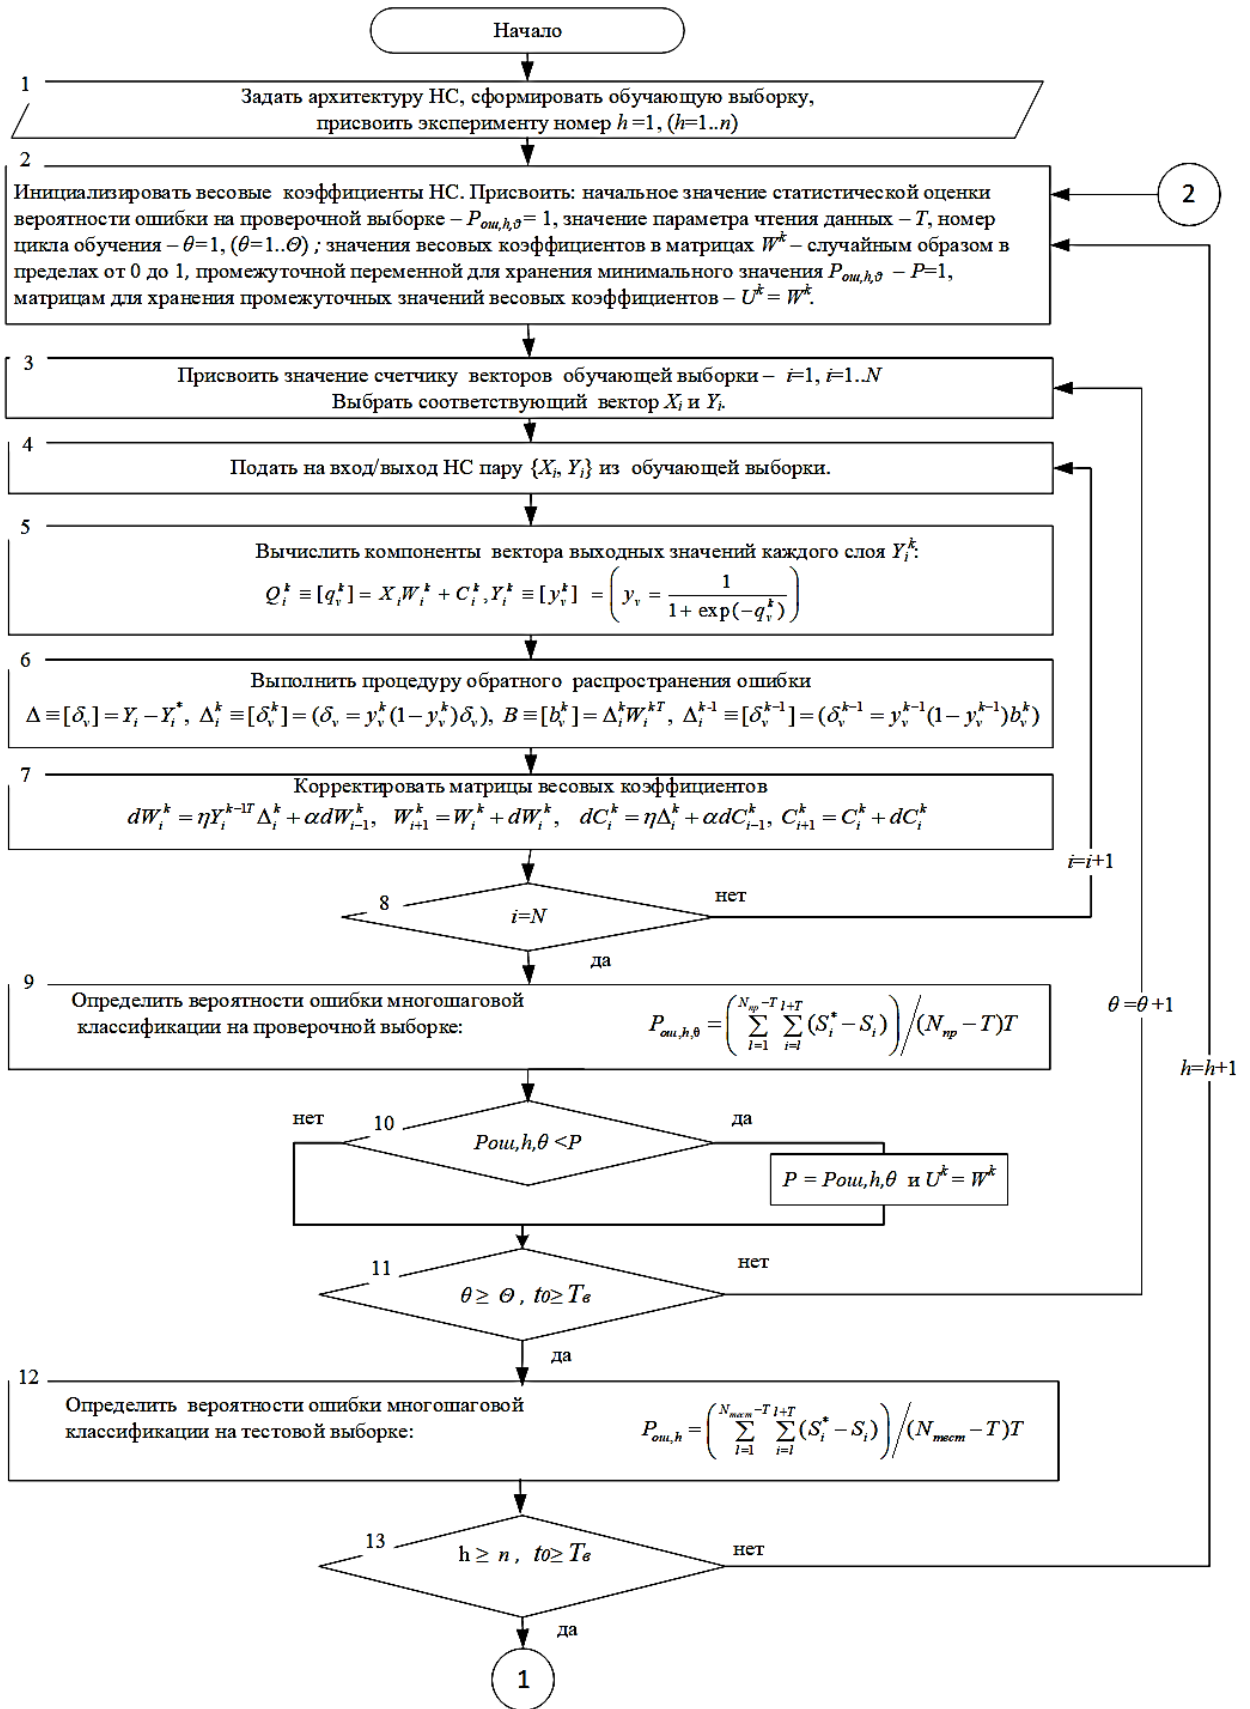


Рисунок 4.9 – Алгоритм синтеза и применения НС MLP (начало)

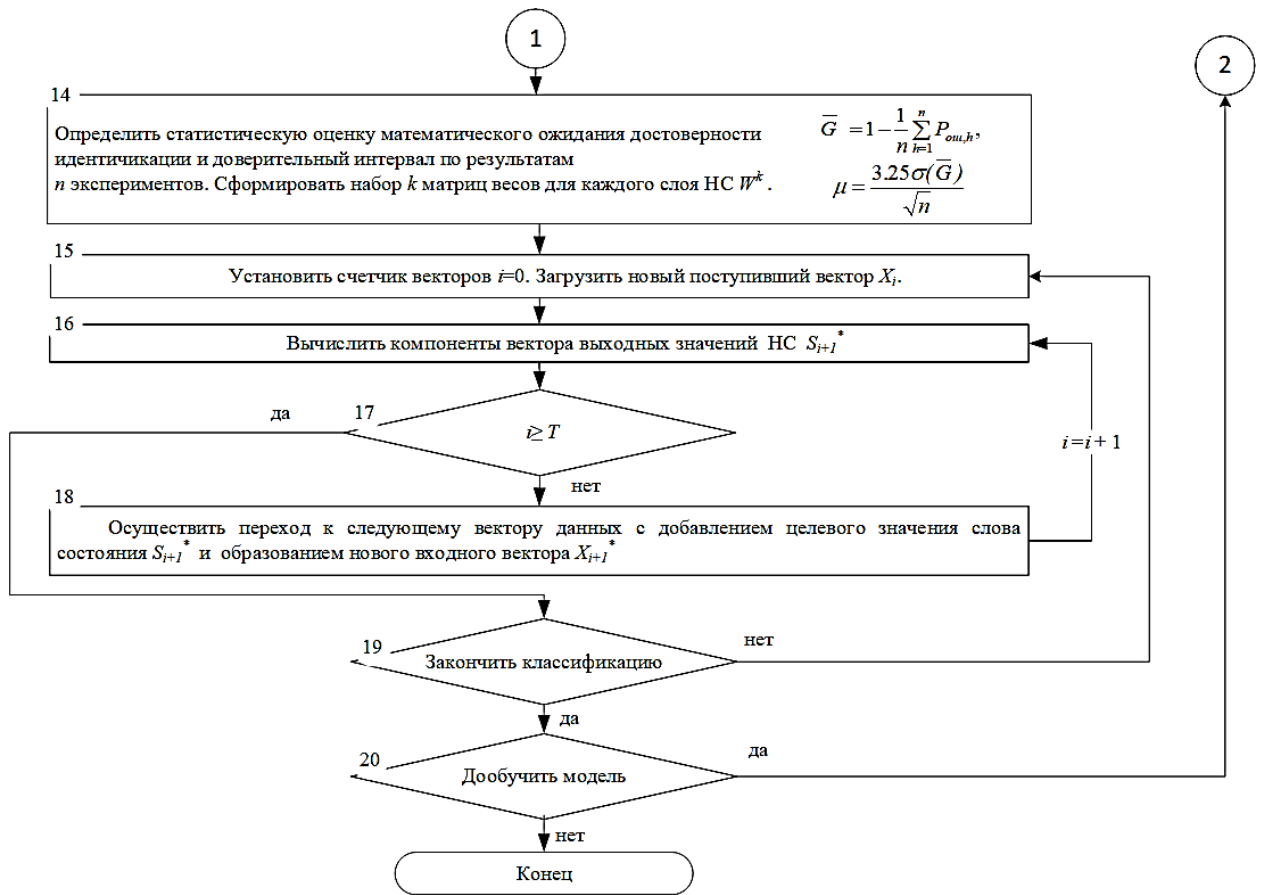


Рисунок 4.10 – Алгоритм синтеза и применения НС *MLP* (окончание)

По результатам обучения формируются графики сходимости, а также визуализируются кривые подписей, использованные как входные векторы (рис. 4.11).



Рисунок 4.11 - кривые подписей, использованные как входные векторы НС

Выходные результаты сценария №3 отображаются в рабочей области *MATLAB* и дополнительно представляются в виде графиков в отдельном окне (рис. 4.12).

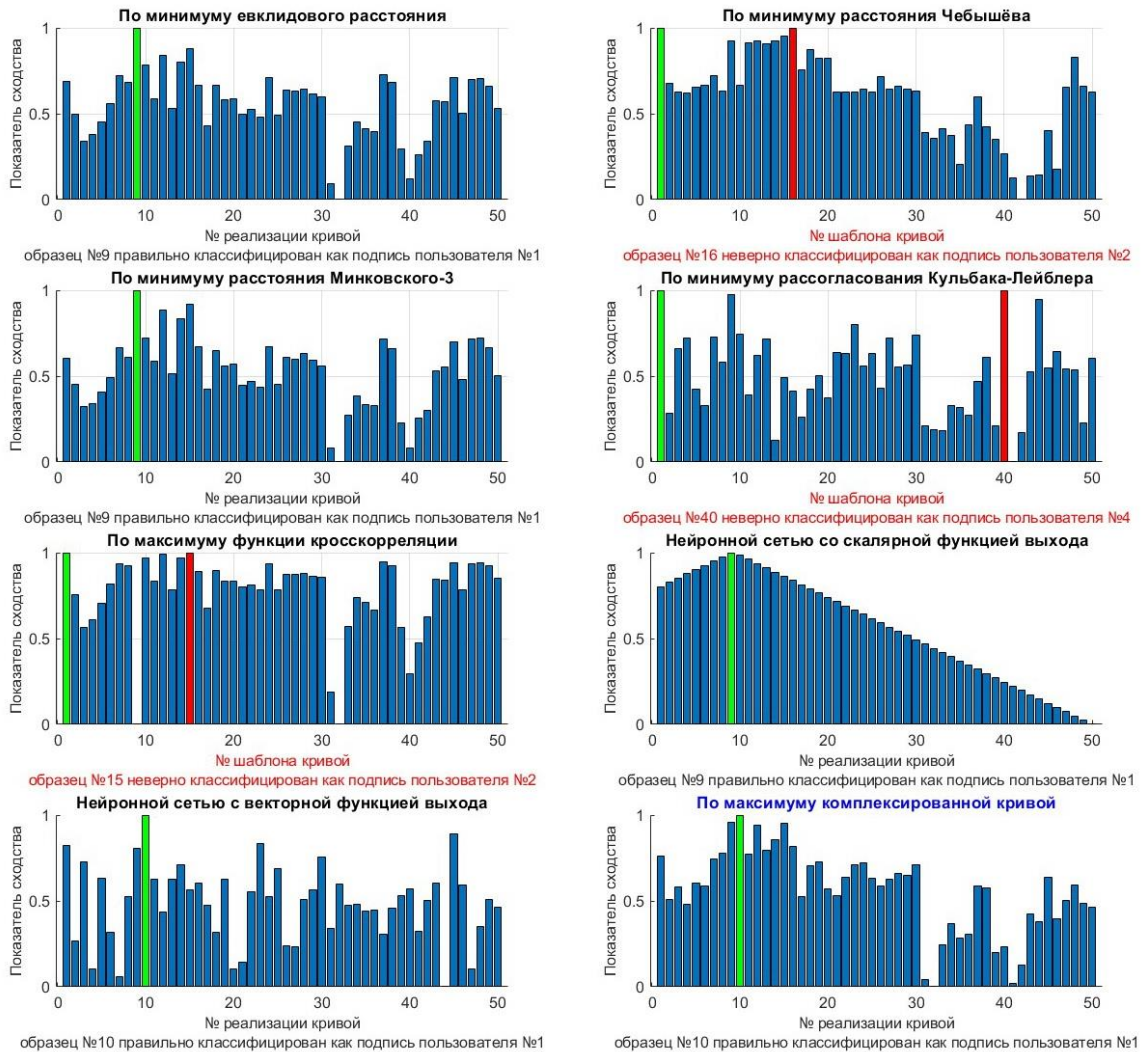


Рисунок 4.12 – Пример графического представления результатов классификации одного образца динамической подписи СПО (*MATLAB*)

4.2. Экспериментальное сравнение нейросетевых алгоритмов классификации динамической подписи в пространстве отсчетов многомерных кривых с базовыми алгоритмами сопоставления многомерных сигналов

Экспериментальные исследования подчинены цели исследований – повышение качества сопоставления и классификации реализаций динамической подписи на основе экстраполяции дополнительных параметров и нейросетевых методов эталонирования и классификации относительно классических схем обнаружения и оценивания сигналов, а также получение сведений о целесообразности реализации разработанных методов и алгоритмов нейросетевого анализа сигнатур динамических параметров подписи в комплексах технических средств современных систем регистрации и обработки динамической подписи.

При проведении эксперимента количество скрытых слоев нейросети варьировалось от 1 до 4 функцией активации являлся гиперболический тангенс, а количество отсчетов подписи не превышало 260.

$$f^{[s]}(x) = \frac{e^{\alpha^{[s]}x} - e^{-\alpha^{[s]}x}}{e^{\alpha^{[s]}x} + e^{-\alpha^{[s]}x}}, \quad (4.2)$$

Коррекция весовых коэффициентов выполнялась по алгоритму обучения Левенберга–Марквардта:

$$w_j(k+1) = w_j(k) + (J_j(k)J_j^T(k) + \chi I)^{-1} J_j(k)(d_j(k) - f(w_j^T(k)x(k))), \quad (4.3)$$

Зависимости показателя достоверности от параметров процедуры классификации оценивались частотным методом. В каждой точке графиков выполнялось не менее 30 испытаний. Достоверность классификации вычислялась по частотной оценке:

$$D = M/N, \quad (4.4)$$

где M - число успешных опытов по классификации пользователя, N – общее число опытов.

На рис. 4.13 приведены зависимости достоверности классификации пользователя от числа кривых его динамической сигнатуры, используемых

при распознавании, полученные путём усреднения по 30 точкам и по результатам шести алгоритмов. При построении каждой точки графика из общего набора в 50 пользователей усреднялись показатели распознавания для 10 пользователей из протокола испытаний (проверочной выборки), при этом для каждого пользователя учитывалось по 20 реализаций подписи.

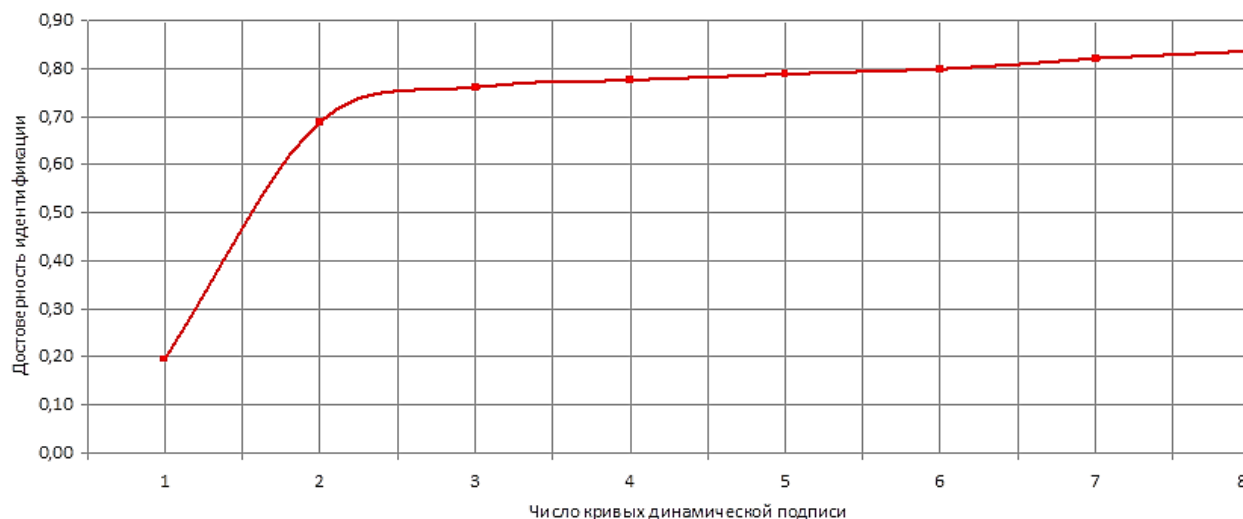


Рисунок 4.13 – Зависимость достоверности классификации от числа кривых динамической подписи

Полученная зависимость показывает, что использование 3–5 базовых параметров – координат x и y в плоскости планшета, давления на экран, а также компонент скорости пера по x и y – уже обеспечивает приемлемый уровень достоверности классификации. Дальнейшее увеличение числа учитываемых кривых приводит лишь к небольшому приросту достоверности, однако заметно повышает вычислительную ресурсоёмкость, поскольку алгоритм Левенберга–Марквардта требует формирования матрицы Якоби J :

$$(H + \alpha I)\delta = J^T E, \quad (4.5)$$

$$\text{где } J = \begin{bmatrix} \frac{\partial F(x_1, w)}{\partial w_1} & \dots & \frac{\partial F(x_1, w)}{\partial w_M} \\ \dots & \dots & \dots \\ \frac{\partial F(x_N, w)}{\partial w_1} & \dots & \frac{\partial F(x_N, w)}{\partial w_M} \end{bmatrix}, F(x_i, w) - \text{значение выхода НС}$$

на i -й входной вектор X [81, 82, 83].

Достоверность существенно зависит от вида параметров, используемых в перечне кривых динамической подписи. Эксперименты для пяти кривых показали максимум достоверности на следующем составе:

- 1) x – проекция текущего положения пера на ось x ;
- 2) y – проекция текущего положения пера на ось y ;
- 3) *pressure* – текущая сила давления пера на экран;
- 4) *velocity_x* – проекция вектора скорости пера на ось x ;
- 5) *velocity_y* – проекция вектора скорости пера на ось y .

Дальнейшие эксперименты реализовывались с данным набором параметров.

На рис. 4.14 показана усреднённая зависимость достоверности классификации кривой (а следовательно, и пользователя) от объёма обучающей выборки и числа пользователей. В эксперименте были зафиксированы следующие условия:

- число алгоритмов, участвующих в комплексировании, – 3 (метрический метод в евклидовой метрике, кросскорреляционный метод и НС со скалярной функцией выхода);

- число используемых кривых динамической подписи – 5 (x , y , p , v_x , v_y);

Полученные зависимости указывают на монотонный рост достоверности классификации при увеличении количества образцов подписи на каждого пользователя и одновременном уменьшении числа пользователей. Такой эффект естественно интерпретируется через

сокращение числа областей классов и изменение их представительности (в геометрическом смысле) в фиксированном признаковом пространстве, что повышает вероятность корректного отнесения предъявляемых образцов подписи к соответствующим классам.




Рисунок 4.14 – Изменение достоверности классификации динамической подписи в зависимости от кол-ва эталонов и групп пользователей

Анализ зависимостей, представленных на рис. 4.14, позволяет сделать вывод, что для достижения требуемых показателей надёжности классификации пользователя целесообразно выполнять декомпозицию аппаратно-программных моделей распознавания динамической подписи на группы, содержащие сравнительно небольшое число пользователей.

Применение метода эталонирования множества реализаций подписи одного пользователя позволяет сравнить разработанные нейросетевые алгоритмы с алгоритмами статистического оценивания, применяемые в цифровой обработке многомерных сигналов.

На рис. 4.15 приведены изменения достоверности классификации динамической подписи пользователя от числа пользователей при фиксированных объёмах обучающей и проверочной выборок.




Рисунок 4.15 – Изменение достоверности классификации динамической подписи в зависимости от их числа

Визуальный анализ рис. 4.15 показывает преимущество НС с векторной функцией выхода по сравнению с остальными применёнными алгоритмами.

На рис. 4. 16 представлены оценки ошибок ложного допуска – *FAR* (*False Acceptance Rate*) и ложного отказа – *FRR* (*False Rejection Rate*) для разработанной модели. Результаты тестирования, показанные на графике, демонстрируют, что разработанные методы эффективно снижает значения *FAR* и *FRR* при разных уровнях чувствительности. При чувствительности 0,1 показатель *FAR* составляет 0,08%, что подтверждает минимизацию ложных допусков в рамках заданного порога. Одновременно, *FRR* при данной чувствительности равен 0,12%, что свидетельствует о низком уровне ложных отказов. Показатель *EER* для данной модели достигает 0,9% при чувствительности ниже 0,1, что указывает на оптимальное сочетание точности и надежности системы. Эти результаты подтверждают эффективность предложенных методов и моделей для задач классификации, обеспечивая сбалансированное соотношение между ошибками первого и второго рода при минимальных значениях *EER*




Рисунок 4.16 - Оценка доли ошибок ложного допуска и ложного отказа для разработанной модели

Следует заметить, что вид зависимостей, также обусловлен представительностью исходного датасета, в частности *MOBISIG*, и для других данных наклон кривых может быть другим.

Ограничением алгоритма, использующего НС с векторной функцией выхода, является непредсказуемый характер роста вычислительной сложности обучения при применении алгоритма. Это, в свою очередь, подтверждает целесообразность децентрализации систем регистрации и обработки подписей пользователей на основе данных кривых динамической подписи.

4.3. Предложения по организации хранения эталонных представлений динамической подписи на основе специализированных баз данных временных рядов и уникальных матриц синаптических коэффициентов межнейронных связей

Особенностями данных динамической подписи множества пользователей являются:

1. Представление одной реализации в едином формате многомерного временного ряда $[m, n]$, где m – число параметров динамической подписи, порядка единиц - десятков, n – число отсчетов многомерного временного ряда.

2. Относительно небольшое число отсчетов многомерного временного ряда каждой подписи, $n = 100, \dots, 300$, т.к. процесс постановки подписи характеризуется медленноменяющимися кинематическими параметрами движения пера.

3. Малое количество реализаций подписи каждого пользователя, порядка нескольких единиц изначально при регистрации в системе, при этом каждый акт классификации увеличивает обучающую выборку на одну реализацию. Обозначим данное измерение индексом k , и в пределе: $k \rightarrow \infty$.

4. Гигантской число v пользователей, которое охватывает целевой класс потребителей, в пределе: $v \rightarrow \infty$.

Для минимизации k -го измерения в настоящей работе использована процедура эталонирования, в результате одному пользователю будет соответствовать один или несколько эталонов его подписи.

Таким образом, хранилище биометрических данных в виде динамической подписи пользователей имеет топологию с четырьмя независимыми, ортогональными измерениями, т.е. в евклидовой метрике – гиперкуба размерностью $[m, n, k, v]$. Графически участок хранения данных одного пользователя может включать не только измерительные данные, но и фактографическую информацию о других биометрических характеристиках субъекта (рис. 4.17).

Множественность измерений естественным образом приводит к представлению данных в форме многомерной модели.

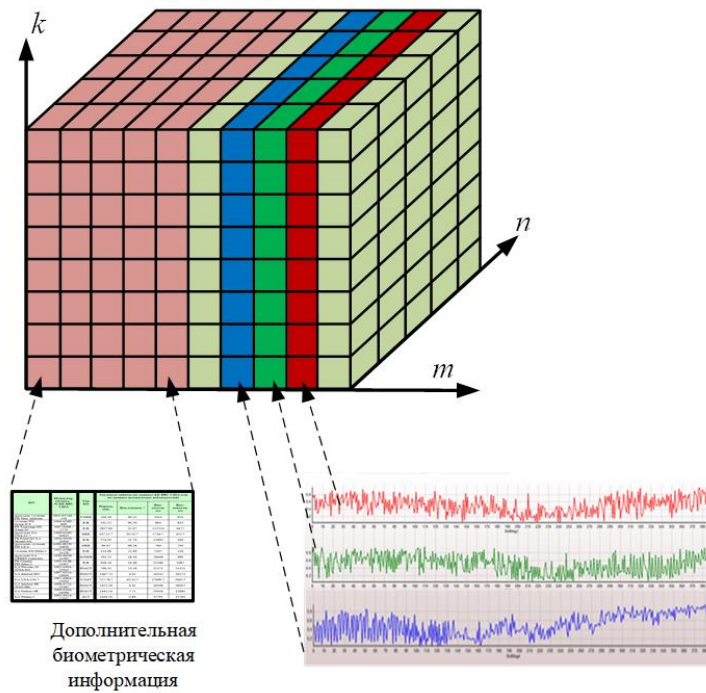


Рисунок 4.17 - Многомерная база данных хранилища эталонов динамической подписи (фрагмент одного пользователя)

Таким образом, задаётся множество измерений D , любая точка соответствующего пространства описывается набором (d_1, \dots, d_n) , где $d_i \in D$, и сопоставленным ей вектором мер (m_1, \dots, m_k) , $m_i \in M$, где M – множество мер.

Тогда многомерное пространство можно задать, с одной стороны, схемой R , атрибутами которой выступают измерения и меры, то есть $R = \langle D, M \rangle$, а с другой стороны множеством отношений r определённых над этой схемой R .

Иными словами, для любого $\forall A \in D$, существует проекция $r[A]$ такая, что для любого $\forall a \in r[A]$: выполняется $a \in \{ALL\}$, где $\{ALL\}$ задаёт полный набор допустимых значений соответствующего измерения. Само многомерное пространство может быть определено декартовым произведением

$$\text{Space}(r) = \{(r[A] \cup ALL) \cup \{0, \dots, 0\}\}.$$

Существенное достоинство подобной топологии базы данных состоит в том, что при поиске и извлечении информации из «куба» по измерениям можно выполнять типовые операции, прежде всего: сечение (срез), транспонирование, свёртку и детализацию.

Алгоритм распознавания пользователя, использующий нормированную функцию кросскорреляции, опирается на операцию свёртки где значения измерений заменяются более общими, иерархически вышестоящими значениями (рис. 4.18), вследствие чего увеличивается степень агрегирования и обобщённости представления данных.




Рисунок 4.18 – Процедура свертки

В качестве технической основы для хранения и обработки временных рядов могут применяться базы данных класса *TSDB* (*Time Series Database*) — специализированные хранилища, ориентированные на работу с данными, снабжёнными временными метками, и на эффективную обработку временных последовательностей.

4.4. Предложения по облику системы передачи данных и децентрализованной структуре центров обработки и анализа динамической подписи

Согласно обобщённой схеме функционирования систем регистрации и обработки динамической подписи, архитектура комплекса средств включает набор ключевых компонентов, представленных на рис. 4.19.

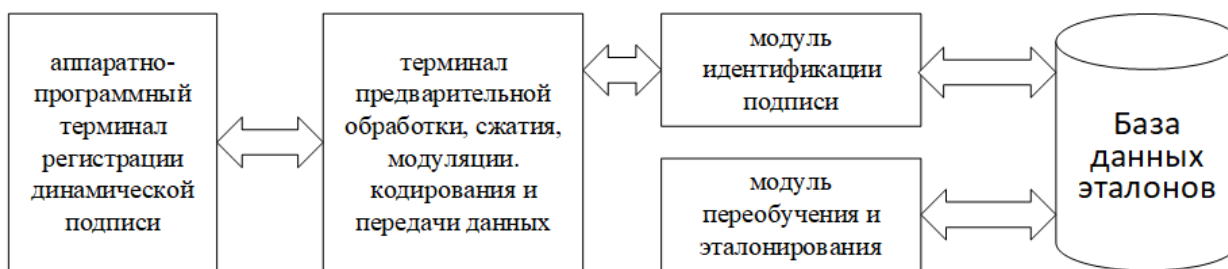


Рисунок 4.19 - Архитектура комплекса технических средств биометрической классификации

Как распределённая система, такой комплекс обязательно содержит терминал, обеспечивающий связь и передачу данных между точкой съёма подписи и центром её классификации. Как показано в п. 4.2, при накоплении образцов подписей большого числа пользователей в рамках одной различительной модели снижается достоверность классификации. Одним из практических способов устранения этого эффекта является декомпозиция вычислительных функций распознавания между несколькими территориально распределёнными центрами в рамках концепции *IoT*. В этом случае систему целесообразно строить по облачному принципу с использованием промежуточных *Fog*-узлов, выполняющих предварительную обработку и маршрутизацию данных.

В модели облачных сервисов обычно выделяют три уровня (рис. 4.20):

- 1) инфраструктурный уровень, предоставляющий ресурсы для биометрических приложений (*IaaS*);
- 2) платформенный уровень, обеспечивающий развёртывание и сопровождение таких приложений (*PaaS*);
- 3) уровень приложений/сервисов, через который пользователи получают доступ к функционалу (*SaaS*).



Рисунок 4.20 – Модель облачных служб

Одним из направлений снижения задержек рассматривается интеграция подходов «туман» и «облако» [84, 85]. Однако такая интеграция требует существенных физических и логических изменений. Для систем регистрации и обработки динамической подписи необходимо расширять слой виртуализации за пределы собственно «облака», включая в него «туман» [86–88].

4.5. Выводы по четвертой главе

В результате проведенных исследований в рамках четвертой главы решены следующие задачи:

1. Разработан программный макет комплекса моделирования и классификации динамической подписи. Реализация: *MATLAB* и *C++*. В качестве исследовательской базы использована *MOBISIG*. Архитектура включает в себя модуль моделирования эталонирования многомерного представления подписи на НС Кохонена (*C++*) с одноточечным эталоном в пространстве статистических реализаций кривых и модуль комплексного анализа и классификации в пространстве отсчетов многомерных кривых (*MATLAB*), выполненный как цепочка сценариев, запускаемых в заданной последовательности.

2. Экспериментально исследованы методы и алгоритмы нейросетевого анализа и классификации динамической сигнатуры подписи в пространстве отсчетов многомерных кривых в сравнении с оптимальными алгоритмами обнаружения-различения многомерных сигналов. Эксперименты показали преимущества НС с векторной функцией выхода над остальными алгоритмами. Средний выигрыш от применения разработанных методов и алгоритмов распознавания подписи по сравнению со статистическими методами составил 25 – 35%, по сравнению с известными метрическими методами с верностью от 5 до 15 %.

3. Предложена организация хранения биометрических эталонов динамической подписи как специализированного хранилища временных рядов и как послойного хранилища матриц синаптических весов нейросети. Данные подписи представлены в топологии четырёхмерного гиперкуба с ортогональными измерениями параметров, что обеспечивает непосредственный многомерный анализ в евклидовой метрике. Технической основой первого варианта выступают TSDB-системы. Во втором подходе предполагается послойное представление весов классифицирующей нейронной сети — со скалярной либо векторной функцией выхода – предварительно обученной различать v пользователей. Для организации такого хранилища целесообразно применять нереляционные СУБД, способные эффективно выполнять операции записи и выборки и масштабироваться при работе с высокоразмерными структурами признаков.

4. Предложен облик системы передачи данных и децентрализованной сети узлов обработки, сопоставления и классификации динамической подписи. Декомпозиция вычислительных функций между территориально распределёнными узлами в парадигмах *IoT*, облачных и туманных вычислений снижает сетевую нагрузку, задержки доставки сегментов временных рядов и риск потерь данных.

Архитектура строится по облачной модели с промежуточными *Fog*-узлами для предобработки и маршрутизации. Техническое ядро формируется аналитической моделью и гибридным алгоритмом обучения с подкреплением, ориентированным на работу с нечёткими данными и реализуемым на основе процедур нечёткой кластеризации.

ЗАКЛЮЧЕНИЕ

1. В ходе исследований проведен анализ существующих механизмов сопоставления и классификации реализаций на основе динамической подписи (рукописного пароля). Обосновано применение многослойных нейронных сетей как способа реализации функции обобщения в условиях большого числа классов и внутриклассовой вариабельности. Установлена целесообразность исходного представления реализации динамической подписи в виде множества функционально связанных многомерных кривых в проекциях дискретных значений измерений физико-геометрических процессов. Алгоритмы чисто метрического представления и последующего нейросетевого анализа и классификации показывают высокую устойчивость к искажениям групповых представлений вида смещения, поворота, изменений масштаба, что целесообразно при учете вариабельности, обусловленной физиологией человека.

2. Теоретически обоснован и программно реализован метод расширения признакового описания подписи. В основу метода положена гипотеза о повышении качества анализа и классификации за счет экстраполяции зависимости значений дополнительных динамических параметров от кортежа значений минимального набора параметров сенсорного устройства. Экспериментально подтверждено, что использование синтезированных признаков стабилизирует процесс классификации: итоговая точность системы составила 0,95, зафиксирован прирост качества от 5 % до 35 % в сравнении с классическими метрическими и статистическими алгоритмами.

3. На основе самоорганизующейся карты Кохонена (*SOM*) разработан метод эталонирования реализаций динамической подписи в пространстве функционально связанных многомерных кривых динамических параметров подписи. Необходимость метода обусловлена внутриклассовой вариативностью когда в рамках одного класса возможны

несколько устойчивых вариантов постановки подписи в различных условиях или состояниях. В отличие от классической *SOM* в метод введены следующие отличия: взвешивание признаков по информативности для учёта разной информативности параметров, процедура подбора числа эталонов с критерием останковки по стабилизации степеней принадлежности, использование нейрона-победителя как указателя на конкретный эталон (вариант реализации) с привязкой к кодовому обозначению класса (эталона), использование полученной карты как компонента подсистемы принятия решения в комплексе методов с метрическим сопоставлением. Проведенное тестирование показало, что предложенный подход успешно нивелирует естественную вариативность моторики человека, позволив снизить показатель *FRR* до 0,12 в сценариях аутентификации.

4. Представлено описание методики отождествления образца динамической подписи с эталонами по кортежу уникальных матриц синаптических коэффициентов межнейронных связей, основная идея которой заключается в декомпозиции процедуры классификации на последовательность операций использования каждого набора матриц. В этом случае в алфавит классов необходимо ввести элемент – «отказ от распознавания», когда входная реализация не может быть отнесена ни к одному из эталонов с заданным уровнем уверенности. Проведенное тестирование показало, что предложенный подход успешно нивелирует естественную вариативность моторики человека, позволив снизить показатель *FRR* до 0,12 в сценариях аутентификации.

5. Усовершенствована методика нейросетевого анализа и классификации динамической сигнатуры в пространстве многоточечного представления статистических характеристик семейства кривых. В методике определены инварианты и метрики сравнения, а нейросетевая реализация выполнена на базе многослойных НС в двух конфигурациях — со скалярной и векторной функцией выхода. Особенностью разработанной

методики является высокая устойчивость к искажениям и масштабируемость по числу параметров и признаков. Эксперименты на репрезентативных выборках подтвердили, что многоточечное представление позволяет гибко настраивать систему: зафиксирован оптимальный баланс характеристик с показателем EER равным 0,09 (при чувствительности 0,06).

6. В результате проведенных исследований разработанные методы и методики в комплексе обеспечивают достижение поставленной цели – повышения качества анализа, сопоставления и классификации реализаций динамической подписи, реализуя свой функционал в следующей последовательности: 1) на основе метода обработки и расширения признакового описания динамической подписи формируются обучающие выборки повышенной информативности; 2) на основе сформированной выборки полного состава по методу эталонирования реализаций динамической подписи на основе SOM формируются эталонные представления; 3) методика отождествления образца динамической подписи с эталонами по кортежу уникальных матриц синаптических коэффициентов, а также методика нейросетевого анализа и классификации динамической сигнатуры в пространстве многоточечного представления статистических характеристик семейства кривых используют в качестве алфавита классов результаты модели эталонирования. Сравнение с известными алгоритмами обнаружения-различения многомерных сигналов подтверждает эффективность предложенных подходов. Эксперименты показали, что учет дополнительных параметров – координат пера в плоскости планшета и давления на экран в совокупности с кинематическими характеристиками обеспечивает достижение значений метрики качества до 0,8...0,95 при ограниченном объеме обучающих данных и числе классов, при этом сохраняется приемлемый уровень качества при их увеличении. Средний выигрыш от применения разработанных методов и алгоритмов анализа и классификации

динамической подписи по сравнению со статистическими методами составил 25–35 %, по сравнению с метрическими – от 5 до 15 %. Результаты тестирования оценок FAR и FRR , для предложенной модели, демонстрируют, что при изменении уровня чувствительности достигается компромисс между FAR и FRR . При чувствительности 0,1 показатель FAR составляет около 0,08, а FRR около 0,12, что соответствует значениям ложных допусков и отказов при выбранной настройке порога. Показатель EER (*Equal Error Rate*), определяемый пересечением кривых FAR и FRR для данной модели, достигает 0,09 при чувствительности 0,06. Эти результаты подтверждают эффективность предложенных методов и моделей для задач анализа и классификации динамической подписи, обеспечивая сбалансированное соотношение между ошибками первого и второго рода при минимальных значениях EER .

СПИСОК ЛИТЕРАТУРЫ

1. Rawlson, K. (2016) Explainer: Signature Recognition. [online] Available at: <https://www.biometricupdate.com/201601/explainer-signature-recognition> [Accessed 26 Jan. 2025].
2. (2019) Signature Verification System. Elsevier Journal Publishers. [online] Available at: <https://www.elsevier.marketing/journal/Pattern-Recognition> [Accessed 13 Jan. 2025].
3. Танцеров, А.Х. Использование моделей нейронного синтеза речи в системах голосовой аутентификации / А.Х. Танцеров // В сборнике: Современные методы и средства обработки пространственно-временных сигналов. Сборник статей XX Всероссийской научно-технической конференции, посвященной 60-летию кафедры "Программирование" ПензГТУ. – Пенза, 2023. – С. 41–45.
4. Bassit, A., Hahn, F., Peeters, J., Kevenaer, T., Veldhuis, R. and Peter, A. (2021) Fast and Accurate Likelihood Ratio-Based Biometric Verification Secure against Malicious Adversaries. IEEE Transactions on Information Forensics and Security, 16, 5045-5060. <https://doi.org/10.1109/TIFS.2021.3122823>
5. Танцеров, А.Х., Данилов, Е.А. Трансформация механизмов аутентификации в XX веке: от аналоговых методов до цифровых систем шифрования / А.Х. Танцеров, Е.А. Данилов // Современные информационные технологии. – 2024. – № 39 (39). – С. 80–85.
6. Танцеров, А.Х. Гибридная биометрическая аутентификация по динамическим параметрам подписи / А.Х. Танцеров // Модели инновационных решений повышения конкурентоспособности отечественной науки: сборник статей по итогам Всероссийской научно-практической конференции с международным участием, Иркутск, 04 мая 2025 года. – Стерлитамак: ООО "Агентство международных исследований", 2025. – С. 124–126.

7. W. Bouamra, C. Djeddi, B. Nini, M. Diaz, and I. Siddiqi. 2018. Towards the design of an offline signature verifier based on a small number of genuine samples for training. *Expert Systems with Applications* 107 (2018), 182–195.
8. Леус А.В. Биометрическая аутентификация по динамическим характеристикам подписи [Электронный ресурс], URL: http://www.secuteck.ru/articles2/sys_ogr_dost/biometrigh-autentifikac-po-dinamich-harakter-podpisi/ (дата обращения: 17.01.2025).
9. Ложников П.С. Разработка метода идентификации личности по динамике написания слов: автореф. дис. ... канд. техн. наук: 05.13.01. – Омск, 2004. – 22 с.
10. Дикий Д.И. Исследование применимости искусственных нейронных сетей для верификации пользователей по динамике почерка // Научно-технический вестник информационных технологий, механики и оптики, 2017. – Т. 17. – № 4. – С. 677–684.
11. Dhieb, T., Boubaker, H., Njah, S., Ben Ayed, M. and Alimi, A.M. (2022) A Novel Biometric System for Signature Verification Based on Score Level Fusion Approach. *Multimedia Tools and Applications*, 81, 7817-7845. <https://doi.org/10.1007/s11042-022-12140-7>.
12. Танцеров, А.Х., Данилов, Е.А. Современные методы обработки изображений динамических подписей: классификация и анализ / А.Х. Танцеров, Е.А. Данилов // Оптико-электронные приборы и устройства в системах распознавания образов и обработки изображений. – Курск, 2025. – С. 258–261.
13. Тихонов, А. Н. Методы решения некорректных задач / А.Н.Тихонов, В.Я.Арсенин. – М.: Наука, Гл. ред. физ.-мат. лит., 1986. – 288 с.
14. Тихонов, А. Н. О решении некорректно поставленных задач и методе регуляризации / А.Н. Тихонов // Доклады АН СССР. – 1963. – Т.151, № 3. – С.501–504.

15. G. Alvarez, B. Sheffer, and M. Bryant. 2016. Offline Signature Verification with Convolutional Neural Networks. Technical Report. Stanford University, Stanford. [12] A. Q. Ansari, M. Hanmandlu, J. Kour, and A. K. Singh. 2013. Online signature verification using segment-level fuzzy modelling. *IET Biometrics* 3, 3 (2013), 113–127.

16. M. Zoghi and V. Abolghasemi. 2009. Persian signature verification using improved dynamic time warping-based segmentation and multivariate autoregressive modeling. In *15th Workshop on Statistical Signal Processing (SSP'09)*. 329–332.

17. M. P. Caligiuri and L. A. Mohammed. 2012. *The Neuroscience of Handwriting: Applications for Forensic Document Examination*. CRC Press.

18. Двоеносова Г., Двоеносова М. Биометрия как наука, метод и способ документирования // *Управление персоналом*, 2009. №11, [Электронный ресурс]. – URL: <https://www.top-personal.ru/issue.html?2039> (дата обращения: 05.05.2024).

19. Биометрия в финансовой сфере 2020: выгоды для потребителя. Аналитическая записка. [Электронный ресурс]. – URL: <https://www.bayometric.com/biometrics-in-banking-and-finance> (дата обращения: 05.05.2024).

20. Обзор международного рынка биометрических технологий и их применения в финансовом секторе. 2018 / Центральный банк Российской Федерации // Москва – 2018. – 22 с.

21. Ломов Н., Петрова Д., Рязанцева Ю. Биометрия в финансовой сфере 2020: Выгоды для потребителя // Аналитическая записка. 06.2020. [Электронный ресурс]. – URL: <https://www.fintechru.org/analytics/analiticheskaya-zapiska-po-biometrii/?ysclid=lvwb2xh8z610856013> (дата обращения: 05.05.2024).

22. Танцеров, А.Х. Распознавание рукописных подписей: анализ методов и проблемы достоверности / А.Х. Танцеров // *Взаимодействие науки и общества - путь к модернизации и инновационному развитию:*

сборник статей по итогам Международной научно-практической конференции, Калуга, 29 апреля 2025 года. – Стерлитамак: ООО "Агентство международных исследований", 2025. – С. 162–165.

23. Мировой рынок биометрических систем – тенденции отрасли и прогноз до 2031 года [Электронный ресурс]. – URL: <https://www.databridgemarketresearch.com/ru/reports/global-biometric-system-market?ysclid=lvwgo7989485412>, (дата обращения: 05.05.2024).

24. Биометрия: что это и как она влияет на мир финансов [Электронный ресурс]. – URL: <https://frankmedia.ru/137504?ysclid=lvwb85nb3o106633262> (дата обращения: 05.05.2024).

25. Перечень действующих национальных стандартов, закрепленных за ТК 098 “Биометрия и биомониторинг”. [Электронный ресурс]. - URL: <https://www.rusbiometrics.com/standartization/gostr/> (дата обращения: 25.09.2025).

26. ГОСТ Р 52633.0-2006. Защита информации. Требования к средствам высоконадежной биометрической аутентификации. – М.: Стандартинформ, 2007.

27. Hafemann L.G. Offline handwritten signature verification - Literature review / L.G. Hafemann, R. Sabourin, L.S. Oliveira // Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA) – 2017. 8p. DOI:10.1109/ipta.2017.8310112.

28. Gupta G.K. The State of the Art in the On-Line Handwritten Signature Verification. Victoria, Australia, Faculty of Information Technology, Monash University, 2006. – 39 p.

29. 5 best electronic signature software for enterprise teams 2025. [online] Available at: <https://www.getaccept.com/blog/best-electronic-signature-software-for-enterprise-teams>. [Accessed 29 Sep. 2025].

30. OneSpan Sign electronic signatures. [online] Available at: <https://www.onespan>

31. Electronic Signature Solutions For Wherever Business Takes You. [online] Available at: <https://www.topazsystems.com/> [Accessed 29 Sep. 2025].
32. Electronic Signature Pad [online] Available at: <https://clinictracker.com/electronic-signature-capture> [Accessed 29 Sep. 2025].
33. Биометризация планеты: ключевые события рынка и ближайшие планы. Часть 1, [Электронный ресурс]. – URL:<https://recfaces.ru/articles/biometricisation-of-the-planet?ysclid=lvwg0o5qjh323460280> (дата обращения: 05.05.2024).
34. Jain A.K., Griess F.D., Connell, S.D. Online signature verification // *Pattern Recognition*. 2022. No. 35. pp. 2963-2972.
35. Ortega-Garsia J., Fierrez-Aquilar J., Martin-Rell J. Complete Signal Modeling and Score Normalization for Function-Based Dynamic Signature Verification. // *Audio and Video-Based Biometric Person Authentication*. 2003. – P. 658–667.
36. Doroz R., Porwik P., Orczyk T. Dynamic signature verification method based on association of features with similarity measures / *Neurocomputing*. – 2016. – No.171. – P. 921–931.
37. Galbally J., Martinez-Diaz M, Fierrez J. Aging in Biometrics: An Experimental Analysis on On-Line Signature. *PLoS ONE* – 2013. – 8(7): e69897. doi:10.1371/journal.pone.0069897.
38. Galbally J., Diaz-Cabrera M., Miguel A. Ferrer, Gomez-Barrero M., Morales A., Fierrez J. On-line signature recognition through the combination of real dynamic data and synthetically generated static data / *Pattern Recognition*. – 2015. – No. 48. – P. 2921–2934.
39. Serdouk Y., Nemmour H., Chibani Y. New off-line Handwritten Signature Verification method based on Artificial Immune Recognition System / *Expert Systems with Applications*. – 2016. – No. 51. – P. 186–194.
40. Танцеров, А.Х., Данилов, Е.А. Сравнительный анализ традиционных методов обработки и классификации многомерных сигналов на примере динамической подписи / А.Х. Танцеров, Е.А. Данилов

// Современные информационные технологии. – 2025. – № 41 (41). – С. 146–149.

41. Хайкин С. Нейронные сети: полный курс. 2-е изд.: пер. с англ. М.: Вильямс, 2006. – 1104 с.

42. Sae-Bae N., Memon N. A simple and effective method for online signature verification / Proc. Int. Conf. Biometrics Special Interest Group (BIOSIG). – 2013. – P. 147–158.

43. Айвазян С.А., Мхитарян В.С. Прикладная статистика и основы эконометрики. – М.: Юнити, 1998. – 1005 с.

44. Танцеров, А.Х. Современные подходы к распознаванию и аутентификации подписей: методы обработки изображений / А.Х. Танцеров, Е.А. Данилов // XXI век: итоги прошлого и проблемы настоящего плюс. – 2025. – Т. 14, № 2(70). – С. 71–76.

45. Танцеров, А.Х. Обзор и сравнение некоторых методов аутентификации подписи по динамическим параметрам / А.Х. Танцеров, Е.А. Данилов, А.И. Мартышкин // Вестник РГРТУ. – 2025. – № 92. – С. 214–225.

46. Танцеров, А.Х., Данилов, Е.А. Сравнительный анализ параметрического и функционального подходов в биометрической аутентификации подписи / А.Х. Танцеров, Е.А. Данилов // Современные информационные технологии. – 2024. – № 40 (40). – С. 97–101.

47. Снижение требований к корректирующей способности классических кодов с обнаружением и исправлением ошибок при использовании предварительного нейросетевого обогащения биометрических данных / А. П. Иванов, Е. А. Кольчугина, А. В. Безяев, Р. В. Еременко // Известия высших учебных заведений. Поволжский регион. Технические науки. – 2022. – № 3(63). – С. 37–45.

48. Иванов, А. И. Устранение методической погрешности оценки энтропии в пространстве расстояний Хэмминга / А. И. Иванов, А. П.

Иванов, А. П. Юнин // Защита информации. Инсайд. – 2023. – № 6(114). – С. 55–59.

49. ГОСТ Р 52633.3-2011. Защита информации. Техника защиты информации. Тестирование стойкости средств высоконадёжной биометрической защиты к атакам подбора. – М.: Стандартинформ, 2012.

50. Анисимова Э.С. Особенности процедуры распознавания динамических подписей // Современная техника и технологии. 2015. № 12, [Электронный ресурс]. – URL: <https://technology.snauka.ru/2015/12/8473> (дата обращения: 12.07.2023).

51. Van Veen, F. & Leijnen, S. (2019). The Neural Network Zoo, [Электронный ресурс]. – URL: <https://www.asimovinstitute.org/neural-network-zoo> (дата обращения 01.06.2024).

52. Танцеров, А.Х. Сравнительное исследование архитектур нейронных сетей в задачах идентификации многомерных биометрических данных / А.Х. Танцеров // Тенденции развития науки и образования. – Самара, 2025. – С. 151–155.

53. Фостер Д. Генеративное глубокое обучение. Творческий потенциал нейронных сетей. - СПб.: Питер, 2020. – 336 с.

54. Farabet C., Couprie C., Najman L., LeCun Y. Learning hierarchical features for scene labeling, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 8 (35), – P. 1915–1929.

55. Ростовцев, В. С. Искусственные нейронные сети. 4-е изд. – СПб.: Лань. 2024. – 216 с.

56. Бишоп К. М. Распознавание образов и машинное обучение: Пер. с англ. – СПб.: ООО «Диалектика», 2020. – 960 с.

57. Carmona P. L., Salvador S. A., Fred L. N. Mathematical Methodologies in Pattern Recognition and Machine Learning. Springer Proceedings in Mathematics & Statistics. Vol.30. 2022. – 200 p.

58. Микелуччи, У. Прикладное глубокое обучение. Подход к пониманию глубоких нейронных сетей на основе метода кейсов: Пер. с англ. – СПб.: БХВ-Петербург, 2020. – 368 с.

59. Танцеров, А.Х. Обзор методов нейросетевого эталонирования / А.Х. Танцеров // Опτικο-электронные приборы и устройства в системах распознавания образов и обработки изображений. – Курск, 2025. – С. 256–258.

60. Алгоритм классификации и восстановления искаженных п-мерных групповых точечных объектов на основе комбинаторного поиска фрагментов / А.Ю. Каплин, А.А. Коротин, А.В. Назаров, В.Л. Якимов // Труды СПИИРАН. –2016. – Вып. 6(49). – С. 167–189.

61. Точечные поля и групповые объекты / Я.А. Фурман, А.А. Роженцов, Р.Г. Хафизов и др.; под ред. Я.А. Фурмана. – М.: Физматлит, 2014. – 340 с.

62. Танцеров, А.Х. Кинематическая модель формирования эталонных динамических параметров подписи пользователя / А.Х. Танцеров, Е.А. Данилов // Вестник РГРТУ. – 2025. – № 92. – С. 170–78.

63. Антал М., Сабо Л. Ж, Тордаи Т. Онлайн-проверка подписи на корпусе отпечатков пальцев *MOBISIG*, 2018, [Электронный ресурс]. – URL: <http://www.ms.sapientia.ro/~manyi/mobisig/MOBISIG.ZIP>, (дата обращения: 01.07.2024).

64. Танцеров, А.Х. Методика отождествления эталона динамической сигнатуры подписи пользователя по кортежу уникальных матриц синаптических коэффициентов межнейронных связей/ А.Х. Танцеров, Е.А. Данилов // XXI век: итоги прошлого и проблемы настоящего плюс. – 2026. – Т. 15, № 1(73). – С. 10 – 16.

65. Иванов, А. И. Оценка качества работы многокритериального нейросетевого статистического анализа на примере проверки гипотезы независимости данных малых выборок / А. И. Иванов, А. И. Ермакова // Надежность и качество сложных систем. – 2024. – № 3(47). – С. 13–18.

66. Kohonen T., Honkela T. Kohonen Network, Scholarpedia, 2007, vol. 2, no. 1. – 1568 p.

67. Кохонен Т. Ассоциативная память. М.: Мир, 1982. – 239с.

68. Кохонен Т. Ассоциативные запоминающие устройства. М.: Мир, 1982. – 384с.

69. Willshaw D. J., von der Malsburg C. A marker induction mechanism for the establishment of ordered neural mappings: Its application to the retinotectal problem. // Proc. R. Soc. London B. – 1977. – 287. – P. 203–243.

70. Hecht-Nielsen R. Kolmogorov's Mapping Neural Network Existence Theorem // IEEE First Annual Int. Conf. on Neural Networks, San Diego, 1987, Vol. 3, PP. 11–13.

71. Танцеров, А.Х. Исследования алгоритмов нейросетевой идентификации динамической подписи пользователя в пространстве отсчетов многомерных кривых в сравнении с оптимальными алгоритмами обнаружения-различий многомерных сигналов / А.Х. Танцеров, Е.А. Данилов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. Медицинское приборостроение. – Т. 15, № 3. – С. 89–87.

72. Tantserov, A.H. Combined Approach to Signature Verification Based on Fourier Transform, Hough Transform, Radon Transform, and the Support Vector Machine Method. / A.H. Tantserov; E.A. Danilov // Proceedings of International Russian Smart Industry Conference (SmartIndustryCon). – Sochi, Russian Federation, 2025. – P.759–764.

73. Танцеров, А.Х. Структурный синтез нейросетевых моделей биометрической идентификации в пространстве вторичных признаков многомерных динамических кривых/ А.Х. Танцеров, Е.А. Данилов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское

приборостроение. Медицинское приборостроение. – Т. 15, № 3. – С. 113–125.

74. Танцеров, А.Х. Использование спектрально-статистических признаков и вейвлет-преобразований в многослойных нейронных сетях в задачах идентификации многомерных биометрических данных / А.Х. Танцеров // Современные достижения научно-технического прогресса. – Самара, 2025. – С. 41–44.

75. Каплин А.Ю., Коротин А.А., Назаров А.В., Якимов В.Л. Алгоритм классификации и восстановления искаженных n-мерных групповых точечных объектов на основе комбинаторного поиска фрагментов // Труды СПИИРАН. 2016. Вып. 6(49). – С.167–189.

76. Ковалев, С.М. Интеллектуальные технологии слияния данных при диагностировании технических объектов / С.М. Ковалев, А.Е. Колоденкова, В. Снасель // Онтология проектирования. – 2019. – Т.9, №1(31). – С.152–168.

77. Городецкий В. И., Серебряков С. В. Методы и алгоритмы коллективного распознавания: обзор // Труды СПИИРАН. Вып. 3, т. 1. – СПб.: Наука, 2006. – С.139–171.

78. Долгий, А.И. Проблемы и методы слияния разнородных данных в гибридных интеллектуальных системах / А.И. Долгий, А.Е. Колоденкова, С.М. Ковалев // Гибридные и синергетические интеллектуальные системы: материалы IV Всероссийской Поспеловской конференции с международным участием. – Калининград: БФУ им. И. Канта, 2018. – С.181–187.

79. Самойлов В.В. Системы объединения данных из разных источников: Принципы реализации и архитектура обработки данных для обучения систем принятия решений. //Труды СПИИРАН, Вып. 1, т. 2. — СПб: СПИИРАН, 2002.

80. Bleiholder J., Naumann F. Data Fusion. ACM Computing Survey 2022. – 340 p.

81. Marquardt, D. An algorithm for least squares estimation of nonlinear parameters, SIAM, 1963. – PP. 431–442.
82. Suratgar, A. A. Modified Levenberg-Marquardt method for neural networks training / A. A. Suratgar, M. B. Tavakoli, A. Hoseinabadi // WEC'05: The Fourth World Enformatika Conference. – 2005.
83. Sousa, C. Neural network learning by the levenberg-marquardt algorithm with bayesian regularization (part 1) [Электронный ресурс] URL: http://crsouza.blogspot.com/2009/11/neural-network-learning-by-levenberg_18.html (дата обращения: 21.12.2024).
84. Cloud Computing | Meaning of Cloud Computing by Lexico (АНГЛ.). Lexico Dictionaries | English [online] Available at: https://www.lexico.com/definition/cloud_computing [Accessed 26 Dec. 2024].
85. Antonio Brogi, Stefano Forti. QoS-Aware Deployment of IoT Applications Through the Fog // IEEE Internet of Things Journal. – 2017-10. – Т. 4, ВЫП. 5. – С. 1185–1192.
86. Kitsak M., Gallos L. K., Havlin S., Liljeros F., Muchnik L., Stanley H. E., Makse H.A. Influential Spreaders in Networks // Nature Physics. – 2019. – Т. 6, vol. 11. – P. 888–893.
87. De Domenico M., Sole-Ribalta A., Omodei E., Gomez S., Arenas A. Ranking in interconnected multilayer networks reveals versatile nodes // Nature Communications. – 2019. – Т. 6. – P. 68–79.
88. Yannis Nikoloudakis, Spyridon Panagiotakis, Evangelos Markakis, Evangelos Pallis, George Mastorakis. A Fog-Based Emergency System for Smart Enhanced Living Environments // IEEE Cloud Computing. – 2016-11. – Т. 3, ВЫП. 6. – С. 54–62.

**ПРИЛОЖЕНИЕ 1. СВИДЕТЕЛЬСТВА О РЕГИСТРАЦИИ
ПРОГРАММ**

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025689457

**Программа для построения и обучения полносвязной
искусственной нейронной сети по многоканальным
временным рядам динамических параметров личной
подписи**

Правообладатель: **Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Пензенский государственный технологический
университет» (RU)**

Авторы: **Данилов Евгений Александрович (RU), Танцеров
Александр Хабибуллоевич (RU)**

Заявка № 2025688076

Дата поступления 17 октября 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 28 октября 2025 г.



Руководитель Федеральной службы
по интеллектуальной собственности

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e4f7ad38d531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 04/09/2025 по 28.11.2026

Ю. С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025690104

**Программный модуль обучения MLP-модели ИНС по
нормированным векторным динамическим параметрам
личной подписи**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Пензенский государственный технологический
университет» (RU)*

Авторы: *Данилов Евгений Александрович (RU), Танцеров
Александр Хабибуллоевич (RU)*

Заявка № 2025688785

Дата поступления 23 октября 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 05 ноября 2025 г.



*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e47a338f531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 14.07.2025 по 28.11.2026

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025690311

**Программа для формирования наблюдательной и
верификационной выборки многоканальных
временных рядов динамических параметров личной
подписи**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Пензенский государственный технологический
университет» (RU)*

Авторы: *Данилов Евгений Александрович (RU), Танцеров
Александр Хабибуллоевич (RU)*

Заявка № 2025688866

Дата поступления 23 октября 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 06 ноября 2025 г.



*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570ea77aaf8b531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 04.07.2025 по 28.11.2026

Ю.С. Зубов

ПРИЛОЖЕНИЕ 2. АКТЫ О ВНЕДРЕНИИ

«УТВЕРЖДАЮ»

И.о. ректора ФГБОУ ВО «Пензенский
государственный технологический
университет»


Д.В. Пашенко
«27» _____ 2025 г.

АКТ

о внедрении результатов диссертационной работы
Танцера Александра Хабибуллоевича

Комиссия в составе:

председатель комиссии – к.т.н., доцент Сёмочкина И.Ю. – начальник
учебно-методического управления ФГБОУ ВО «Пензенский
государственный технологический университет»;

члены комиссии:

к.т.н., доцент Мартышкин А.И. – декан факультета
автоматизированных информационных технологий ФГБОУ ВО «Пензенский
государственный технологический университет»;

к.т.н., доцент Покровский В.Г. – доцент кафедры «Программирование»
ФГБОУ ВО «Пензенский государственный технологический университет»;

к.т.н., доцент Печерский С.В. – доцент кафедры «Программирование»
ФГБОУ ВО «Пензенский государственный технологический университет»;

составила настоящий акт о том, что результаты диссертационной
работы Танцера А.Х. на тему «Методы интеллектуального анализа
динамических параметров подписи на основе искусственных нейронных
сетей», представленной на соискание ученой степени кандидата технических
наук, внедрены в учебный процесс кафедры «Программирование» ФГБОУ
ВО «Пензенский государственный технологический университет».

Автором получены новые научные результаты:

1. Разработан обработки и расширения динамических параметров
на множестве функционально связанных многомерных кривых динамических
параметров его подписи по кортежу стандартных параметров сенсорного
устройства, обеспечивающий повышение качества анализа и устойчивости
сопоставления реализаций подписи.

2. Разработан метод эталонирования биометрических реализаций
подписи (парольной фразы) пользователя, на основе SOM, в пространстве
функционально связанных многомерных кривых, учитывающий
внутриклассовую вариативность подписи для задач сопоставления и
классификации реализаций подписи.

3. Разработана методика отождествления образца динамической
сигнатуры подписи с эталонами по кортежу уникальных матриц
синаптических коэффициентов межнейронных связей многослойной
нейронной сети.

4. Усовершенствована методика нейросетевого анализа и классификации динамической сигнатуры подписи пользователя в пространстве многоточечного представления статистических характеристик семейства кривых.

Указанные результаты внедрены в учебный процесс кафедры «Программирование» по направлению подготовки 09.04.04 «Программная инженерия» при проведении лекционных и лабораторных работ по дисциплинам: «Искусственные нейронные сети и глубокое обучение», «Интеллектуальный анализ данных», «Методы и алгоритмы искусственного интеллекта».

Внедрение полученных автором научных результатов позволило повысить качество учебного процесса.

Председатель комиссии  И.Ю. Сёмочкина

Члены комиссии  А.И. Мартышкин

 В.Г. Покровский

 С.В. Печерский

УТВЕРЖДАЮ



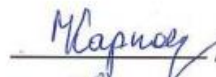
АКТ

о внедрении результатов кандидатской
диссертационной работы Танцера А.Х.


Комиссия в составе: председатель – начальник управления программных средств защиты информации Карпов И.В.; члены комиссии – начальник управления тестирования защищенных систем Акчурина Д.В., начальник отдела технологий защиты накопителей информации Чикманов С.В., специалист к.ф.-м.н. Карманов А.А., специалист к.ф.-м.н. Игошина С.Е., настоящим актом подтверждает, что результаты диссертационной работы Танцера Александра Хабибуллоевича внедрены при проведении проекта «QR-МДЗ» в части применения предложенного метода эталонирования реализаций личной подписи на основе самоорганизующихся карт SOM (Self-organizing map) в пространстве функционально связанных многомерных кривых динамических параметров.

Результаты работы были использованы на этапах разработки опытного образца и получили положительную оценку в ходе выполнения натурного моделирования.


Председатель комиссии:

 / Карпов И.В.

Члены комиссии:

 / Акчурина Д.В.

 / Чикманов С.В.

 / Карманов А.А.

 / Игошина С.Е.