

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ  
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ  
«РОССИЙСКИЙ УНИВЕРСИТЕТ ДРУЖБЫ НАРОДОВ  
ИМЕНИ ПАТРИСА ЛУМУМБЫ»

*На правах рукописи*

**Мищук Всеволод Александрович**

**ТЕОРЕТИЧЕСКИЕ И ПРАКТИЧЕСКИЕ АСПЕКТЫ  
ПРИМЕНЕНИЯ НЕЙРОННЫХ СЕТЕЙ  
В СУДЕБНО-ПОЧЕРКОВЕДЧЕСКОЙ ЭКСПЕРТИЗЕ**

Специальность 5.1.4. Уголовно-правовые науки  
(юридические науки)

**ДИССЕРТАЦИЯ**

на соискание ученой степени  
кандидата юридических наук

**Научный руководитель:**  
доктор юридических наук  
**Чеснокова Елена Владимировна**

Москва – 2025

## ОГЛАВЛЕНИЕ

|                                                                                                                                                                                 |            |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| <b>Введение .....</b>                                                                                                                                                           | <b>4</b>   |
| <b>Глава 1. Основные теоретические положения использования искусственных нейронных сетей в судебно-почерковедческой экспертизе .....</b>                                        | <b>21</b>  |
| § 1.1. Искусственные нейронные сети – понятие, виды и принципы работы. Соотношение с понятием «искусственный интеллект» и «машинное обучение» .....                             | 21         |
| § 1.2. История внедрения и применения искусственных нейронных сетей и программных комплексов ЭВМ в судебно-почерковедческой экспертизе ...                                      | 54         |
| § 1.3. Современные подходы использования искусственных нейронных сетей для решения задач судебно-почерковедческой экспертизы .....                                              | 76         |
| <b>Глава 2. Использование искусственных нейронных сетей для решения типовых задач судебно-почерковедческой экспертизы .....</b>                                                 | <b>88</b>  |
| § 2.1. Оценка текущего положения практики использования искусственных нейронных сетей для решения отдельных задач судебно-почерковедческой экспертизы .....                     | 88         |
| § 2.2. Возможные подходы применения искусственных нейронных сетей для решения задачи идентификации исполнителя подписи. Архитектура нейросетевых моделей .....                  | 111        |
| § 2.3. Анализ и оценка результатов применения искусственной нейронной сети в решении задачи идентификации исполнителя подписи .....                                             | 128        |
| <b>Глава 3. Методические и организационно-тактические рекомендации и предложения по использованию искусственных нейронных сетей в судебно-почерковедческой экспертизе .....</b> | <b>148</b> |
| § 3.1. Место искусственных нейронных сетей в методике судебно-почерковедческой экспертизы .....                                                                                 | 148        |

|                                                                                                                                                      |            |
|------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| § 3.2. Правовые и организационно-тактические рекомендации по использованию искусственных нейронных сетей в судебно-почерковедческой экспертизе ..... | 160        |
| § 3.3. Возможные направления по дальнейшей интеграции искусственных нейронных сетей в судебно-почерковедческую экспертизу .....                      | 176        |
| <b>Заключение.....</b>                                                                                                                               | <b>184</b> |
| <b>Список сокращений и условных обозначений.....</b>                                                                                                 | <b>191</b> |
| <b>Список источников и литературы.....</b>                                                                                                           | <b>194</b> |
| <b>Приложения.....</b>                                                                                                                               | <b>222</b> |

## ВВЕДЕНИЕ

**Актуальность темы диссертационного исследования.** Сегодня мир переживает эпоху четвертой промышленной революции, во многом связанной с развитием технологий искусственного интеллекта (ИИ). Подобного мнения придерживаются многие исследователи и публицисты. Это неудивительно, поскольку искусственные нейронные сети (ИНС) – наиболее передовые на сегодняшний день алгоритмы в области ИИ – находят применение в самых различных сферах жизни. Современные ИНС, как показывают многочисленные исследования, уже превосходят человека во многих аспектах. В частности, это касается задач, связанных с обработкой и анализом больших объемов информации. Это особенно важно в условиях современного общества, где одному человеку становится практически невозможно охватить и качественно проанализировать весь массив доступной информации.

В связи с этим ИИ-технологии приобретают все большую значимость и в правоохранительной деятельности, равно как и в области судопроизводства. Это не удивительно, ведь компьютерные технологии, в частности методы компьютерного моделирования, уже давно используются как для расследования и раскрытия различных преступлений<sup>1</sup>, особенно в сферах, непосредственно связанных с компьютерной информацией<sup>2</sup>, так и при рассмотрении гражданских и арбитражных дел. Нельзя не заметить, что с точки зрения теории информации перечисленные процессы можно рассматривать как процедуру исследования и анализа большого объема разнородной информации. Особенно это характерно для судебной-экспертной деятельности, которая интегрирует в себе знания из юридической, естественнонаучной, технической, социальных и иных областей. В настоящее

---

<sup>1</sup> Ковалев С.А., Решняк О.А., Вехов В.Б. Генезис компьютерного моделирования в криминалистике // Расследование преступлений: проблемы и пути их решения. – 2017. – № 4(18). – С. 156–160.

<sup>2</sup> Ковалев С. А. Основы компьютерного моделирования при расследовании преступлений в сфере компьютерной информации монография / Ковалев С. А., Вехов В. Б. – М.: Буки-Веди, 2015.



время судебные разбирательства практически не обходятся без назначения той или иной судебной экспертизы, так как именно результаты экспертного исследования часто становятся основным источником доказательственной информации по делу.

В свете этого вполне логично рассматривать возможности применения ИИ-технологий как продолжение процесса интеграции методов компьютерного моделирования в область криминалистики и судебной экспертологии как для увеличения эффективности анализа данных, так и автоматизации рутинных процессов и повышения объективности экспертных заключений<sup>1</sup>. Особый интерес в данном направлении вызывает использование нейросетевых алгоритмов для решения задач, связанных с судебно-почерковедческой экспертизой. Это не случайно, поскольку в последние десятилетия в связи с активным развитием института гражданского и арбитражного судопроизводства востребованность таких исследований в нашей стране значительно возросла.

В то же время методологическая база судебного почерковедения была преимущественно сформирована в 60–70-е гг. прошлого века<sup>2</sup>. Несмотря на то, что современные научные достижения в области исследования почерка частично восполняют существующие методологические пробелы, действующие методики все еще требуют актуализации отдельных положений. Более того, в экспертной практике все чаще встречаются объекты исследования, которые затруднительно анализировать с применением традиционных подходов. Дополнительно эксперты сталкиваются с увеличением нагрузки, что усложняет проведение исследований в условиях современных требований к срокам и качеству экспертных заключений.

Учитывая эти обстоятельства, в экспертной среде все чаще высказываются предложения о необходимости разработки и внедрения

---

<sup>1</sup> Цифровая криминалистика: учебник для вузов / под редакцией В. Б. Вехова, С. В. Зуева. 2-е изд., перераб. и доп. М.: Издательство Юрайт, 2025.

<sup>2</sup> Судебно-почерковедческая экспертиза документов: учеб.-практ. пособие / М. В. Жижина; под ред. Е. П. Ищенко. М.: Юрлитинформ, 2006.

инструментов, способных полностью или частично автоматизировать отдельные этапы судебно-почерковедческой экспертизы. По мнению ряда специалистов, использование компьютерных алгоритмов и математических методов в почерковедении позволит повысить объективность и достоверность проводимых исследований. Аналогичные подходы активно развиваются и за рубежом.

В этом контексте особенно перспективным направлением считается применение нейросетевых алгоритмов. Уже с 1989 года, ознаменовавшегося новым этапом в развитии ИНС, они начали использоваться в ряде экспериментальных проектов для решения таких задач, как биометрическая идентификация и верификация личности по почерку, а также обнаружение фальсифицированных рукописей, в частности подписей. В дальнейшем бурное развитие вычислительной техники, особенно графических процессоров и специализированного программного обеспечения, а также появление крупных наборов данных для задач компьютерного зрения и распознавания образов позволили существенно усложнить архитектуры нейросетевых моделей. В результате этого ИНС стали одним из наиболее эффективных инструментов для решения неформализуемых задач, что во многом объясняет их широкое распространение и высокую популярность в различных сферах.

В то же время нельзя не заметить, что в современной практике почерковедческого анализа применение ИНС пока не получило широкого распространения. Во многом это объясняется тем, что человеческий почерк остается одним из наиболее сложных и малоформализуемых объектов исследования. Одной из ключевых проблем является его высокая степень вариационности, а также существенное влияние на процесс письма различных внутренних и внешних сбивающих факторов. Эти особенности затрудняют разработку универсальных алгоритмов, способных эффективно и объективно обрабатывать и интерпретировать такие данные.

Тем не менее, учитывая стремительное развитие технологий и

накопление соответствующих данных, можно с уверенностью говорить о перспективах успешного применения нейросетевых алгоритмов в судебно-почерковедческой экспертизе в ближайшем будущем. Внедрение таких инструментов позволит повысить скорость и объективность экспертных исследований, а также снизить нагрузку на специалистов, что отвечает потребностям современного правосудия.

Таким образом, **актуальность темы** настоящего диссертационного исследования обусловлена объективной потребностью судебно-экспертной практики в разработке надежных и эффективных алгоритмических средств обработки данных, способных полностью или частично автоматизировать отдельные этапы судебно-почерковедческой экспертизы.

**Степень разработанности темы.** Среди отечественных работ, связанных с применением ИНС в процессе экспертного исследования почерка, можно выделить исследования исследования С.Д. Кулика и Н.А. Никонец<sup>1</sup>, которые в период с 2008 по 2010 гг. занимались разработкой программы «FNWE v.1.0» и подсистемы распознавания «RSFNWE v.1.0». Созданный ими программный комплекс использовался, в частности, для дифференциации почерков на мужские и женские. В 2016 г. авторы предложили адаптацию традиционных методик почерковедческих исследований для применения в них ИНС. Однако указанные разработки в настоящее время не применяются в экспертной практике, поскольку использованный в них нейропакет NeuroSolutions в настоящее время считается устаревшим.

В работах А.И. Иванова<sup>2</sup>, А.И. Газина, Е.И. Качайкина и Д.Ю. Андреева отражены экспериментальные исследования, направленные на адаптацию программы «БиоНейроАвтограф» для решения задачи идентификации

---

<sup>1</sup> Никонец Д.А. Методы и средства повышения эффективности работы экспертов-почерковедов в криминалистике: диссертация ... кандидата технических наук: 05.13.01 / Никонец Денис Артурович – Москва, 2012.

<sup>2</sup> Иванов А.И. Нейросетевые технологии биометрической аутентификации пользователей открытых систем: диссертация ... доктора технических наук: 05.13.01. – Пенза, 2002.

человека по его почерку<sup>1</sup>. Эти исследования обладают несомненной практической ценностью, однако в рамках представленной реализации авторами не была решена задача ввода в программную среду отсканированных изображений подписей, поскольку основная функциональность системы рассчитана на непосредственное выполнение подписи с помощью графического планшета. Также осталась неразрешенной проблема формирования «негативных» примеров для программы, чтобы она могла научиться отличать подлинную подпись от поддельной.

Отдельного внимания заслуживает проект NSP-SigVer под руководством Д.В. Бахтеева, в котором была реализована нейросетевая модель для верификации подписей<sup>2</sup>. По утверждению авторов, разработанная система способна с высокой точностью отличать поддельные подписи от подлинных. Вместе с тем было установлено, что при тестировании на независимых данных, не использовавшихся в процессе обучения, система демонстрирует несколько сниженные показатели точности. Кроме этого, в рамках данного проекта исследователями была сформирована обширная база данных подписей и их имитаций, выполненных кириллицей, которая на сегодняшний день является крупнейшей в СНГ среди специализированных наборов данных для решения задач по идентификации подписей.

Более современной работой, посвященной исследуемой тематике, является публикация М.В. Бобовкина, О.А. Диденко и А.Е. Нестерова, в рамках которой был разработан программный комплекс «Фрося»<sup>3</sup>. Представленная система является достаточно перспективной и

---

<sup>1</sup> Иванов А.И., Газин А.И., Качайкин Е.И., Андреев Д.Ю. Автоматизация почерковедческой экспертизы, построенная на обучении больших искусственных нейронных сетей // Модели, системы, сети в экономике, технике, природе и обществе. – 2016. – № 1(17). – С. 249–257.

<sup>2</sup> Бахтеев Д.В. Концептуальные основы теории криминалистического мышления и использования систем искусственного интеллекта в расследовании преступлений: диссертация ... доктора юридических наук: 5.1.4. / Бахтеев Дмитрий Валерьевич – Екатеринбург, 2022.

<sup>3</sup> Бобовкин М.В., Диденко О.А., Нестеров А.Е. Компьютерное моделирование раздельного и сравнительного исследования частных признаков почерка на основе программного комплекса «Фрося» // Судебная экспертиза – 2021–№3 (67). – С. 62–71.

инновационной, однако ее основное назначение заключается лишь в предоставлении экспертам вспомогательных инструментов для сбора статистических данных о частных признаках почерка и формирования интерактивных подсказок.

Кроме того, среди работ, не связанных напрямую с использованием нейросетевых алгоритмов, но посвященных применению автоматизированных алгоритмических средств в рамках судебно-почерковедческой экспертизы, следует выделить монографическое исследование А.Н. Охлупиной<sup>1</sup>. Несмотря на то, что автор отдает предпочтение применению ДСМ-метода (метод автоматического порождения гипотез) и достаточно критично оценивает перспективы внедрения нейросетевых алгоритмов в почерковедческие исследования, предложенный ею методический подход по интеграции интеллектуальных систем в существующие методики экспертизы, в частности посредством объединения на аналитической стадии исследования и автоматизации процесса оценки выявленных признаков, представляется интересным для дальнейшего осмысления. Более того, предложенная автором система обеспечивает наглядность, что способствует повышению прозрачности экспертного заключения для органов предварительного расследования и суда.

Предмет и цель настоящего диссертационного исследования формулируются следующим образом:

**Объект исследования** – судебно-экспертная деятельность с применением ИНС и/или компьютерных программ, основанных на нейросетевых алгоритмах, при проведении судебно-почерковедческой экспертизы.

**Предмет исследования** – закономерности внедрения и применения программных комплексов, в частности ИНС и/или программ на их основе, для

---

<sup>1</sup> Охлупина А.Н. Теоретические, методические и организационно-тактические основы применения интеллектуальных систем в судебно-почерковедческом исследовании подписей: диссертация ... кандидата юридических наук: 12.00.12 / Охлупина Анастасия Николаевна – Москва, 2019.

решения задач судебно-почерковедческой экспертизы, а также теоретические, методологические и организационно-тактические особенности их применения в экспертной практике.

**Цель исследования** – комплексное изучение возможностей внедрения и применения ИНС и других компьютерных программ, базирующихся на нейросетевых алгоритмах, для решения отдельных задач судебно-почерковедческой экспертизы.

Для достижения поставленной цели в рамках исследования необходимо решить следующие **задачи**:

- проанализировать понятие «искусственная нейронная сеть» и соотнести его с категориями «искусственный интеллект», «машинное обучение» и «глубокое обучение»;
- изучить принципы функционирования современных ИНС при осуществлении судебно-экспертной деятельности;
- исследовать историю разработки и применения программных комплексов для решения задач судебно-почерковедческой экспертизы, а также определить актуальные проблемы в этом направлении;
- определить цели, задачи, условия и этапы экспериментального исследования, направленного на оценку возможности применения ИНС в судебно-почерковедческой экспертизе;
- провести анализ результатов экспериментального исследования;
- при получении положительных результатов выработать на их основе методические и организационно-тактические рекомендации по применению ИНС для решения задач судебно-почерковедческой экспертизы, а также определить дальнейшие перспективы данного направления.

**Научная новизна** диссертационного исследования заключается в разработке комплекса теоретических положений и практических рекомендаций, направленных на совершенствование судебно-почерковедческой экспертизы в части интеграции современных компьютерных технологий, а именно искусственных нейронных сетей и

методов машинного обучения.

В данной работе:

- через призму судебно-почерковедческой экспертизы и судебной экспертологии рассмотрены современные ИИ-технологии, в частности искусственные нейронные сети. При этом подчеркивается, что на современном этапе науки и техники нейронные сети, равно как и другие схожие ИИ-технологии, следует рассматривать как алгоритмический инструмент, обеспечивающий обработку и анализ почерка как большого массива данных;

- разработана оригинальная периодизация развития применения нейросетей в почерковедении, позволяющая проследить этапы от ранних экспериментов (1960–1970-е гг.) до современных проектов (NSP-SigVer, «Фрося»), с анализом методологических пробелов и влияния вычислительных технологий на эволюцию экспертизы;

- впервые комплексно и на монографическом уровне рассмотрена возможность применения современных нейросетевых архитектур, таких как сверточные нейронные сети и сети с механизмами внимания (CBAM, Self-Attention, Cross-Attention), для автоматизации отдельных задач судебно-почерковедческой экспертизы, в частности для идентификации исполнителя спорной подписи;

- предложена новая система классификации подходов к обучению нейросетевых моделей в экспертной практике, построенная на критериях «локального» (на ограниченной выборке конкретной экспертизы) и «глобального» (на больших массивах обезличенных данных) обучения, что обеспечивает адаптивность, точность и воспроизводимость моделей;

- интерпретируемость результатов работы искусственных нейронных сетей впервые определена как необходимое и обязательное условие их применения в судебном почерковедении, позволяющее экспертам оценивать, корректировать и научно обосновывать свои выводы в соответствии с требованиями судебной практики;

- разработаны методические рекомендации по интеграции нейросетевых алгоритмов в систему общих и частных методик судебно-почерковедческой экспертизы. Предложена схема их использования на стадиях предварительного, аналитического, сравнительного исследования и оценки результатов. При этом предлагается использование специализированных моделей, ориентированных на решение конкретных задач в рамках экспертного исследования – таких, как выделение, анализ и сопоставление диагностических, общих и частных признаков. Такой подход, как ожидается, позволит повысить эффективность и объективность экспертного исследования;

- предложена организационно-тактическая модель внедрения нейросетей в судебно-экспертную деятельность, предусматривающая разработку и валидацию методик с нейросетевыми алгоритмами, создание специализированного программного обеспечения и обучение судебных экспертов работе с ИИ-инструментами;

- обоснована правовая допустимость использования нейронных сетей в судебно-почерковедческой экспертизе на текущем этапе развития законодательства, при условии соблюдения норм о защите персональных данных и применении процедур обезличивания;

- определены перспективные направления дальнейшего развития, включая интеграцию больших языковых моделей для автоматизации подготовки текстов экспертных заключений и создание единой цифровой платформы для систематизации признаков почерка.

**Методология и методы исследования.** Методологическая база исследования основана на положении диалектического материализма, а также включает общенаучные и специальные методы, применяемые в судебной экспертиологии и почерковедении. К основным методам исследования относятся:

- Эксперимент: предназначен для воссоздания условий экспертного исследования и проверки возможностей нейронных сетей в решении задач



почерковедения, таких как идентификация исполнителя подписи;

- Моделирование: направлено на представление рукописей в удобной для алгоритма форме (в виде многомерных векторов), что улучшает точность прогнозов и позволяет обосновать результаты, полученные нейросетью;

- Описание: служит вспомогательным средством фиксации и анализа экспериментальных данных;

- Сравнение: используется для сопоставления различных подходов и архитектур нейронных сетей, выбирая наиболее эффективный подход для решения задач почерковедческой экспертизы.

Из частнонаучных методов был применен метод оценки совпадений признаков почерка и анализ рукописей, выполненных с подражанием почерку другого человека. Из области искусственного интеллекта бы применены такие методы машинного обучения как обратное распространение ошибки как базовый алгоритм обучения ИНС, метод опорных векторов, а также анализ почерка с применением ИНС.

**Теоретическую основу диссертации** составили труды отечественных ученых в области судебной экспертологии, криминалистики, почерковедения и разработки ИНС: Л.Е. Ароцкера, Д.В. Бахтеева, М.В. Бобовкина, С.М. Бобовкина, В.Б. Вехова, О.А. Диденко, А.И. Иванова, А.Е. Нестерова, Д.А. Никонца, С.Д. Кулика, А.Ф. Купина, Р.М. Ланцмана, Г.Г. Омелянюка, А.Н. Охлупиной, Е.Р. Россинской, А.В. Смирнова, С.А. Смирновой, А.И. Усова, Ш.Н. Хазиева, А.И. Хмыза, Е.В. Чесноковой, Л.Г. Эджубова.

Также были изучены работы следующих зарубежных авторов: Ч. Вен, Д. Гонг, Т. Дуани, Х. Као, В. Кумара, Я. Лекуна, Ш. Лю, И. Ма, М. Марциновского, С. Сундарам, Г. Сюэ, А. Хедрика, Р. Хубера, М. Чауханз, М.А. Шейх, С.Н. Шрихари.

**Нормативную базу** исследования составляют положения процессуального законодательства, иных федеральных законов, указов и поручений Президента Российской Федерации, правовых актов федеральных органов исполнительной власти, иных нормативно-правовых документов,

регулирующих деятельность судебно-экспертных учреждений, а также нормативно-техническая документация в виде национальных и международных стандартов.

**Эмпирическую основу исследования составили:**

- практика применения программного комплекса «ОКО-1», предназначенного для анализа малообъемных почерковых объектов;
- экспериментальные разработки и исследования отечественных и зарубежных исследователей в области интеграции алгоритмов искусственного интеллекта, в частности искусственных нейронных сетей, как для решения идентификационных и диагностических задач судебно-почерковедческой экспертизы, так и для решения задач, связанных с биометрией почерка;
- образцы рукописей и подписей, предоставленных для сравнительного исследования и выполненных проверяемыми лицами, с количеством не менее 100 образцов от каждого автора. Эти материалы использовались для обучения и тестирования нейросетевых моделей;
- открытые базы данных рукописных текстов и подписей, в том числе международные датасеты. Указанные базы данных применялись для апробации «глобального» подхода к обучению нейронных сетей как непосредственно автором, так и другими исследователями;
- результаты экспериментальных исследований, в ходе которых моделировались различные условия выполнения подписей и рукописей.
- нормативно-правовые акты, ГОСТы, регламентирующие порядок проведения судебных экспертиз, защиту персональных данных, а также документы, определяющие статус систем искусственного интеллекта в правовом поле.

**Положения, выносимые на защиту:**

1. Концепция интеграции искусственных нейронных сетей (ИНС) в систему научно-методического обеспечения судебно-почерковедческой экспертизы. Разработан модульный подход к применению ИНС в судебно-почерковедческой экспертизе, предполагающий использование

специализированных нейросетевых моделей для решения конкретных задач на различных стадиях исследования.

2. Обоснование применения «локального» и «глобального» подходов к обучению нейронных сетей при осуществлении судебно-экспертной деятельности. Системно обоснована целесообразность одновременного применения двух подходов при обучении нейронных сетей в рамках анализа объектов судебно-почерковедческой экспертизы:

- «Локальное» обучение нейросетевой модели – производится на ограниченной выборке в рамках конкретной судебно-почерковедческой экспертизы;

- «Глобальное» обучение нейросетевой модели, производимое на больших массивах обезличенных данных для создания обобщенных моделей, решающих наиболее общий спектр задач, которые могут возникнуть при интеграции ИНС в процесс экспертного исследования почерка (такие как кодирование элементов рукописи и извлечение из них признаков).

Такой подход, по мнению автора, позволяет обеспечить высокую точность, воспроизводимость и адаптивность нейросетевых алгоритмов.

3. Интерпретируемость результатов ИНС как необходимое и обязательное условие их применения в судебно-почерковедческой экспертизе. Установлено, что интерпретируемость получаемых результатов позволяет экспертам оценивать, корректировать и обосновывать свои выводы в соответствии с потребностями судебной практики.

4. Методические рекомендации по интеграции искусственных нейронных сетей в общие и частные методики судебно-почерковедческой экспертизы. В частности, разработана и предлагается следующая схема по интеграции нейросетевых алгоритмов в структуру различных методик судебно-почерковедческой экспертиза:

- 1) В общую идентификационную и диагностическую методики судебно-почерковедческого исследования предлагается интегрировать ИНС на стадиях

предварительного исследования для кодирования<sup>1</sup> рукописей и предварительного извлечения признаков почерка, аналитического анализа для выявления общих, частных и диагностических признаков в конкретной рукописи, сравнительного исследования выявленных признаков и оценки полученных результатов;

2) В частные (типовые) экспертные методики<sup>2</sup> – в качестве специализированных методов обработки данных для решения конкретных задач, возникающих на разных стадиях экспертного исследования. Среди них можно выделить:

- кластеризация и предварительный отбор наиболее пригодных образцов для сравнительного анализа;
- автоматизированное выделение диагностических признаков необычных условий выполнения подписи;
- выделение, извлечение и анализ общих и частных признаков почерка в исследуемой рукописи и образцах для сравнительного исследования;
- идентификации исполнителя подписи путем сравнения выявленных признаков с последующей оценкой полученных результатов.

При этом во всех случаях нейронные сети рассматриваются как специальные методы экспертного исследования, обеспечиваемые машинными средствами (кодировщики, алгоритмы кластеризации, сиамские сети, байесовские нейросети и др.), с обязательным соблюдением принципов научной обоснованности, законности, воспроизводимости и интерпретируемости.

Внедрение нейросетевых алгоритмов требует валидации в двух аспектах:

---

<sup>1</sup> Под процедурой кодирования мы подразумеваем процедуру фотографирования или сканирования рукописи с последующим анализом полученного изображения, чтобы получить ее цифровой аналог, в котором бы явно отражались общие и частные признаки почерка.

<sup>2</sup> В частности, в работе предлагается типовой шаблон методики, основанный на интеграции нейросетевых алгоритмов в структуру частной качественно-описательной методики идентификационного исследования подписей и рукописей.

- для «глобальных» моделей – создание верифицированных наборов данных и тестирование по схеме, предложенной Е.Р. Россинской<sup>1</sup>;

- для «локальных» нейросетевых моделей – процедурная валидация по правилам апробации экспертных методик (оценка корректности и эффективности способа решения задачи).

5. Организационно-тактическая модель внедрения ИНС в судебно-экспертную деятельность. Предложена организационная схема внедрения ИНС, предусматривающая:

- разработку методик с ИНС-алгоритмами и их валидацию;
- создание специализированного программного обеспечения;
- обучение судебных экспертов базовым навыкам работы с ИИ-инструментами без необходимости глубоких IT-компетенций.

6. Правовые и этические аспекты использования ИНС в судебной экспертизе. Обоснована допустимость использования ИНС в судебно-почерковедческой экспертизе на текущем этапе развития права, при условии соблюдения действующего законодательства о персональных данных и осуществления процедур обезличивания и соблюдения конфиденциальности.

7. Перспективы интеграции больших языковых моделей (LLM) в процессе подготовки заключений эксперта. Определены некоторые возможности применения LLM для автоматизации подготовки текстов заключений эксперта, их стилистической и логической проверки, что повышает эффективность и стандартизирует процесс оформления результатов.

8. Рекомендации по созданию единой цифровой платформы для комплексной оценки и систематизации диагностических признаков почерка. Предложен перспективный путь создания цифровой базы данных обезличенных почерков с целью улучшения нейросетевых моделей и

---

<sup>1</sup> Россинская Е.Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы // Вестник Университета имени О.Е. Кутафина (МГЮА). 2024. № 3(115). С. 21–33.

стандартизации диагностики необычных условий выполнения рукописей.

**Теоретическая значимость** результатов диссертационного исследования заключается в дальнейшем развитии судебного почерковедения, в частности положений по использованию в экспертной практике алгоритмов, построенных на нейронных сетях; их месте и роли в системе общей и частных методик судебно-почерковедческой экспертизы; практических возможностях применения данных алгоритмов при производстве судебно-почерковедческой экспертизы.

**Практическая значимость** результатов диссертационного исследования заключается в разработке и формулировании рекомендаций по внедрению нейросетевых алгоритмов в практику производства судебно-почерковедческой экспертизы, а также ориентира для разработки полноценных программных комплексов, построенных на базе нейронных сетей, для решения задач судебно-почерковедческой экспертизы.

**Апробация и внедрение результатов исследования.** Работа подготовлена на кафедре судебно-экспертной деятельности юридического института ФГАОУ ВО «Российский университет дружбы народов имени Патриса Лумумбы». Основные положения диссертационного исследования получили свое освещение в одиннадцати научных статьях автора, четыре из которых опубликованы в журналах, рецензируемых ВАК при Министерстве науки и высшего образования Российской Федерации.

Основные положения работы докладывались на следующих научных конференциях и иных мероприятиях: «We speak legal English, German, French, Spanish...»: students' annual conference, 21.11.2022, г. Москва, ФГАОУ ВО «Российский университет дружбы народов имени Патриса Лумумбы»; научно-практической конференции с международным участием «Труды профессора Р. С. Белкина как вектор развития теории и практики судебной экспертизы. К 100-летию со дня рождения ученого и педагога», 24.11.2022, г. Москва, ФГАОУ ВО «Московский государственный юридический университет имени О.Е. Кутафина»; 5-й Международной научно-практической конференции

«Дискуссионные вопросы теории и практики судебной экспертизы», посвященной столетию профессора Г. Л. Грановского, 13.04.2023 – 14.04.2023, г. Москва, ФГБОУ ВО «Российский государственный университет правосудия»; XXXV Всероссийском круглом столе «Комплексные экспертные исследования с использованием современных технологий: правовые и методические проблемы», 19.10.2023, г. Москва, ФГКОУ ВО «Московский университет Министерства внутренних дел Российской Федерации имени В.Я. Кикотя»; Международной научно-практической конференции «Криминалистика – наука без границ: традиции и новации», 30.11.2023 – 01.12.2023, г. Санкт-Петербург, ФГКОУ ВО «Санкт-Петербургский университет Министерства внутренних дел Российской Федерации»; Международной научно-практической конференции «Экспертные ошибки: современные проблемы возникновения, выявления и профилактики», 19.01.2024, г. Москва, ФГАОУ ВО «Московский государственный юридический университет имени О.Е. Кутафина»; Всероссийском круглом столе «Инновационные аспекты в экспертной практике и дидактическом процессе», 27.06.2024, г. Москва, ФГКОУ ВО «Московский университет Министерства внутренних дел Российской Федерации имени В.Я. Кикотя»; X Международной научно-практической конференции «Теория и практика судебной экспертизы в современных условиях», 30.01.2025 – 31.01.2025, г. Москва, ФГАОУ ВО «Московский государственный юридический университет имени О.Е. Кутафина».

Кроме этого, выводы диссертационного исследования используются в научно-исследовательской работе Российского федерального центра судебной экспертизы имени профессора А.Р. Шляхова при Министерстве юстиции Российской Федерации (РФЦСЭ) для разработок соответствующих методик и методических рекомендаций по интеграции искусственных нейронных сетей для исследования почерка, поскольку положения диссертационного исследования развивают основы применения нейронных сетей в судебной почерковедческой экспертизе, а также представляют собой комплекс

организационных и технологических решений по использованию нейронных сетей в качестве инновационного инструмента по вопросу об установлении лица, выполнившего подпись или рукописную запись (см. Приложение №1). Также, согласно Акту о внедрении, полученные результаты и выводы также могут быть использованы при производстве конкретных судебно-почерковедческих экспертиз после проведения комплекса валидационных испытаний и комплекса запланированных научно-методических работ совместно с отделом почерковедческой экспертизы РФЦСЭ.

**Достоверность результатов** исследования обеспечивается использованием методов научного познания, достаточным объемом эмпирического материала по тематике исследования, результатами научных работ по исследуемой тематике.

**Структура диссертации** соответствует логике проведенного исследования, определена его целью и задачами, состоит из введения, трех глав, заключения, списка сокращений, списка литературы и приложений.



# **ГЛАВА 1. ОСНОВНЫЕ ТЕОРЕТИЧЕСКИЕ ПОЛОЖЕНИЯ ИСПОЛЬЗОВАНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В СУДЕБНО-ПОЧЕРКОВЕДЧЕСКОЙ ЭКСПЕРТИЗЕ**

## **§ 1.1. Искусственные нейронные сети – понятие, виды и принципы работы. Соотношение с понятием «искусственный интеллект» и «машинное обучение»**

### **1.1.1. Искусственный интеллект – основная идея**

Прежде чем приступить к освещению основной темы настоящего диссертационного исследования, мы хотели бы уделить внимание нескольким важным аспектам, которые связаны с рассматриваемой проблематикой. В первую очередь, это базовые теоретические положения, касающиеся искусственных нейронных сетей, машинного обучения и искусственного интеллекта. Понимание этих ключевых концепций необходимо для глубокого и правильного восприятия материала, представленного в последующих разделах работы. Также оно поможет более четко понять логику исследования, полученные результаты и сделанные на их основе выводы.

Начнем с общих представлений об ИИ, которые, без преувеличения, формировались у человечества на протяжении всей его истории. Например, ещё Аристотель в своём труде «Политика» высказывал мысль об использовании в хозяйстве таких орудий труда, которые могли бы самостоятельно выполнять порученную им работу, освобождая рабов от этой обязанности<sup>1</sup>. Схожие идеи прослеживаются и в культуре Средневековья. Так, мифология сохранила свидетельства о том, что алхимики того времени пытались создать «голема» – неживое человекоподобное существо, которое

---

<sup>1</sup> Аристотель. Сочинения: В 4-х т. Т. 4 / Пер. с древнегреч.; Общ. ред. А.И. Доватура. – М.: Мысль, 1983. – С. 381.

должно было выполнять всю тяжёлую работу вместо людей<sup>1</sup>. Нельзя не вспомнить и о шахматном автомате В. Кемпелена, который был представлен широкой публике в 1769 г. в Вене<sup>2</sup>. Хотя этот аппарат и был продуктом профессионального мошенничества, он, по сути, олицетворял в себе идею «механического разума», способного анализировать ситуацию и принимать решения без помощи человека<sup>3</sup>.

Научное оформление идеи ИИ было получено только в середине XX века вместе с появлением первых электронно-вычислительных машин и иных средств компьютерной техники, а также с развитием математики и возникновением новых научных областей – кибернетика, теория информации и т. д. Одним из фундаментальных трудов в этой области стала публикация А. Тьюринга «Вычислительные машины и разум»<sup>4</sup> 1950 г., в которой он поставил вопрос: «Может ли машина мыслить?»<sup>5</sup>. В своих рассуждениях автор ставит под сомнение традиционное понимание термина «мышление», предполагая, что ЭВМ в какой-то степени также могут «мыслить», особенно если достигают определенного критического порога вычислительной мощности. Говоря формально, такая машина может имитировать деятельность, обычно присущую людям, для выполнения поставленной перед ней задачи. К примеру, это может быть общение, целью которого для машины будет убедить экзаменатора в том, что она является человеком<sup>6</sup>. Отчасти именно эта идея имитации в дальнейшем легла в основу современных представлений об ИИ.

---

<sup>1</sup> Голем / [Электронный ресурс] // Научно-образовательный портал «Большая российская энциклопедия»: [сайт]. – URL: <https://bigenc.ru/c/golem-93e841> (дата обращения: 03.01.2025).

<sup>2</sup> Шахматы: энциклопедический словарь / гл. ред. А.Е. Карпов. – М.: Советская энциклопедия, 1990. – С. 8–9.

<sup>3</sup> Это не единственные примеры «искусственного интеллекта» прошлого. Подробнее об истории ИИ до его научного оформления см. McCorduck P., Cfe C. *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*. – AK Peters/CRC Press, 2004.

<sup>4</sup> Turing A.M. *Computing machinery and intelligence*. – Springer Netherlands, 2009. – С. 23–65.

<sup>5</sup> При этом он уточняет, что речь идет в первую очередь о цифровых вычислительных машинах, т. е. компьютерах.

<sup>6</sup> А. Тьюринг в своей публикации назвал этот эксперимент «Игра в имитацию».

Сам термин «искусственный интеллект» появился только спустя некоторое время – в 1956 г. Его предложил Дж. Маккарти на Дартмутском семинаре<sup>1</sup>. Исследователь определил ИИ как машины, которые ведут себя так, словно они обладают интеллектом<sup>2</sup>. Однако уже в то время и сам термин, и его трактовка вызывали определённые вопросы. К примеру, как вспоминает Т. Мор, один из участников Дартмутского семинара, ему никогда не нравилось использование терминов «искусственный» или «интеллект<sup>3</sup>» для обозначения этой научной области<sup>4</sup>. Это вполне объяснимо, ведь сразу возникает множество вопросов:

- как понять, что у машины появился «интеллект»;
- как оценить уровень «интеллектуальности» той или иной задачи и т. д.

Например, В. Эртель в своей работе отмечает<sup>5</sup>, что если придерживаться определения ИИ, предложенного Дж. Маккарти, то можно назвать «интеллектуальным» практически любой механизм. В качестве примера он приводит так называемые «тележки Брайтенберга» – маленькие транспортные средства с двумя колесами, к каждому из которых подключён датчик света<sup>6</sup>. Принцип работы этих устройств основан на том, что при попадании света на датчики тележка начинает поворачиваться в сторону источника света или от него, в зависимости от особенностей электрической схемы, расположенной внутри. Благодаря этому мысленному эксперименту В. Брайтенберг продемонстрировал, что сложное поведение системы может быть достигнуто

---

<sup>1</sup> Это мероприятие развивает идеи А. Тьюринга, так как центральная проблема, обсуждавшаяся на Дартмутском семинаре, заключалась в возможности создания компьютеров и программного обеспечения, способных моделировать процесс обучения и решать интеллектуальные задачи.

<sup>2</sup> J. McCarthy, M.L. Minsky, N. Rochester, C.E. Shannon A proposal for the dartmouth summer research project on artificial intelligence. USA: Dartmouth. 1955. – С. 11.

<sup>3</sup> Здесь важно уточнить, что «интеллект» (intelligence) в данном случае означает «умение рассуждать разумно», а не «интеллект» (intellect) как свойство человеческого мозга (Боровская Е.В., Давыдова Н.А. Основы искусственного интеллекта: учебное пособие. 4-е изд., электрон. М.: Лаборатория знаний, 2020. – С. 6.).

<sup>4</sup> Moor J. The Dartmouth College artificial intelligence conference: The next fifty years // Ai Magazine. – 2006. – Т. 27. – №. 4. – С. 87.

<sup>5</sup> Ertel W. Introduction to Artificial Intelligence. London: Springer, 2018. – С. 1–2.

<sup>6</sup> Braitenberg V. Vehicles: Experiments in Synthetic Psychology. The MIT Press, 1986. 168 p.

с помощью использования простых элементов. Вполне очевидно, что механизмы подобного плана сложно назвать «интеллектуальными», по крайней мере в привычном понимании.

Тем не менее определение, предложенное Дж. Маккарти, на наш взгляд, достаточно хорошо отражает сущность ИИ. Машины подобного плана, равно как и заложенные в них алгоритмы работы, не являются попыткой в точности воссоздать человеческий мозг. Они лишь имитируют деятельность человека в тех или иных аспектах. Причем важно указать, что способы этой имитации могут быть разными: от простых правил и логических операций, до, собственно, нейронных сетей и иных систем машинного обучения.

При этом нельзя не заметить, что многие исследователи в своих разработках во многом опираются на последние достижения нейробиологии, нейрофизиологии и других смежных наук. К примеру, специалисты из Google в одной из своих работ пришли к выводу, что процессы обработки языковой информации в человеческом мозге и современных больших языковых моделях во многом схожи<sup>1</sup>. Более того, уже сейчас имеются экспериментальные разработки по созданию и обучению биокомпьютеров – вычислительных систем, построенных на использовании биологических компонентов<sup>2</sup>. Подобное заимствование знаний и представлений о человеческом мозге при создании машин, способных действовать автономно, вполне логично, поскольку нервная система живых существ является самым сложным средством обработки информации, известным науке. Причем он обладает удивительной гибкостью и может относительно быстро адаптироваться для достижения поставленных целей, особенно когда речь идет о выживании организма.

---

<sup>1</sup> Goldstein A. et al. A unified acoustic-to-speech-to-language embedding space captures the neural basis of natural language processing in everyday conversations // Nature Human Behaviour. – 2025. – С. 1–15.

<sup>2</sup> Cai H. et al. Brain Organoid Reservoir Computing for Artificial Intelligence // Nature Electronics. 2023. Vol. 6. No. 12. С. 1032–1039.

Однако, как справедливо отмечает Ф. Шолле: «... хотя некоторые основополагающие идеи глубокого обучения<sup>1</sup> отчасти заимствованы из науки о мозге, модели глубокого обучения не являются моделями мозга»<sup>2</sup>. Действительно, если вернуться к работе исследователей Google, то можно заметить, что современные LLM обрабатывают информацию статистически. В свою очередь в когнитивных моделях мышления человека, согласно современным представлениям, напротив, доминирует работа с символическими структурами<sup>3</sup>. Иными словами, мозг «опирается» на чёткие семантические структуры, синтаксис и иерархию слов. Однако и его «вычислительные возможности» имеют свои пределы, особенно когда речь идет о специфических задачах, для решения которых они изначально не приспособлены. Поэтому исследователям приходится разрабатывать и использовать иные, более эффективные механизмы обработки информации, которые уже базируются на положениях теории информации, теории вероятности и даже квантовых вычислениях<sup>4</sup>.

Поэтому повторимся – алгоритмы искусственного интеллекта лишь имитируют некоторые аспекты человеческой деятельности, но не копируют их в точности. Мы считаем, именно это подразумевал А. Тьюринг, задавая вопрос: «Могут ли машины мыслить?». Мышление в этом контексте следует воспринимать не как когнитивную функцию человека, а как способность ЭВМ и в целом любой вычислительной системы на основе имеющихся данных без помощи человека достигать поставленной цели вне зависимости от ее сложности. Говоря простыми словами, центральным в этом вопросе является не сам условный «механический разум», а алгоритмические средства, которые можно было бы использовать для имитации процессов принятия решения

---

<sup>1</sup> Глубокое обучение – область машинного обучения, в которой основное внимание уделяется использованию искусственных нейронных сетей для решения разных задач.

<sup>2</sup> Chollet F. Deep learning with Python. – Simon and Schuster, 2021. – С. 7.

<sup>3</sup> Marcus G. Deep learning: A critical appraisal // arXiv preprint arXiv:1801.00631. – 2018.

<sup>4</sup> Bokhan D., Mastiukova A.S., Boev A.S., Trubnikov D.N., Fedorov A.K. Multiclass classification using quantum convolutional neural networks with hybrid quantum-classical learning // Frontiers in Physics. – 2022. – Т. 10. – С. 1069985.

человеком в той или иной ситуации при решении конкретной задачи. Именно эти алгоритмы, правила и общие принципы обработки данных являются основой «машинного мышления».

Здесь мы подходим к, пожалуй, самому важному аспекту, который определяет восприятие искусственного интеллекта как в общественном сознании, так и в научной среде на каждом этапе его развития. Это задачи, которые предстоит решать с его помощью. Как указывает Я. Лекун: «Когда та или иная проблема решена, она покидает сферу искусственного интеллекта и постепенно переходит в классический набор инструментов»<sup>1</sup>. Действительно, если в качестве примера взять задачу поиска оптимального пути из пункта «А» в пункт «В», то еще в 1950-е гг. она в большей степени относилась к области, связанной с ИИ. Сегодня она легко решается благодаря системе спутниковой навигации и применению таких эффективных алгоритмов, как «метод Дейкстры» и «алгоритм А\*». Поэтому можно согласиться с Э. Ричем, который определил искусственный интеллект как: «... изучение способов сделать так, чтобы компьютеры были способны справляться с тем, что на данный момент у людей получается лучше»<sup>2</sup>.

Таким образом, в рамках настоящей работы мы рассматриваем искусственный интеллект как экспериментальную область информатики, которая стремится различными способами и подходами алгоритмизировать решение задач, с которыми на текущем этапе научно-технического развития могут справляться только люди. В этом, на наш взгляд, и заключается основная цель ИИ как научной области и идеи в целом<sup>3</sup>. Поэтому, как и в любой другой деятельности, поставленной цели можно достичь несколькими путями.

---

<sup>1</sup> Le Cun Y. Quand la machine apprend: la révolution des neurones artificiels et de l'apprentissage profond. – Odile Jacob, 2019. – С. 14–15.

<sup>2</sup> Rich E. Artificial Intelligence. New York: McGraw-Hill. 1991. – С. 3.

<sup>3</sup> 1. Мищук В.А. Соотношение понятий «искусственный интеллект» и «искусственная нейронная сеть» в судебной экспертологии // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 33–46.

### 1.1.2. Машинное обучение

Одним из подходов в рамках ИИ является машинное обучение. Чтобы лучше продемонстрировать особенности МО, для начала рассмотрим устройство и принципы работы алгоритмов автоматического рассуждения, построенных на логике и манипулировании символами формальной логики. Такие системы обычно называют «символический ИИ» или GOFAL<sup>1</sup>. Классическими представителями символического ИИ являются «экспертные системы». Самой известной из них является MYCIN, созданная в 1975 г. для диагностики заболеваний крови и выдачи рекомендаций по лечению<sup>2</sup>.




Рисунок 1. Элементы экспертной системы

Обычно экспертная система состоит из четырех блоков (рис. 1):

- 1) Данные – вводимая в компьютер информация, которую программе нужно обработать. В случае MYCIN это информация об инфекционном агенте – его форма, размеры и т. п.;
- 2) Модель представления данных – система кодировки подступающей в программу информации. Именно этот блок отвечает за хранение введенных данных и взаимодействие с ними;

<sup>1</sup> GOFAL – Старый добрый искусственный интеллект (англ. «Good old fashioned artificial intelligence»). Данный термин был введен Дж. Хоугеландом в 1985 г. (J. Haugeland Artificial Intelligence: The Very Idea. MIT Press, Cambridge, MA – 1985. – 287 pp.).

<sup>2</sup> Van Melle W. MYCIN: a knowledge-based consultation program for infectious disease diagnosis //International journal of man-machine studies. – 1978. – Т. 10. – №. 3. – С. 313–322.

3) База знаний – центральная часть экспертной системы, поскольку в ней содержится набор правил, благодаря которым алгоритм приходит к тому или иному выводу при обработке введенной в него информации. В экспертных системах эти правила обычно выражаются в виде логических операций, таких как «ЕСЛИ–ТО»;

4) Подсистема выводов – элемент, в котором, собственно, и происходит процесс обработки входных данных. Осуществляется это путем извлечения необходимых правил из базы знаний и их применения для изучения введенной информации. В MYCIN это происходит примерно следующим образом: «ЕСЛИ инфекционный организм грамотрицательный, И организм палочковидный, И организм анаэробный, ТО этот организм является (с вероятностью 60%) бактерией»<sup>1</sup>. Благодаря такому последовательному применению нужных правил MYCIN может осуществлять классификацию инфекционных агентов.

Очевидно, что принцип работы подобных алгоритмов является достаточно простым и предельно понятным. За счёт этих факторов обеспечивается высокая надежность символического ИИ. Кроме того, экспертные системы являются максимально интерпретируемыми, так как можно отследить все этапы принятия решения программой. В этом заключается их существенное преимущество.

Однако это же является и их главный недостаток – огромное количество заранее прописанных логических операций. Чтобы написать для ЭВМ весь этот набор правил, необходимо потратить большое количество времени, а также привлечь специалистов соответствующих отраслей, чтобы они объяснили «свой» алгоритм принятия решения в той или иной ситуации. И даже в этом случае нет гарантии, что в процессе эксплуатации программа не столкнётся с ситуацией, которая будет выходить за рамки всех имеющихся у нее правил. Как итог, система в лучшем случае выдаст ошибку о

---

<sup>1</sup> Le Cun Y. Quand la machine apprend: la révolution des neurones artificiels et de l'apprentissage profond. – Odile Jacob, 2019. – С. 15.



невозможности обработать входную информацию. В худшем – сделает неправильный вывод, который может повлиять на решение специалиста, использующего результаты без их анализа и оценки.

Одним из способов решения этой проблемы являются методы машинного обучения. Основная идея алгоритмов, разрабатываемых в рамках МО, заключается в предоставлении им возможности самостоятельно анализировать исходные данные, а не задавать их логику работы заранее<sup>1</sup>. Благодаря этому программа «обучается» решать поставленную перед ней задачу.

Причем процесс такого «машинного обучения» во многом похож на привычный нам. Так, в традиционном смысле обучение предполагает передачу и усвоение знаний, умений, навыков и способов познавательной деятельности человека, результатом чего становится целенаправленное изменение его поведения<sup>2</sup>. Проще говоря, когда человек чему-то учится, он воспринимает новую информацию на примерах и далее применяет её в похожих ситуациях. Ярче всего это демонстрирует процесс освоения письменности и алфавита. Сначала человек запоминает начертания каждого символа, усваивает, из каких элементов он состоит и в какой последовательности их нужно воспроизводить. После чего он тренируется писать эти символы самостоятельно.

В машинном обучении алгоритм совершает похожие действия. Сначала он изучает представленную ему информацию, а затем на её основе пытается выработать некоторые правила по её обработке. Полученные правила алгоритм использует для решения поставленной задачи. Если она была выполнена верно, алгоритм достигает своей цели. В противном случае он корректирует правила обработки данных до тех пор, пока задача не будет выполнена. Формально, это можно описать следующим образом: «... компьютерная программа обучается на опыте  $E$  относительно некоторого класса задач  $T$  и

---

<sup>1</sup> Речь идёт об алгоритме анализа конкретных данных. Сама программа в любом случае базируется на определённых базовых правилах и принципах работы.

<sup>2</sup> Задоркин В.И. Организация учебного процесса: Учебное пособие. М.: РГСУ, 2013. – С. 2.

меры качества  $P$ , если ее качество на задачах, принадлежащих  $T$ , измеренное в соответствии с  $P$ , улучшается с увеличением опыта  $E$ »<sup>1</sup>.

Важным элементом в описанном процессе являются целевые данные<sup>2</sup>. В большинстве случаев нам нужно получить конкретный результат от алгоритма. Например, это может правильная классификация набора изображений. Поэтому важно, чтобы программа изучила не только сами изображения, но и некоторые «метаданные», а именно метки, по которым можно определить, к какому классу относится каждая картинка. В силу этого процесс «обучения» сводится к такой настройке алгоритма, которая бы позволяла получать на обучающей выборке<sup>3</sup> прогнозы, максимально совпадающие с целевыми значениями. Причем такую «обученную» машину можно использовать при решении схожих задач и анализе схожей информации, даже если она не была частью обучающей выборки.

Заметим, что алгоритмы «классического» МО в большинстве случаев изучают данные через их признаки. Уточним, что судебной экспертологии признаком объекта исследования принято считать такое свойство этого объекта, которое наиболее значимо для решения задач, стоящих перед экспертом<sup>4</sup>. Соответственно, свойством объекта экспертного исследования, как пишет Р.С. Белкин, является: «сторона объекта, обуславливающая его различие и общность с другими объектами и обнаруживающая в его отношении к ним. Существенные свойства определяют качественную и количественную характеристики объекта. Свойства объекта экспертизы выражаются через признаки этого объекта»<sup>5</sup>.

<sup>1</sup> Mitchell T.M. Machine learning. – New York: McGraw-hill, 1997. – Т. 1. – №. 9. – С. 2.

<sup>2</sup> Целевые данные обычно используются в задачах, которые решаются с помощью методов супервизорного обучения, также известного как «обучение с учителем». Более подробная классификация методов машинного обучения и соответствующих классов задач, которые они решают, представлена в Приложении №2.

<sup>3</sup> Обучающая выборка – набор данных, на которых происходит обучение алгоритма.

<sup>4</sup> Хрусталеv В.Н. Теория судебной экспертизы: учебное пособие / В. Н. Хрусталеv. — М.: КноРус, 2020. — С. 111.

<sup>5</sup> Белкин Р.С. Криминалистическая энциклопедия. — М.: Мегатрон XXI, 2000. — 2-е изд. доп. — С. 224.

В машинном обучении трактовка признака в большей степени близка к понятию «свойство объекта исследования», однако имеет более широкое значение. В частности, признаком является любая информация, которая характеризует обрабатываемые алгоритмом данные. Это могут быть как строгие математические параметры объекта, такие как косинусное сходство между векторами, так и закодированные качественные признаки, как, например, цвет, форма и иные характеристики. Причём важность того или иного признака определяется в процессе обучения.

Разберем это на примере одного из распространённых алгоритмов «классического» МО – дерево решений. Его можно представить в виде графа, который начинается с одной вершины и расширяется к основанию. Основными элементами такого графа являются (рис. 2):

- узлы – вершины графа, в которых содержатся решающие правила, иными словами, логические операции. При этом различают корневой узел – первое условие решающего дерева, и внутренние узлы – последующие условия;
- «ветки» – ребра графа, которые соединяют узлы между собой и в которых записаны признаки данных;
- «листья» – финальные узлы решающего дерева, в которых содержатся целевые значения, т. е. ответы на поставленную задачу.




Рисунок 2. Упрощенная схема дерева решений

Чтобы лучше понять, как происходит обработка данных в решающем дереве, вернёмся к приведенному ранее примеру задачи о классификации инфекционных заболеваний крови. Когда анализируемый объект попадает в узел, он проходит через операцию «ЕСЛИ–ТО». Выглядит это примерно так: «Является ли организм палочковидным?». Соответственно, от каждого узла отходят две «ветки»: одна указывает на наличие признака (ответ «да»), а другая – на его отсутствие (ответ «нет»)<sup>1</sup>. Так исследуемая информация проходит от корневого узла до листьев, которые уже выдают итоговый результат.

Нельзя не заметить, что дерево решений имеет сходство с экспертной системой. Однако, как ранее описывалось, последняя опирается на заранее разработанную исследователем систему правил, применяемых в определенной последовательности. В дереве решений, напротив, эти правила создаются самим алгоритмом в результате анализа значимости различных признаков. Проще говоря, в процессе обучения программа определяет, какое условие следует разместить первым: «Является ли организм палочковидным?» или «Является ли организм анаэробным?». Расположение этих условий напрямую влияет на итоговую эффективность дерева решений.

Чаще всего для «построения» такого дерева используют функцию разбиения данных, которая и является тем самым «алгоритмом обучения». Данная функция последовательно разделяет обучающую выборку на подмножества до тех пор, пока все узлы в конце всех «ветвей» не будут объявлены «листьями». Обычно это происходит в двух случаях:

- 1) При выполнении определенного условия обучения. Например, когда достигается максимальная «глубина» решающего дерева, т.е. число уровней, на которых располагаются узлы;
- 2) Естественным образом, когда узел содержит максимальное количество объектов одного класса.

---

<sup>1</sup> При этом условия, как и сами признаки, могут быть намного сложнее.

Именно к последнему и стремится функция разделения, так как выполнение этого условия означает, что алгоритм достиг поставленной задачи. Чтобы добиться этого программой производится оценка значимости каждого признака в соответствии с определённым критерием. Наиболее распространёнными из них являются теоретико-информационный и статистический<sup>1</sup>. Эти критерии направлены на то, чтобы во время обучения на верхних уровнях дерева находились наиболее информативные признаки. Предполагается, что именно они будут служить основой для максимально эффективного разделения данных. В то же время признаки, расположенные на более глубоких уровнях, становятся менее значимыми и носят уточняющий характер.

Как можно видеть, решающие деревья являются весьма эффективным инструментом для автоматического анализа данных. Однако, подобно другим алгоритмам МО, дерево решений в значительной степени зависит от качества и количества признаков, которые предоставляет исследователь.

Безусловно, это позволяет контролировать процесс обучения. Более того, решающее дерево и другие аналогичные алгоритмы дают исследователю возможность понять, какие именно закономерности легли в основу того или иного вывода. Помимо этого, предоставление признаков, на основе которых алгоритм самостоятельно вырабатывает правила анализа данных, гораздо проще, чем написание этих правил для каждого возможного случая. Тем не менее, подбор и передача признаков компьютеру остается довольно трудоемким процессом. В связи с этим, параллельно с развитием «классического» машинного обучения, возникла идея, чтобы алгоритм не только самостоятельно обучался, но и в процессе этого обучения мог сам находить, извлекать и использовать признаки в предоставляемом наборе данных.

---

<sup>1</sup> Подробнее см. Сеницин Ф. Решающие деревья / Сеницин Ф. [Электронный ресурс] // Яндекс. Образование: [сайт]. – URL: <https://education.yandex.ru/handbook/ml/article/reshayushchiye-derevya> (дата обращения: 04.01.2025).

### 1.1.3. Искусственные нейронные сети – история и основной принцип работы

Здесь мы переходим к рассмотрению искусственных нейронных сетей и принципам их функционирования. Как и другие алгоритмы, применяемые в области искусственного интеллекта и машинного обучения, ИНС являются сложными математическими моделями, которые ищут закономерности в данных. Однако, в отличие от многих других алгоритмов, нейросети имеют свои отличительные особенности.

Идея создания искусственных нейронных сетей берет свое начало в нейробиологии и была предложена в 1943 г. У. МакКаллоком и У. Питтсом<sup>1</sup>. В своей работе они выдвинули несколько ключевых концепций, которые стали теоретической основой для дальнейших исследований в этой области.




Рисунок 3. а) Строение биологического нейрона б) Формальное описание единичного нейрона по У. МакКаллоку и У. Питтсу

Во-первых, поскольку нервную систему можно представить как сеть взаимосвязанных нейронов, чем, в принципе, она и является, то в качестве базового структурного элемента такой системы можно рассматривать единичный нейрон. Связь между нейронами осуществляется через

<sup>1</sup> McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // The bulletin of mathematical biophysics. – 1943. – Т. 5. – С. 115–133.

электрические импульсы, которые проходят по аксонам и дендритам – нервным отросткам нейрона. Сам сигнал передаётся с помощью синапсов – мест контакта аксона с мембраной другой клетки (нейрона, мышечной, железистой и др.) (рис. 3а)<sup>1</sup>. Синапс играет важную роль в системе передачи сигнала, поскольку на его поверхности в результате химических реакций определяется, будет ли следующий нейрон возбуждён или нет<sup>2</sup>.

На основе этого исследователи выдвинули следующее предположение: раз нейрон имеет два состояния, то для описания этих состояний можно использовать бинарную логику, где «0» означает отсутствие возбуждения нейрона, а «1» – его наличие<sup>3</sup> (рис. 3б). Это позволяет рассматривать нервную систему в качестве логического графа, в котором протекает передача условного «нервного импульса», т. е. информации, от одного нейрона к другому в случае возбуждения исходного нейрона.

Из этого вытекает второе положение: раз нервную сеть можно определить как логический граф, то этом случае нейрон, который является базовой вычислительной единицей этого графа, можно представить в виде логического высказывания или операции, результатом которого будет «0» или «1». Так как каждый нейрон связан с другими нейронами, целесообразно говорить о системе последовательных логических высказываний, в котором одно вытекает из другого. У. МакКаллок и У. Питтс писали об этом следующим образом: «Каждой реакции любого нейрона соответствует утверждение, выраженное в некотором простом предложении (логическое высказывание – *прим.*). В свою очередь оно либо выводит некоторое другое простое предложение, либо, в зависимости от конфигурации синапсов и порога

<sup>1</sup> Шульговский В.В. Основы нейрофизиологии // М.: Аспект пресс. – 2000. – С. 153–156.

<sup>2</sup> Бушов Ю.В., Светлик М.В., Нейрофизиология: учеб. пособие. – Томск: Издательство Томского государственного университета, 2021.

<sup>3</sup> На момент написания работы У. МакКаллоком и У. Питтсом считалось, что нейрон может иметь только два состояния. Однако позже с развитием нейробиологии было установлено, что реальные нейроны могут менять частоту импульсации в зависимости от «силы» входного сигнала (Левашов О.В. Искусственное зрение. Искусственный интеллект. Нейронные модели живых сенсорных систем / О. В. Левашов. – М.: URSS, 2022. – С. 150.).

нейрона (порог активации нейрона – *прим.*), о котором идет речь, влечет дизъюнкцию, конъюнкцию, с отрицанием или без отрицания, аналогичных предложений»<sup>1</sup>. Иными словами, на описываемом искусственном нейроне можно выполнять простейшие логические операции, такие как «И», «ИЛИ», «НЕ» и т. п., используя для этого значения состояний синапсов, которые особым образом соединяют все нейроны<sup>2</sup>.

Как итог мы имеем большую логико-вычислительную систему, работающую с бинарными значениями. Это чем-то напоминает ранее рассмотренное дерево решений, за исключением того, что нервная сеть использует не признаки, а условные сигналы в виде «0» и «1», полученные от предыдущих нейронов. Кроме того, как уже упоминалось, в нервной сети нейрон может иметь различные связи. Если в том же решающем дереве каждый узел обычно имеет только по 2 связи с другими узлами, а движение информации осуществляется в основном от корневого узла к листьям, то в нервных сетях нейрон может иметь одну, две и более связей. Причем они могут быть реализованы как с нейронами следующего уровня (слоя), так и с нейронами предыдущего.

В итоге, по утверждению авторов, такая система, состоящая из определённого количества нейронов, которые структурно организованы нужным образом для решения конкретной задачи, обладает конкретным поведением. Это означает, что для каждого логического выражения можно найти такую сеть, которая по своему «поведению» – принципам функционирования и получаемым результатам – будет соответствовать данному логическому высказыванию. Благодаря этому описанная структура может обрабатывать некоторую информацию и выдавать на нее конкретное значение.

---

<sup>1</sup> McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // The bulletin of mathematical biophysics. – 1943. – Т. 5 – С. 115–116.

<sup>2</sup> Детальное описание работы модели нейронной сети У. МакКаллока и У. Питтса см. Приложение №3.



В то же время предложенная У. МакКаллоком и У. Питтсом модель имела один серьезный недостаток – ее нельзя было обучать, а конструкция самой сети была жестко фиксированной, включая виды и количество связей между нейронами. Из-за этого, устроенная определенным образом сеть, фактически может работать только с узким спектром данных.

Тем не менее, данные положения заложили основу для математического и компьютерного моделирования нервной системы и как следствие – создание искусственных нейронных сетей. Первой подобной практической моделью стал перцептрон, который был создан и описан Ф. Розенблатом в работах за 1957–1962 гг. на ЭВМ «Mark 1»<sup>1</sup>. В настоящее время эта модель считается классической в теории нейросетей и машинном обучении.

Исследователь, базируясь на теоретических разработках У. МакКаллока и У. Питтса, а также на работе Д. Хебба, в которой он высказал предположение, что процесс обучения в человеческом мозге происходит за счет изменения силы синаптических связей между нейронами<sup>2</sup>, смог развить эти положения и смоделировать их на ЭВМ. Однако, в отличие от своих предшественников, Ф. Розенблат сконцентрировал свое внимание на числовых коэффициентах весов синапсов.

Так, У. МакКаллок и У. Питтс выделяли только два вида синаптических связей: возбуждающие, которые передают входной сигнал на нейрон, и тормозящие, которые, в случае если по ним проходит сигнал, полностью «обнуляют» весь нейрон (см. Приложение №3). В перцептроне подобного не происходит. Рассмотрим детальнее математику этого процесса (рис. 4).

---

<sup>1</sup> Справедливости ради отметим, что самая первая «компьютерная модель» нейросети была предложена М. Миньски (Minsky M. A neural-analogue calculator based upon a probability model of reinforcement // Harvard University Psychological Laboratories, Cambridge, Massachusetts. – 1952. – С. 7.). При помощи устройства, работающего на 3000 вакуумных лампах, им было смоделировано 40 нейронов. Однако с развитием средств компьютерной техники дальнейшее моделирование и обучение нейронов на электронно-вакуумных устройствах стало непрактичным.

<sup>2</sup> Hebb D.O. The organization of behavior: A neuropsychological theory. – Psychology press, 2005. – 279 с.




Рисунок 4. Схема перцептрона, упрощенная современная модель

Модель нейрона в перцептроне, так же, как и у У. МакКаллока и У. Питтса, является базовой математической единицей сети. Сам нейрон состоит из двух основных элементов: сумматора и функции активации<sup>1</sup>. Сумматор, используя поступившую в него информацию от предыдущих слоев, умножает каждое входное значение на соответствующий весовой коэффициент синапса, который можно рассматривать в качестве «силы» связи одного нейрона с другим. После этого все полученные значения суммируются. Далее, получившийся результат передается на функцию активации, которая преобразует это значение в новое, находящееся в определенном диапазоне<sup>2</sup>. В случае перцептрона использовалась пороговая функция активации, которая выдает значения «+1» или «-1»<sup>3</sup>, что можно рассматривать как ответы «Да» и «Нет».

Такая форма ответа возвращает нас к основной идее машинного обучения – поскольку в большинстве случаев мы ожидаем получить прогноз, который будет соответствовать целевому набору данных, то в случае

<sup>1</sup> Мы используем упрощенное описание перцептрона, чтобы показать основные принципы работы данного алгоритма. Полное описание устройства перцептрона см. Приложение №4.

<sup>2</sup> Функция активации также является нововведением в перцептроне, поскольку в работе У. МакКаллока и У. Питтса возбуждение нейрона происходило путем накопления сигналов и преодолением определенного порога возбуждения (см. Приложение №3–4).

<sup>3</sup> Редько В.Г. Эволюция, нейронные сети, интеллект: модели и концепции эволюционной кибернетики / В. Г. Редько; предисл. Г. И. Малинецкого. – Изд. 6-е. М.: URSS., 2009.

перцептрона можно настроить веса синапсов так, чтобы получать необходимый прогноз, не меняя при этом архитектуру самой сети.

Это именно тот постулат, который был выведен Ф. Розенблатом – настройка нейронной сети путём изменений числовых значений синапсов между самими нейронами. Благодаря этому такую сеть можно «научить» решать определённую задачу путём подбора оптимальных значений синаптических связей. Фактически подбор весовых коэффициентов представляет собой процесс формирования правил обработки информации. Причем сформированные правила в целом будут применимы и к новому набору схожих данных, на которых алгоритм не обучался. К примеру, в своих работах автор показал, что перцептрон может решать задачу распознавания простых геометрических фигур и символов латинского алфавита<sup>1</sup>.

Работает это следующим образом: в процессе обучения мы «показываем» алгоритму множество примеров, допустим изображения буквы «А», и определяем, при каких значениях весов синапсов алгоритм дает положительный ответ. После обучения модели ей можно предоставить новые данные, на которых она не обучалась, тем самым получить для них прогноз. Конкретно в примере выше мы получим прогноз, является ли символ на изображении буквой «А».

Благодаря этому в нашем распоряжении появляется алгоритм, который с определенной степенью достоверности может делать прогнозы на основе предоставляемых ему данных в рамках решения конкретной задачи. Причем для повышения точности прогнозов перцептроны можно объединять в более сложные последовательные структуры со множеством слоев – многослойные перцептроны (см. Приложение №5). Подобные системы уже могут выявлять более сложные закономерности в исследуемых данных.

Из приведенного следует очевидный вывод, что перцептрон, равно как и его «потомки», представляют собой обычные математические

---

<sup>1</sup> Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain // Psychological review. – 1958. – Т. 65. – №. 6. – С. 386–408.

вычислительные модели, которые используют входные данные для вычисления определённых выходных значений, например класса геометрической фигуры.

Однако на тот момент времени подбор оптимальных параметров модели был достаточно трудоёмкой задачей. Во-первых, тогда было популярно использовать подходы бинарной логики, что не позволяло точно настраивать синаптические связи. Во-вторых, весовые коэффициенты зачастую подбирались вручную либо при помощи алгоритмов, которые не всегда обеспечивают приемлемую точность работы. Например, для коррекции своего перцептрона Ф. Розенблат применял метод коррекции ошибки, который он разработал самостоятельно. Суть этого метода заключалась в том, чтобы не изменять значение синапса до тех пор, пока реакция нейрона остаётся верной, т. е. пока он выдаёт ожидаемое значение. Однако этот алгоритм обучения, как и многие другие, был несовершенным, поскольку они не позволяли обучать «глубокие» нейронные сети – сети с одним или несколькими «скрытыми» слоями нейронов, расположенными между входным и выходным слоями. Из-за этого приходилось ограничиваться моделями с двумя-тремя слоями.

Всё изменилось в середине 1980-х гг., когда Д. Румельхарт, Дж. Хинтон и Р. Вильямс предложили использовать в качестве алгоритма автоматического нахождения оптимальных значений весов синапсов метод обратного распространения ошибки<sup>1</sup>. Как уже упоминалось ранее, при обучении нейронной сети обычно используется обучающая выборка и целевой набор данных. Напомним, что целевой набор данных представляет собой желаемые значения, которые мы стремимся достичь при анализе обучающей выборки.

Идея, которую предложили исследователи, заключалась в вычислении разницы между результатами работы искусственной нейронной сети и целевым набором данных. Иными словами, предлагалось оценить, насколько ИНС ошибается. Значение этой ошибки потенциально можно было бы

---

<sup>1</sup> Rumelhart D.E., Hinton G.E., Williams R.J. Learning representations by back-propagating errors // Nature. – 1986. – Т. 323. – №. 6088. – С. 533–536.

использовать для коррекции весов синапсов. Чтобы реализовать эту идею, авторы отказались от бинарной логики и перешли к использованию чисел с плавающей точкой. Из-за этого была изменена и функция активации, которая стала нелинейной, в отличие от линейной пороговой функции перцептрона (см. Приложение №5).




Рисунок 5. Упрощенная схема градиентного спуска

Надо заметить, что для определения степени коррекции весов исследователи использовали не само значение ошибки, а производную функции потерь. Эта функция, которая рассчитывается по всем весам нейронов и показывает, как сильно отличается прогноз нейросети от целевых данных. Применение производной обусловлено тем, что она не только указывает на степень коррекции каждого отдельного нейрона, но и определяет направление этой коррекции: увеличивает или уменьшает первоначальное значение веса синапса (рис. 5). Благодаря этому производная от функции потерь позволяет определить, насколько сильно нужно изменить значение синапса и в каком направлении.

Однако изменение этих значений до оптимальных происходит не с первого раза, поскольку посчитанные градиенты – то самое значение производной функции потерь – первоначально слишком сильно их корректируют. В то же время, с каждой новой итерацией разница между

прогнозами ИНС и целевым набором данных уменьшается. Как следствие, уменьшается и величина изменений в весах синапсов. Описанный метод известен как «градиентный спуск», потому что он позволяет нейросети «спускаться» к минимуму ошибки по целевой функции, которой является сама сеть. Как итог, весь процесс обучения представляет собой повторение описанного выше алгоритма в течение нескольких циклов, называемых эпохами обучения.

В настоящее время метод обратного распространения ошибки занимает центральное место в теории искусственных нейронных сетей. Он позволяет обучать сети, состоящие из множества слоёв нейронов, что значительно повышает их точность. Благодаря этому сеть способна учитывать при прогнозировании множество различных закономерностей, содержащихся в данных.

Обобщая вышеизложенное, можно сказать, что современная теория искусственных нейронных сетей основывается на таких ключевых вещах как: коэффициенты весов синапсов, вычисление степени ошибки, метод градиентного спуска и ряде других параметров. Однако современные ИНС отличаются более совершенными методами вычислений и подходами к обучению и построению архитектуры.

#### **1.1.4. Современные подходы проектирования архитектуры нейронных сетей. Основная классификация**

Сегодня существует множество способов построения нейронных сетей, в которых используются разнообразные методы обработки данных. Это разнообразие привело к появлению множества оснований для классификаций ИНС. Одна из самых распространенных – классификация по типу решаемых задач. Она охватывает такие области как: обработка естественного языка, компьютерное зрение и многие другие. Также стоит упомянуть

классификацию по способу обучения: с учителем, без учителя и обучение с подкреплением<sup>1</sup>.

Мы постараемся максимально подробно описать различные подходы к созданию архитектуры нейросетей. Для удобства классифицируем их по степени обобщенности и субординации. Основываясь на этом критерии, современные ИНС можно разделить на следующие категории:

1) Искусственные нейронные сети как один из методов машинного обучения<sup>2</sup> – данная категория характеризует все нейронные сети и определяет, как и по каким принципам они работают. Как говорилось ранее, ИНС не являются единственным подходом в области искусственного интеллекта. Однако это не означает, что нейросетевые алгоритмы существуют обособленно. На практике они часто используются совместно с другими методами машинного обучения. Последние, как правило, играют роль дополнительных инструментов на финальных этапах обработки данных, когда необходимо выполнить конкретную задачу, имеющую свою специфику. В то же время, основной объем вычислений ложится на нейросетевые модели.

2) Общая архитектура – этот уровень классификации описывает общий подход к созданию архитектуры для определённых групп моделей ИНС<sup>3</sup>. Например, сюда можно отнести сверточные нейронные сети, рекуррентные сети, полносвязные и т. д. Можно сказать, что это упрощённая модель какого-либо подхода. В настоящее время существует множество подобных систем и вычислительных приёмов. Среди основных можно выделить следующие<sup>4</sup>:

---

<sup>1</sup> Частично было рассмотрено ранее, см. Приложение №2.

<sup>2</sup> Ростовцев В.С. Искусственные нейронные сети: учебник для вузов / В. С. Ростовцев. 2-е изд., стер. Санкт-Петербург: Лань, 2021. – 216 с.

<sup>3</sup> Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2017. Т. 6, № 3. С. 28–59.

<sup>4</sup> Здесь мы не будем описывать все возможные архитектуры искусственных нейронных сетей. В следующих разделах работы мы еще уделим внимание некоторым специфичным нейросетевым моделям, таким как сиамские ИНС. Однако более полный список возможных архитектур нейросетей можно найти, например, в работе Alzubaidi L. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions // Journal of big Data. – 2021. – Т. 8. – С. 1–74., и в Приложении №6.

2.1) Многослойные полносвязные нейронные сети – данный вычислительный подход является практически прямым «потомком» перцептрона Ф. Розенблата (см. Приложение №5). Благодаря переходу на числа с плавающей точкой, а также добавлению нелинейной функции активации и использованию метода обратного распространения ошибки, современные FC-модели способны обрабатывать достаточно большие массивы информации.

В то же время они являются очень затратными в плане производимых вычислений, поскольку каждый нейрон связан со всеми нейронами предыдущего и последующего слоя сети. Из-за этого в памяти компьютера необходимо хранить большой массив коэффициентов весов синапсов. Помимо этого, во время коррекции всех этих весов необходимо производить математические операции над каждым отдельным параметром, что и порождает объемный массив вычислений.

Вследствие этого на текущей момент полносвязные нейронные сети самостоятельно практически не используются. Обычно их применяют либо в качестве небольших субмодулей в одной большой ИНС, где нужно проводить небольшой объем конкретных вычислений с конкретными фрагментами данных, либо на финальных стадиях обработки, когда количество нейронов обычно является небольшим. В качестве примера можно привести использование линейного полносвязного классификатора в сверточных нейронных сетях, речь о которых идет ниже.

2.2) Сверточные сети – впервые данный вычислительный метод был предложен в начале 1980-х гг. К. Фукусима<sup>1</sup> и позже существенно развит Я. ЛеКуном<sup>2</sup>. Однако массовое распространение, особенно в области компьютерного зрения, они получили только с 2010-х гг., так как до этого

---

<sup>1</sup> Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position // Biological cybernetics. – 1980. – Т. 36. – №. 4. – С. 193–202.

<sup>2</sup> LeCun Y. et al. Backpropagation applied to handwritten zip code recognition // Neural computation. – 1989. – Т. 1. – №. 4. – С. 541–551.



компьютерно-технические средства не могли эффективно производить множество параллельных вычислений, которые активно применяются в CNN.

Если говорить об общей архитектуре таких систем, то основной принцип их работы лежит в проведении операции «свертки» N-мерного тензора, который подаётся в сеть. Разберем это детальнее на примере обработки изображения. Тензором в теории ИНС обычно принято называть структурированный определённым образом массив данных (см. Приложение №7). К примеру, 2-мерным тензором является математическая матрица. В случае изображения тензор будет уже 3-мерным, где 2 измерения – это длина и ширина изображения, тогда как 3 измерение – количество цветовых каналов, которых может быть как один, т. е. монохромное изображение, так и 4 в случае RGBA кодировки.




Рисунок 6. а) Операция свертки. б) Операция pooling

Суть операции свертки заключается в последовательном «наложении» небольшого фильтра (ядра свертки), представляющего собой матрицу N-размера, на отдельные участки обрабатываемого тензора (рис. 6а). При наложении фильтра на какой-то участок происходит покомпонентное умножение значений фильтра и значений тензора, попавших в фильтр, с последующим их суммированием. За счет этого вычисляется новая матрица. После того как фильтром были «изучены» все участники данных, полученные матрицы объединяются в единый тензор, благодаря чему на выходе получается

новое представление о данных, которое характеризует их основные параметры – карта признаков. Как правило, на одном сверточном слое применяется не один, а несколько фильтров с разными параметрами. Это позволяет получить максимальное представление об исследуемых данных.

Зачастую после свертки применяют операцию pooling – процедура уменьшения пространства признаков путем выделения максимальных (max-pooling) либо средних (avg-pooling) значений в матрице (рис. 6б). Благодаря этой операции происходит уменьшение пространства полученной карты признаков с целью выделения наиболее важной информации, что способствует уменьшению количества дальнейших вычислений.

При этом, несмотря на большое количество производимых над тензорами операций, сам процесс обучения CNN проще в части оптимизации весовых коэффициентов, поскольку ими являются числовые значения в ядре свертки. Так, для первичной обработки изображения размером  $28 \times 28$  пикселя в FC-сети потребуется использовать 784 входных нейрона, что уже составляет минимум 784 параметра сети. В CNN при использовании 12 фильтров размером  $3 \times 3$  потребуется всего 108 параметров. Причем CNN, в отличие от FC-моделей, могут учитывать и пространственную информацию в виде взаиморасположения элементов изображения. Благодаря этому CNN выступают в большинстве случаев как механизм упрощения сложных данных, оставляя при этом только наиболее важную информацию, которую уже используют иные системы, к примеру описанный полносвязный классификатор (см. Приложение №8).




Рисунок 7. а) Общая схема RNN. б) Внутреннее устройство блока RNN

2.3) Рекуррентные сети – в современном исполнении сети данного типа были описаны Й. Бенжио, П. Симаром и П. Фраскони<sup>1</sup>, хотя до этого схожая конструкция была предложена Дж. Хопфилдом<sup>2</sup>. В отличие от полносвязных и сверточных сетей, архитектура RNN имеет уникальную особенность. Она состоит из одного блока, который имеет один входной и один выходной каналы, а также один «внутренний» канал, замыкающийся на самом блоке RNN (рис. 7а). Такая структура была разработана специально для работы с последовательностями данных.

Обычные FC-модели в целом тоже могут работать с последовательностями данных, однако в этом случае они не будут учитывать взаиморасположение элементов последовательности друг относительно друга. В свою очередь при решении некоторых задач, в частности в машинном переводе, учет взаимного позиционирования элементов является очень важным фактором, поскольку в противном случае мы рискуем получить неточные результаты.

Принцип работы RNN как раз основан на том, чтобы постепенно, по одному элементу, анализировать всю последовательность. Обычно в качестве таких элементов выступают токены – минимальные элементы цепочки данных. В контексте машинного перевода токеном может быть отдельный символ, группа символов, слово или словосочетание, в зависимости от конкретной задачи. Сам процесс обработки одного токена мало чем отличается от полносвязной сети. Входной токен преобразуется в вектор, после этого он умножается на матрицу весов модели. Далее применяется функция активации и полученное значение умножается на матрицу весов, предназначенную для вывода результата. На этом процесс обработки одного токена заканчивается.

---

<sup>1</sup> Bengio Y., Simard P., Frasconi P. Learning long-term dependencies with gradient descent is difficult // IEEE transactions on neural networks. – 1994. – Т. 5. – №. 2. – С. 157–166.

<sup>2</sup> Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities // Proceedings of the national academy of sciences. – 1982. – Т. 79. – №. 8. – С. 2554–2558.

Однако, поскольку мы имеем дело с последовательностью данных, нам нужно знать, какие элементы уже были обработаны. Иными словами, необходим весь контекст обрабатываемых данных. Для этих целей и нужна указанная «внутренняя» связь, которая замыкается на самом нейроне. Дело в том, что значение, полученное после применения функции активации, сохраняется в блоке RNN, выступая в роли «внутренней памяти».

Когда происходит обработка следующего токена, к вектору «памяти» применяется собственная матрица весов, после чего полученное значение и входные данные перед применением функции активации объединяются в единый массив (рис. 76). После применения функции активации выходное значение обновляет состояние «внутренней памяти», и вся процедура повторяется, только уже для нового входного токена. При этом значения весовых матриц для входа, выхода и «внутренней памяти» являются единым для всех элементов последовательности. Именно поэтому RNN на схемах обычно изображают в виде одного блока, хотя фактически при обработке последовательности этот блок «разворачивается» в цепочку однотипных блоков, в которых меняется только состояние «памяти». По этой причине рекуррентные нейронные сети весьма затратны в вычислительном плане, поскольку им приходится хранить в себе массивные вектора и обрабатывать большие объемы информации.

Кроме того, RNN обладают еще одним существенным недостатком – они имеют свойство «забывать» уже обработанную информацию. Связано это с тем, что при обработке длинных последовательностей вектор внутреннего состояния изменяется до такой степени, что при анализе последних токенов в векторе памяти уже почти не содержится никакой информации о первых токенах.




Рисунок 8. Схема LSTM. Внутреннее устройство.

Вследствие этого З. Хохрайтер и Ю. Шмидхубер предложили модификацию RNN – сеть с долгой краткосрочной памятью (рис. 8)<sup>1</sup>. В отличие от RNN, LSTM использует в вычислениях еще один элемент – вектор состояния ячейки, который просто периодически обновляется при обработке новой информации. При этом, для правильного обновления и использования внутренней информации используется три специальных фильтра:

- фильтр забывания – именно он взаимодействует с вектором состояния ячейки и на основе вектора текущей «памяти» и новых входных данных определяет, какую информацию стоит сохранить, а какую «забыть»;
- фильтр входного слоя – работает непосредственно с входной информацией и определяет, какие значения необходимо обновить;
- фильтр выходного слоя – определяет, какую информацию следует выводить.

На практике сети LSTM проявили себя очень хорошо, что сделало их и их модификации одними из самых популярных моделей для работы с последовательностями до недавнего времени.

2.4) Нейронные сети с механизмом внимания – являются новым подходом в проектировании архитектуры ИНС, который был предложен Д. Богдановым, К. Чо и Й. Бенжио<sup>2</sup> в 2014 г. Свое начало эта идея берет из машинного перевода, в которой существовала проблема точности перевода при использовании RNN и LTSM. Суть в том, что когда мы пытаемся преобразовать

<sup>1</sup> Hochreiter S., Schmidhuber J. Long short-term memory // Neural computation. – 1997. – Т. 9. – №. 8. – С. 1735–1780.

<sup>2</sup> Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate // arXiv preprint arXiv:1409.0473. – 2014.

одну последовательность в другую, например, перевести исходное предложение на другой язык, то при использовании этих архитектур нейронной сети нам приходится «сжимать» всю последовательность до вектора фиксированной длины. На основе этого вектора делается вероятностный прогноз, какой может быть выходная последовательность. Как показала практика, такие преобразования не всегда являются точными, особенно когда необходимо работать с длинными предложениями.




Рисунок 9. а) Схема механизма адитивного внимания, предложенного в 2014 г. для обработки последовательностей в RNN б) Визуализация семантических связей между словами, выявленных при помощи механизма внимания во время перевода

Поэтому, чтобы улучшить качество перевода, было предложено использовать промежуточные значения, которые получаются при обработке каждого элемента входной последовательности. Полученные вектора «памяти» затем преобразуются в единый вектор контекста с помощью весов, которые вычисляются на основе предыдущего вектора переведённого слоя и текущего внутреннего состояния сети (рис. 9а). Вычисленный таким образом вектор контекста обычно демонстрирует взаимосвязь между элементами последовательности (рис. 9б).

Говоря простыми словами, нейросеть с механизмом внимания начинает работать примерно также, как человек, когда переводит предложение: вместо того, чтобы один раз «прочитать» и по памяти перевести предложение, нейросеть при помощи вектора контекста начинает выделять наиболее значимые слова во всем предложении, которые на текущем этапе перевода необходимо использовать.

Благодаря этому идея использования attention в нейронных сетях получала широкое распространение, причем не только в сфере машинного перевода, но и при обработке изображений. Так, одной командой исследователей было установлено, что использование механизма внимания при преобразовании изображений в их текстовое описание позволяет интерпретировать, какой именно участок картинки соответствует тому или иному слову<sup>1</sup>.

Отдельно стоит упомянуть разработку команды исследователей из Google Brain под названием Transformer<sup>2</sup>. В данной сети не используются рекуррентные или сверточные блоки. Вместо этого там применяются только блоки с механизмом внимания, которые основаны на небольших полносвязных ИНС и вычислении скалярного произведения входных данных, из-за чего данный вид attention также называют самовниманием (Self-attention) (см. Приложение №9).

Необходимо уточнить, что механизм внимания является сравнительно новым подходом в обработке информации, в связи с этим эта область еще активно развивается. Поэтому сегодня существует большое количество вариаций и предложений по реализации attention в нейростях (см. Приложение №10).

5) Генеративные и генеративно-состязательные сети – фактически сети данного рода в своей основе используют описанные ранее подходы. Разница

---

<sup>1</sup> Xu K. et al. Show, attend and tell: Neural image caption generation with visual attention // International conference on machine learning. – PMLR, 2015. – С. 2048–2057.

<sup>2</sup> Vaswani A. et al. Attention is all you need // Advances in neural information processing systems. – 2017. – Т. 30.

состоит только в том, что в случае генеративных сетей мы не анализируем большой массив данных, упрощая его до пригодных в работе значений, а наоборот, из вектора или матрицы создаем новую информацию, например изображение. Иными словами, генеративные сети реализуют обратную процедуру обработки данных. Это очень удобно, поскольку в этом случае мы можем преобразовывать один тип данных, к примеру текст, в другой – изображение.

Кроме этого, можно имитировать некоторые исходные данные – для этих задач обычно используются генеративно-сопоставительные сети. Структура GAN состоит из двух самостоятельных, но в то же время взаимосвязанных между собой, вычислительных блоков – генератора и дискриминатора.

В задачу генератора, как ясно из названия, входит генерация новых данных, к примеру новых изображений, на основе эталонного набора данных, являющихся «подлинником». Дискриминатор напротив, использует эталонные данные для того, чтобы отличить их от создаваемых генератором «подделок». Благодаря этому обучение этих двух подсистем происходит совместно, и каждая из них влияет на эффективность противоположной подсистемы. К примеру, если дискриминатор хорошо отличает «оригинальный» набор данных от «поддельного», происходит коррекция весов в генераторе. В противном случае происходит корректировка дискриминатора. Этот подход в создании нейросетей был описан в 2014 г. Я. Гудфеллоуи<sup>1</sup> и в настоящее время обычно используется для создания синтетических данных в целях обучения других нейросетей, когда исходно информации недостаточно.

3) Частная архитектура – это модели, разработанные для решения определённого вида задач, использующие в качестве основы определённые типы нейросетей, обозначенных выше. К примеру, нейросети VGG 19 и VGG 16 решают одну и ту же задачу – распознавание изображений. Они имеют схожий принцип построения, типы используемых слоёв и их

---

<sup>1</sup> Goodfellow I. et al. Generative adversarial nets // Advances in neural information processing systems. – 2014. – Т. 27.



последовательность. Отличие заключается только в количестве слоёв. Модели ResNet тоже выполняет задачу по распознаванию изображений, однако типы и последовательность слоёв отличается от моделей VGG. Таким образом ResNet и VGG хоть глобально и относятся к CNN, однако подходы в их проектировании являются разными.

4) Конкретная модель – это нейронная сеть, разработанная в рамках решения конкретной задачи и имеющая определённую архитектуру и конкретные параметры.

Мы рассмотрели ключевые подходы к созданию архитектуры нейронных сетей, но это далеко не полный список. В настоящее время активно изучаются и применяются сиамские нейронные сети, байесовские нейросети<sup>1</sup>, сети Колмогорова–Арнольд, а также подходы, основанные на нейроэволюции, и многие другие.

Однако из вышеизложенного можно сделать вывод, что ИНС прошли долгий путь от простых алгоритмов, выполняющих простые логические операции, до сложных систем, способных обрабатывать огромные массивы данных и анализировать разнообразную информацию. Благодаря процессу «обучения» эти программы значительно превосходят обычные алгоритмы в ряде областей. Тем не менее, нейросети остаются обычными математическими моделями, которые эффективно решают конкретные задачи.

---

<sup>1</sup> Chopra P. Making Your Neural Network Say «I Don't Know» – Bayesian NNs using Pyro and PyTorch // Medium: [сайт]. URL: <https://towardsdatascience.com/making-your-neural-network-say-i-dont-know-bayesian-nns-using-pyro-and-pytorch-b1c24e6ab8cd> (дата обращения: 03.08.2024).

## **§ 1.2. История внедрения и применения искусственных нейронных сетей и программных комплексов ЭВМ в судебно-почерковедческой экспертизе**

### **1.2.1. Основные периоды и общие положения**

Говоря об истории любой научной проблемы, обычно принято выделять отдельные периоды её развития. Как правило это делается для того, чтобы продемонстрировать, как изменялись взгляды и подходы к её решению на протяжении времени. Такой исторический анализ позволяет понять, как проблема развивалась, что помогает глубже осознать её современное состояние, а также выявить тенденции и перспективы дальнейшего исследования. Кроме того, это помогает обнаружить интересные идеи, которые по каким-то причинам не получили должного внимания в своё время.

В связи с этим мы также решили рассмотреть историю внедрения и использования искусственных нейронных сетей и других программных комплексов ЭВМ в судебно-почерковедческой экспертизе. Основываясь на различных исследованиях в этой сфере, а также на общих тенденциях развития нейросетевых алгоритмов и судебного почерковедения в целом, мы выделили несколько ключевых этапов развития рассматриваемой проблематики:

1) Появление идеи и её активное развитие (конец 1950-х – начало 1970-х гг.). На этом этапе, в связи с бурным развитием компьютерной техники, кибернетики и появлением перцептрона, некоторые исследователи начали задумываться о возможности использования программных комплексов ЭВМ для решения задач, связанных с анализом почерка. В этот период во многом была заложена методологическая основа и сформировано общее представление о том, как потенциально можно интегрировать эти системы в СПЭ и что это в принципе возможно.

2) Спад интереса к научной теме (середина 1970-х гг.). Данный процесс обусловлен двумя основными причинами. Во-первых, компьютеры того времени были технически несовершенны, дорогостоящими и сложными в

эксплуатации. Во-вторых, в это время, а именно в 1969 г., в публикацию вышла работа М. Минского и С. Пейперта «Перцептрон»<sup>1</sup>. В ней они высказались с резкой критикой данного алгоритма, вследствие чего интерес к нейросетям значительно спал, особенно в странах Европы и Америки.

3) Возрождение интереса и отдельные разработки (начало 1980-х — 2010-е гг.). На данном этапе наблюдается новый всплеск интереса к научным изысканиям, посвящённым использованию нейросетей и компьютерных технологий в почерковедении. Этот интерес можно объяснить как минимум двумя причинами. Во-первых, широкое распространение и доступность компьютерных технологий способствовали их активному применению во многих сферах жизнедеятельности общества. Во-вторых, в это время был разработан метод обратного распространения ошибки, который мы уже обсуждали ранее. Он стал ключевым для эффективного обучения нейросетей, что позволило применять их для решения прикладных задач. В результате этих факторов появилось множество различных разработок и исследований в этой области. Кроме того, именно в этот период область применения информационных технологий в судебно-экспертной деятельности сформировалась в полноценное научное направление в рамках судебной экспертологии и криминалистики.

4) Современный период (начинается с 2012–2014 гг.). Этот этап мы выделили отдельно в силу специфики развития искусственных нейронных сетей. Хотя за период с 1980-х по 2010-е гг. были достигнуты определённые успехи в проектировании и применении ИНС, однако эти алгоритмы оставались и во многом остаются технически сложными, из-за чего для их обучения требуется значительный объем ресурсов компьютера. В то же время, с увеличением вычислительной мощности современных компьютеров средств, особенно графических процессоров, обучение нейросетей стало более эффективным. Это связано с тем, что многие вычисления в процессе обучения

---

<sup>1</sup> Minsky M., Papert S. A. Perceptrons, reissue of the 1988 expanded edition with a new foreword by Léon Bottou: an introduction to computational geometry. – MIT press, 2017.

могут выполняться параллельно, и именно GPU лучше всего подходят для этого<sup>1</sup>.

Благодаря этому появилась возможность усложнять архитектуры ИНС. В частности, стали более эффективно использоваться системы, предложенные в конце 1980-х – начале 1990-х гг., такие как CNN, RNN и LSTM, которые ранее не были широко распространены. Кроме того, увеличение вычислительной мощности дало возможность реализовать новые подходы к обработке данных на основе существующих способов вычисления и методов машинного обучения. Например, сейчас активно развиваются методы нейроэволюции, различные механизмы внимания и более сложные байесовские нейронные сети. Эти факторы во многом стали основой для нового эффективного подхода к созданию искусственных нейронных сетей, который в настоящее время продолжает активно развиваться.

Все перечисленные достижения можно назвать «Второй революцией» в области использования нейронных сетей. Одним из ярких примеров этого являются результаты конкурса программного обеспечения ILSVRC<sup>2</sup>, где в 2012 г. частота ошибок при распознавании изображений нейронной сетью AlexNet составляла всего 15.3%<sup>3</sup>, а в 2015 году — 3.57%<sup>4</sup>. Как указывает А. Карпати, этот результат превосходит показатели человека, который в среднем допускает около 5% ошибок при классификации изображений<sup>5</sup>.

Как можно заметить, представленные нами этапы развития и применения ИНС и иных программных комплексов в области судебно-

---

<sup>1</sup> Исключением являются специализированные сервера, суперкомпьютеры, а также тензорные и нейронные процессоры, которые ещё сильнее ускоряют процесс обучения ИНС. Это позволяет обучать более сложные сети с использованием колоссальных массивов данных. Однако данные устройства являются специализированными и в настоящее время широко не распространены.

<sup>2</sup> ImageNet Large Scale Visual Recognition Challenge – Масштабная задача ImageNet по визуальному распознаванию объектов.

<sup>3</sup> Krizhevsky A., Sutskever I., Hinton G. E. Imagenet classification with deep convolutional neural networks // Advances in neural information processing systems. – 2012. – Т. 25.

<sup>4</sup> He K. et al. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – С. 770–778.

<sup>5</sup> Karpathy A. What I learned from competing against a ConvNet on ImageNet // Andrej Karpathy Blog. – 2014. – Т. 5. – С. 1–15.

почерковедческой экспертизы во многом пересекается с этапами информатизации и компьютеризации судебной экспертизы и судебно-экспертной деятельности<sup>1</sup>. В то же время, по перечисленным выше причинам, некоторые из периодов в силу специфики развития самих нейросетей были выделены отдельно.

Следует также подчеркнуть, что мы рассмотрели лишь общие тенденции этого научного направления. Если обратить внимание на развитие этой темы в отдельных странах и регионах, то можно заметить, что оно происходило неравномерно. Собственно, на примере отдельных исследований разных временных периодов рассмотрим это более детально.

### **1.2.2. Искусственные нейронные сети в судебном почерковедении – возникновение идеи**

Как отмечалось ранее, идея применения компьютерных программ для исследования почерка датируется концом 1950-х гг. – началом 1970-х гг. Во многом интерес к данной теме возник на фоне развития средств компьютерной техники, а также появлением кибернетики – науки об общих закономерностях получения, хранения, преобразования и передачи информации в сложных управляющих системах, будь то машины, живые организмы или общество<sup>2</sup>. Новая научная область стала достаточно быстро внедряться во многие области жизни общества, и правоохранительная деятельность, включая криминалистику и судебную экспертизу, не стала исключением<sup>3</sup>.

<sup>1</sup> Россинская Е.Р. Теория информационно-компьютерного обеспечения судебно-экспертной деятельности как новая частная теория судебной экспертологии // Вестник Университета имени ОЕ Кутафина. – 2022. – №. 2 (90). – С. 27–40.

<sup>2</sup> Амосов Н.М. Энциклопедия кибернетики / Н.М. Амосов, И.А. Артеменко/Отв. ред. ВМ Глушков // Киев: Укр. сов. энцикл. – 1974. – С. 440.

<sup>3</sup> Ярким примером этого являются проводимые в этот период конференции, по результатам которых выходили, например, следующие сборники и научные издания: Проблемы правовой кибернетики / Науч. совет по комплексной проблеме «Кибернетика» АН СССР. Секция «Кибернетика и право». Центр науч.-исслед. ин-т судебных экспертиз Юрид. комис. при Совете Министров РСФСР. Ин-т государства и права АН СССР...; Под общ. ред. В. Н. Кудрявцева и А. Р. Шляхова, М., 1968.; 44. Правовая кибернетика / Ред. коллегия: В. Н. Кудрявцев (отв. ред.) и др. М.: Наука, 1970. – 334.

Началом этого процесса можно считать работу Ф. Розенблатта. Напомним, что разработанный им перцептрон мог распознавать буквы латинского алфавита, что в целом можно отнести к области изучения почерка. Вследствие этого, данную разработку можно считать отправной точкой в исследовании проблематики внедрения и применения программных комплексов ЭВМ в сферу анализа почерка. В то же время, хоть работа автора и вызвала немалый интерес в сфере кибернетики и информационных технологий, в зарубежной криминалистике и области исследования письма она оказалась незамеченной<sup>1</sup>. В результате этого криминалистика зарубежных странах не применяла нейросети и иные компьютерные программы для анализа почерка вплоть до конца 1980-х – начала 1990-х гг.<sup>2</sup>

Однако исследование Ф. Розенблатта привлекло внимание советских учёных-криминалистов. Так, в период с 1962 по 1965 гг. было опубликовано несколько статей, посвящённых возможности использования перцептрона в практике производства судебно-почерковедческих экспертиз. Среди наиболее значимых работ этого времени можно выделить исследование Р.М. Ланцмана<sup>3</sup>, Б.Н. Козинец и В.А. Якубовича<sup>4</sup>. В основе их разработок лежали следующие идеи:

– Во-первых, необходимость создания такого ЭВМ и программного комплекса к нему, который мог бы моделировать зрительное восприятие

---

<sup>1</sup> Следует уточнить, что речь в первую очередь идет о научных исследованиях, которые проводились в основном в странах Западной Европы, Северной Америки и частично Японии. Это связано с двумя причинами. Во-первых, страны социалистического блока ориентировались прежде всего на научные достижения СССР. Криминалистика здесь не является исключением. Во-вторых, за период с 1950-х до 2000-х годов автором не было обнаружено научных работ из стран других регионов, которые были бы посвящены разработке и внедрению искусственных нейронных сетей и других программных комплексов ЭВМ в область судебно-экспертной деятельности, включая почерковедение.

<sup>2</sup> The Expert Working Group for Human Factors in Handwriting Examination, Forensic Handwriting Examination and Human Factors: Improving the Practice Through a Systems Approach, U.S. Department of Commerce, National Institute of Standards and Technology – 2021.

<sup>3</sup> Ланцман, Р.М. Кибернетика и криминалистическая экспертиза почерка / Р.М. Ланцман. М.: Наука, 1968. – 95 с.

<sup>4</sup> Козинец Б.Н., Ланцман Р.М., Якубович В.А. Об одном кибернетическом методе исследования в криминалистической экспертизе почерка // Кибернетика и судебная экспертиза. – Вильнюс: НИИСЭ. – 1966. – №. 2. – С.55–84.

эксперта-почерковеда. Как показывают современные исследования в области нейробиологии, нейроны зрительной коры головного мозга на ранних этапах обработки, предположительно, «расчленяют» видимое глазом изображение на части в виде простейших геометрических форм, и «сообщают» о найденных признаках дальше – в систему зрительного узнавания<sup>1</sup>. Такое разделение существенно помогает выявлять важную информацию в объекте, что как следствие повышает степень его узнаваемости среди всех остальных вещей, в том числе и схожих;

– Во-вторых, созданная машина должна иметь возможность «обучаться». Обусловлено данное положение таким свойством почерка, как вариационность<sup>2</sup>. Вследствие этого первоначальной задачей в обработке компьютером рукописи видится в обнаружении общих закономерностей почерка как в большом массиве данных. Выявление этих закономерностей позволяет на их основе отличать одни рукописные образцы от других. Р. М. Ланцман писал об этом следующее: «Научившись их (закономерности/признаки почерка – *прим.*) различать, (программа – *прим.*) проводила распознавание, т. е. относил исполнение исследуемых объектов к лицам, образцы почерка которых она запомнила»<sup>3</sup>.

– В-третьих, важным принципом во всей описанной системе «обучения» становится самостоятельность ЭВМ в решении поставленной задачи. Такой подход, по мнению авторов, позволяет машине независимо от человека выделять наиболее значимые для формирования вывода признаки почерка. Это позволяет системе не копировать действия и процедуру принятия решений эксперта-почерковеда, которые не всегда могут быть верными. Как в

---

<sup>1</sup> Левашов О.В. Искусственное зрение. Искусственный интеллект. Нейронные модели живых сенсорных систем / О.В. Левашов. – М.: URSS, 2022. – С. 33–35.

<sup>2</sup> Вариационность почерка – устойчивое видоизменение почерка одного и того же лица, проявляющееся в его рукописях как результат приспособления письменного-двигательного функционально-динамического комплекса навыков к различным условиям выполнения рукописей (ГОСТР 59508–2021 «Судебно-почерковедческая экспертиза. Термины и определения»).

<sup>3</sup> Ланцман Р.М. Кибернетизация почерковедческой экспертизы // Правоведение. Л.: Изд-во Ленингр. ун-та, 1966, № 4. – С. 131.

дальнейшем констатирует автор: «Осмысливание первых результатов процесса кибернетизации почерковедческой экспертизы позволяет прийти к некоторым новым выводам как в оценке признаков почерка, визуально наблюдаемых экспертом и подвергающихся сравнительному анализу, так и в понимании сущности графической идентификации»<sup>1</sup>.

Данное исследование побудило активный научный интерес к теме программной алгоритмизации экспертизы почерка и в целом судебной экспертизы, что впоследствии привело к публикации другими исследователями своих работ по этому направлению. Так, параллельно с разработками Р.М. Ланцмана ещё в период с 1962 по 1964 гг. А.Я. Лернер, Л.Я. Червоненкич и В.Н. Вапник предложили метод «обобщенного портрета»<sup>2</sup>. Хотя работа указанных авторов и является более ранней, первенство в попытке внедрения кибернетических методов в сферу исследования почерка принадлежат всё же Р.М. Ланцману, поскольку его исследования были сразу ориентированы на данную область. В свою очередь, метод «обобщенного портрета» был протестирован для дифференциации схожих почерков в ЦНИИСЭ только в период с 1965 по 1966 гг.<sup>3</sup>, а для решения задачи идентификации – в период с 1966 по 1967 гг.<sup>4</sup>

Инициатором данных экспериментов стал Л.Г. Эджубов, работы которого по этой проблематике занимают особое место. Связано это с тем, что в своих трудах он одним из первых затронул проблемы, возникающие при использовании в криминалистике и судебной экспертизе алгоритмов, основанных на распознавании образов и их классификации. Детальнее с позиции современности мы рассмотрим эту проблему в следующем разделе.

---

<sup>1</sup> Там же – С. 132.

<sup>2</sup> Вапник В.Н., Лернер А.Я., Червоненкис А.Я. Системы обучения распознаванию образов при помощи обобщенных портретов. Известия АН СССР, Техническая кибернетика, № 1, 1965.

<sup>3</sup> Эджубов Л.Г. Кибернетика и некоторые вопросы судебного почерковедения. – В сб. «Вопросы кибернетики и право». Изд-во «Наука», 1967.

<sup>4</sup> Журавель А.А., Трошко Н.В., Эджубов Л.Г. Использование алгоритма обобщенного портрета для опознания образов в судебном почерковедении // Правовая кибернетика. – М.: Наука. – 1970. – С. 212–227.



Пока что ограничимся лишь тем, для решения этой проблемы Л.Г. Эджубов предлагал разработать специальный программный комплекс, который мог бы решать задачу криминалистической идентификации образов. По задумке, алгоритм, который будет использовать этот комплекс, должен уметь распознавать неизвестные ему объекты и относить их к новому классу, а не к тем, на которых он обучался ранее. На базе этой концепции Л.Г. Эджубов, А.А. Журавель и Н.В. Трошко доработали метод обобщенного портрета, чтобы с его помощью можно было решать задачу криминалистической идентификации. Для этого ими в качестве обучающих данных для программы использовать только образцы для сравнительного исследования, выполненные одним из предполагаемых исполнителей. Все эти «образы» после их кодировки поэлементно вводились в память ЭВМ, тогда как алгоритм производил их группировку, формируя тем самым область схожих элементов в многомерном пространстве.

После такого обучения, как пишут исследователи: «... машине показывали буквы поддельных подписей, и она определяла, попадала ли данная буква внутрь области подлинных письменных знаков данного лица либо за границу этой области»<sup>1</sup>. Несложно понять, что, если вносимый элемент попадал в эту область, значит автором<sup>2</sup> исследуемой рукописи является проверяемое лицо, в противном случае – другой человек. Как показали проведённые эксперименты, точность данного подхода составляет порядка 90%.

Помимо вышеуказанных способов анализа в период с 1965 по 1975 гг. были разработаны ещё несколько алгоритмов для решения задач

---

<sup>1</sup> Журавель А. А., Трошко Н. В., Эджубов Л. Г. Использование алгоритма обобщенного портрета для опознания образов в судебном почерковедении // Правовая кибернетика. – М.: Наука. – 1970 – С. 225.

<sup>2</sup> В данном исследовании термин «автор» используется как синоним понятия «исполнитель». Это уточнение имеет важное значение, поскольку на практике лицо, написавшее рукопись, не обязательно является её автором. Для более глубокого понимания вопроса рекомендуется обратиться к источникам, посвящённым судебной лингвистической экспертизе.

почерковедческой экспертизы при помощи ЭВМ. К примеру, Л.Е. Ароцкер, А.М. Компаниец и И.Б. Сироджа предложили метод, построенный на графической идентификации при помощи R-функции<sup>1</sup>. Принцип функционирования алгоритма базируется на вычислении числовых характеристик исследуемых рукописных объектов. Основой для работы системы стала гипотеза, что подпись либо рукописное слово можно представить в виде совокупности прямолинейных и дугообразных элементов. Причем для каждого такого элемента можно составить нормальное уравнение, которое будет его описывать. Из этого можно предположить, что существует такое нормальное уравнение, которое будет описывать весь рукописный объект как геометрическую фигуру. Соответственно, сравнивая два уравнения, например, исследуемой подписи и образца для сравнения, можно определить их степень схожести. Это дает эксперту инструмент для проведения количественной оценки.

Принципиально иной подход в своей работе предложил Г.М. Собко, в которой им предлагалось использовать ЭВМ как оценочно-аналитическую машину. Суть идеи сводится к тому, что эксперт проводит аналитическое исследование признаков почерка и их фиксацию, тем самым формируя базу данных этих признаков для машины. Последняя при помощи математического аппарата теории вероятности и математической статистики определяет наличие либо отсутствие тождества между исследуемой рукописью и образцами для сравнительного исследования, взятых у предполагаемого исполнителя.

Применение вероятностного подхода автор аргументирует тем, что: «Задача идентификации не допускает детерминированного решения. Теоретически возможен и практически целесообразен такой подход к решению задачи, который позволит определить вероятность истинности того или иного

---

<sup>1</sup> Ароцкер Л.Е., Компаниец А.М., Сироджа И.Б. Об использовании электронно-вычислительных машин для графической идентификации // Проблемы правовой кибернетики. М., 1968.

вывода. Это положение прежде всего связано со статистической природой почерка, а также с теми реальными преимуществами, который даёт для идентификации почерка статическое изучение признаков на большой выборочный совокупности»<sup>1</sup>.

Это не весь перечень публикаций, посвященных интеграции компьютерных технологий в почерковедение. В то время также было опубликовано множество работ, касающихся вопросов выбора лучшего способа кодирования рукописей для внесения их в память ЭВМ, применению более простых математических подходов, некоторым вопросам правового обеспечения подобных исследований, а также иным схожим проблемам<sup>2</sup>. Все это позволяет говорить о формировании к середине 1970-х гг. в отечественной практике методологических основ использования программных комплексов ЭВМ для решения задач судебно-почерковедческую экспертизы. В то же время, несмотря на первоначальную высокую исследовательскую активность, постепенно интерес к этой теме стал постепенно снижаться. Объясняется это преимущественно двумя факторами.

Во-первых, как упоминалось ранее, технические ограничения ЭВМ того времени не позволяли создать простой полноценный программный комплекс, направленный на решения конкретных задач судебного почерковедения. Как отмечает В.М. Самороковский в своей работе за 1977 г.: «Хоть математические модели в криминалистике и известны давно, однако с их помощью ещё не удавалось получить таких результатов исследования, которые бы сами по себе позволяли решать вопрос в категорической форме с полной гарантией

---

<sup>1</sup> Собко Г. М. Некоторые возможности математической формализации идентификационного судебно-почерковедческого исследования // Применение математических методов и вычислительной техники в праве, криминалистике и судебной экспертизе: материалы симпозиума. – 1970. – С. 110.

<sup>2</sup> Подробнее см.: Проблемы правовой кибернетики. – М. – 1968.; Правовая кибернетика. – М.: Наука. – 1970.; Применение математических методов и вычислительной техники в праве, криминалистике и судебной экспертизе: материалы симпозиума. – 1970.

достоверности»<sup>1</sup>. Техническим специалистам и криминалистам приходилось сталкиваться с такими проблемами как:

- сложность во внесении информации о почерке и его признаках в память компьютера;
- сложность в изучении почерка при помощи средств ЭВМ за счёт высокой вариационности признаков;
- низкая вычислительная мощность компьютеров, вследствие чего скорость анализа исследуемого почеркового материала была достаточно низкой;
- слабая разработанность математического аппарата для решения задач установления тождества в криминалистическом его понимании<sup>2</sup>;
- проблемы в дальнейшей оценке результатов работы ЭВМ как судом и органами следствия, так и самим экспертом<sup>3</sup>.

Помимо этого, накладывало ограничения и то, что компьютерная техника того времени была прерогативой математиков, кибернетиков и иных специалистов в области информационных технологий и компьютерной техники. В свою очередь эксперты-криминалисты массово в то время не имели должного уровня подготовки для работы с подобными комплексами, а также не располагали соответствующей приборной базой для работы по методикам, в которых предполагалось использование ЭВМ.

Вторая причина отчасти вытекает из первой. Параллельно с развитием кибернетического подхода, была сформирована методическая часть судебного почерковедения. Именно в 1960–1970-х гг. она получила своё окончательное оформление, которое остаётся практически неизменным и сегодня<sup>4</sup>. Была

---

<sup>1</sup> Самороковский В.М. Криминалистическая экспертиза почерка с применением математической модели вариационности признаков / М-во юстиции СССР. ВНИИ судебных экспертиз; Отв. ред. докт. юрид. наук Г.Л. Грановский. – М., 1977. – С. 11.

<sup>2</sup> Там же – С. 11.

<sup>3</sup> Ланцмана Р.М. Проблема наглядности в процессе использования ЭВМ в почерковедческой экспертизе // Проблемы правовой кибернетики. М., 1968. – С. 117–118.

<sup>4</sup> Орлова В.Ф. и др. Судебно-почерковедческая экспертиза: общая часть // Теоретические и методические основы (Под науч. ред. ВФ Орловой, 2-е изд., РФЦСЭ при Минюсте РФ. – М.: Наука. – 2006. – С. 40–47.

разработана простая система общих и частных признаков почерка, а также максимально формализована качественно-описательная методика проведения исследований, которая была понятна, проста в применении и наглядна как для самого эксперта, так и для органов следствия и суда<sup>1</sup>. В результате этого большая часть криминалистов стали недооценивать средства и методы компьютерного и математического моделирования<sup>2</sup>.

Как итог, качественно-описательный подход оказался на тот момент лучше и практичнее предлагаемых кибернетических и вероятностно-статистических подходов, особенно в решении идентификационных задач. Исключением здесь является только работа П.Г. Кулагина и А.И. Колонутова, в которой ЭВМ была вполне успешно использована для выявления диагностических признаков, позволявших определить пол исполнителя рукописи<sup>3</sup>. Тем не менее, как было верно подмечено П.М. Кошмановым, дальнейшее развитие кибернетического и математического направления вплоть до середины 1980-х гг. было направлено на доработку уже разработанных подходов<sup>4</sup>, а также на их экспериментальную апробацию<sup>5</sup>.

### **1.2.3. Применение программных комплексов ЭВМ в зарубежной практике в период с 1970-х по 1980-е гг.**

Изначально, как писалось до этого, зарубежная криминалистика не была заинтересована в использовании компьютерных программ для исследования

<sup>1</sup> Однако, это порождает такую проблему как высокий уровень субъективной оценки при проведении исследований.

<sup>2</sup> Самороковский В.М. Криминалистическая экспертиза почерка с применением математической модели вариационности признаков / М-во юстиции СССР. ВНИИ судебных экспертиз; Отв. ред. докт. юрид. наук Г.Л. Грановский. – М., 1977. – С. 11.

<sup>3</sup> Кулагин П.Г., Колонутова А.И. Экспертная методика дифференциации рукописей на мужские и женские. – Изд-во Всесоюзного НИИ МВД СССР, 1970.

<sup>4</sup> Ярким примером здесь служит разработка и внедрение методов вероятностно-статистического моделирования и принятия решения на их основе. Подробнее см. Применение методов исследования, основанных на вероятностном моделировании, в судебно-почерковедческой экспертизе: (Метод. пособие) / М-во юстиции СССР. Всесоюз. науч.-исслед. ин-т судебных экспертиз. М., 1976.

<sup>5</sup> Кошманов М.П., Кошманов П.М. Этапы и основные направления внедрения компьютерных технологий в судебное почерковедение и почерковедческую экспертизу // Эксперт-криминалист – 2008 – №3. – С. 35–40.

почерка. Согласно отчету NIST интерес к этой области возник только в середине 1980-х гг., тогда как первые прикладные программные комплексы появились только в 1990-х гг.<sup>1</sup> Во многом это объясняется в целом скептическим отношением правоохранительной системы зарубежных стран к результатам почерковедческой экспертизы, а также слабой развитостью данного направления криминалистической техники. Как указывают Р. Губер и А. Хедрик, из-за особенностей политики правоохранительной системы США и Канады, сотрудники государственных судебно-экспертных учреждений обычно не привлекаются при рассмотрении гражданских дел частных лиц<sup>2</sup>. Вследствие этого для установления фактов, требующих применение специальных знаний в области почерка, адвокатам приходится обращаться к услугам графологов<sup>3</sup>, «экспертные» выводы которых: «... были удручающе низкими, из-за чего возникали обоснованные вопросы о количестве несправедливых судебных решений, которые произошли по их вине»<sup>4</sup>.

Очевидно, что подобные ситуации также негативно влияют на репутацию судебно-экспертных учреждений и специалистов, занимающихся почерковедением. В настоящее время до сих пор ведутся дискуссии относительно того, стоит ли причислять судебное почерковедение к специальным знаниям, что мы подробно рассматривали в одном из своих исследований<sup>5</sup>. Нельзя не отметить и то, что в США, Канаде и большинстве европейских стран до сих пор отсутствует централизованная академическая система подготовки

---

<sup>1</sup> The Expert Working Group for Human Factors in Handwriting Examination, Forensic Handwriting Examination and Human Factors: Improving the Practice Through a Systems Approach, U.S. Department of Commerce, National Institute of Standards and Technology – 2021.

<sup>2</sup> Huber R.A., Headrick A.M. Handwriting identification: facts and fundamentals. – CRC press, 1999. – С. 23.

<sup>3</sup> Графология – учение об определении характера человека по почерку. Официально не является псевдо- или лженаукой, однако большей частью исследователей признается как псевдонаучное учение.

<sup>4</sup> Huber R.A., Headrick A.M. Handwriting identification: facts and fundamentals. – CRC press, 1999. – С. 24.

<sup>5</sup> Мищук В.А. Использование искусственных нейронных сетей для решения задач судебно почерковедческой экспертизы: анализ зарубежного опыта // Теория и практика судебной экспертизы. 2025. Т. 20. No 1. С. 44–65.

судебных экспертов в области почерковедения<sup>1</sup>, что негативно влияет на общее развитие данного направления.

Однако, возвращаясь к теме внедрения и использования программных комплексов ЭВМ для анализа рукописей, нельзя сказать, что исследований на эту тему не велось в принципе. Так, работы по математическому моделированию почерка стали проводиться примерно в конце 1950-х гг., вследствие чего некоторые из них легли в основу компьютерного анализа почерка. Начиная с середины 1970-х гг. специалисты в области компьютерной техники, имеющие то или иное отношение к криминалистике, либо просто интересовавшиеся данным вопросом, предпринимали активные попытки использовать метрические характеристики почерка для установления факта фальсификации рукописей и идентификации ее автора<sup>2</sup>.

Одной из первых работ в этой области были исследования Р. Нагеля и А. Розенфельда, в которой авторами использовались признаки соотношения размеров и наклона, полученные из модифицированной кинематической модели почерка М. Идена<sup>3</sup>. Сам процесс идентификации строится на том, что выявленные признаки у группы образцов от одного писателя имеют тенденцию к группировке, т. е. к образованию кластера. В случае разных писателей разброс признаков будет более широким. При этом, как отмечают авторы, в своей работе ими исследовались непосредственно признаки уже написанной на бумаге подписи, а не ее компьютерная модель или ограниченный фрагмент, как это было в других исследованиях того времени. Также можно выделить публикацию Н. Хербста и К. Лю, в которой ими

---

<sup>1</sup> Harralson H.H., Miller L.S. Huber and Headrick's Handwriting Identification: Facts and Fundamentals. – Crc Press, 2017. – С. 5.

<sup>2</sup> Не последнюю роль в этом вопросе сыграло постепенное возникновение и развитие электронного документооборота, а также то, что финансовая система развитых стран того времени стала испытывать острую потребность в автоматизации некоторых бизнес-процессов, включая проверку подлинности подписей в документах. В дальнейшем это сильно повлияет на современный облик этого направления, что будет рассмотрено далее.

<sup>3</sup> Nagel R. N., Rosenfeld A. Computer detection of freehand forgeries // IEEE Transactions on Computers. – 1977. – Т. 100. – №. 9. – С. 895–905.

описывалась возможность использования динамики написания штрихов подписи, выполненной при помощи устройств электронного ввода<sup>1</sup>.

К середине 1980-х гг. М. Аммар, Ю. Йошида и Т.А. Фукумура предложили модель по обнаружению факта фальсификации рукописей, основанную на анализе распределения красящего вещества в штрихах<sup>2</sup>. Предполагалось, что если в определённых местах на изображении подписи пиксели темнее, то и давление пера в этих областях было выше. Базируясь на этой информации, можно было составить алгоритм, который бы проводил идентификацию исполнителя подписи на основе указанных признаков.

Позднее эта работа положила новое направление в области автоматической проверки подписи и послужила отправной точкой уже для исследований Р. Сабурина и Р. Пламондона, где для предварительной обработки изображения был предложен анализ градиента изображения.<sup>3</sup> Таким образом, как отмечает М. Пароди: «Эти подходы (предложенные указанными выше авторам – *прим.*) были в основном сосредоточены на описании признаков и реализации некоторых простых классификаторов, например, основанных на расстояниях (имеется в виду метрические характеристики почерка – *прим.*) или k-ближайших соседях (K-Nearest Neighbors – KNN)»<sup>4</sup>.

Таким образом, к середине 1980-х годов, как указывают Г. Лоретта и Р. Пламондон, в практике выявления поддельных подписей были разработаны два основных подхода (подробнее смотри приложение №11)<sup>5</sup>:

<sup>1</sup> Herbst N.M., Liu C.N. Automatic signature verification based on accelerometry // IBM Journal of Research and Development. – 1977. – Т. 21. – №. 3. – С. 245–253.

<sup>2</sup> Ammar M., Yoshida Y., Fukumura T. A new effective approach for off-line verification of signatures by using pressure features // Proceedings of the 8th International Conference on Pattern Recognition. – 1986. – С. 566–569.

<sup>3</sup> Sabourin R., Plamondon R. Preprocessing of handwritten signatures from image gradient analysis. In Proc. 8th Int. Conf. Pattern Recognition, 1986. – С. 576–579.

<sup>4</sup> Parodi M. Automatic Handwritten Signature Verification: doctoral dissertation. – Universidad Nacional de Rosario, 2015. – С. 9.

<sup>5</sup> Plamondon R., Lorette G. Automatic signature verification and writer identification – the state of the art // Pattern recognition. – 1989. – Т. 22. – №. 2. – С. 107–131.



– Статический подход, он же offline-исследование почерка, который направлен на анализ «традиционных» рукописей, т. е. выполненных на бумажном носителе;

– Динамический подход, известный также как online-исследование почерка, которое базируется уже на изучении рукописей, выполненных с помощью электронных устройств (стилус, графический планшет и т. п.)<sup>1</sup>.

Поскольку в настоящей работе рассматриваются в основном «традиционные» объекты судебно-почерковедческой экспертизы, далее мы будем в большей степени уделять именно offline-способам исследования почерка. Однако нельзя не отметить, что подходы, разработанные для исследования цифровых рукописей, являются более эффективными благодаря высокой информативности последних. В силу этого мы также будем периодически обращаться и к этим методам.

#### **1.2.4. Переход к искусственным нейронным сетям**

Наряду с развитием «классических» способов компьютерного анализа почерка, в научном сообществе вновь возродился интерес к искусственным нейронным сетям. Метод обратного распространения ошибки помог максимально формализовать задачу распознавания образов, что открыло возможности для его применения в решении ряда задач судебно-почерковедческой экспертизы.

Ярким примером подобного формализованного подхода является работа 1988 г. Д. Майгелла, Т. Уилкинсона и Дж. Гудмана. За счет использования указанного выше метода они смогли разработать практически автоматическую распознающую систему, способную отличить оригинал подписи от ее грубой фальсификаций. Как отмечают сам авторы: «Случайные подделки – это непрофессиональные подделки, в которых пишущий не практикуется в воспроизведении подписи. У пишущего может даже не быть копии подлинной

---

<sup>1</sup> Далее эти объекты именуются «цифровые рукописи/тексты/подписи».

подписи. Случайные подделки очень важно обнаружить. Они гораздо более многочисленны и влекут за собой большие денежные потери, чем профессиональные подделки»<sup>1</sup>.

Фактически их идея сводится к бинарной классификации нескольких наборов данных, а именно изображений подписи условного «оригинала» и «фальсификации». Нейросеть в течение нескольких циклов обучения анализирует каждый из этих наборов и корректирует свои веса синапсов в сторону уменьшения степени ошибки алгоритма, тем самым вырабатывая определённый набор правил обработки этих данных. Таким образом нейросеть в состоянии отличить один набор от другого, а также производить классификацию новых изображений подписи либо иных рукописей. Как заключают авторы, подобный алгоритм может производить идентификацию исполнителя исследуемой рукописи и определить, является ли она поддельной<sup>2</sup>.

Однако указывается, что у этого подхода есть существенный недостаток: как и где найти изображения поддельной подписи? В своей публикации исследователи предложили два пути решения этой проблемы. Первый – эксперт-почерковед либо иной специалист может самостоятельно создать набор «поддельных» подписей, используя так называемые «случайные подделки» – случайные подписи, выполненные разными людьми. Кроме того, в рамках этого подхода предлагается использовать компьютерную генерацию изображений, похожих на исследуемый объект.

Второй способ требует уже доработки самой нейронной сети, в ходе которой алгоритм должен обучиться распознавать только один набор изображений, а именно сравнительные образцы почерка проверяемого лица. На выходе программа должна выдавать числовое значение в пределах от «0»

---

<sup>1</sup> Wilkinson T., Mighell D., Goodman J. Backpropagation and its application to handwritten signature verification // Advances in Neural Information Processing Systems. – 1988. – Т. 1. – С. 341.

<sup>2</sup> Описанный алгоритм имеет ту же проблему дихотомии, что и описанный метод обобщенного портрета что ограничивает его применение в идентификационных исследованиях.

до «1». В этом случае для решения вопроса о подлинности подписи предполагается установить пороговое значение, при котором, допустим, полученный результат больше 0.5 будет трактовать как «подлинная» подпись, в противном случае – сфальсифицированная.

Основной пик исследований по применению нейросетевых алгоритмов приходится на 1992–1993 гг. и во многом они дальше развивают идеи, предложенные Д. Майгеллом, Т. Уилкинсоном и Дж. Гудманом. Так, можно выделить разработку Я. Лекуна, в которой он использовал для выявления «поддельных» рукописей «сиамскую нейронную сеть» – архитектура, в которой используются две условно независимых ИНС<sup>1</sup>. Далее мы более детально рассмотрим принцип работы этой архитектуры. Пока что просто укажем, что такая нейросеть в процессе обучения учится сравнивать между собой несколько объектов и определять, похожи они или нет.

По мере развития ИНС они, подобно «классическим» алгоритмам, стали применяться в рамках двух подходов: статического и динамического. При этом, как и в случае обычных компьютерных программ, более эффективным стало динамическое направление, поскольку использование устройств для электронного ввода рукописей значительно расширяет спектр анализируемых признаков. Так, в работе Дж. Хигашино нейронная сеть анализировала зафиксированное электронным устройством степень давления пишущего прибора, а также горизонтальную и вертикальную скорость выполнения штрихов<sup>2</sup>. П. Джентрик и Дж. Минот, напротив, использовали ИНС только для анализа степени давления и особенностей расположения штрихов в виде их координат<sup>3</sup>.

---

<sup>1</sup> Bromley J. et al. Signature verification using a «Siamese» time delay neural network // *Advances in neural information processing systems*. – 1993. – Т. 6.

<sup>2</sup> Higashino J. Signature verification system on neuro-computer // *Proceedings., 11th IAPR International Conference on Pattern Recognition. Vol. III. Conference C: Image, Speech and Signal Analysis*. – IEEE, 1992. – С. 517-521.

<sup>3</sup> Gentric P., Minot J. Authentification dynamique de signatures par reseaux de neurones // *Revue annuelle-LEP*. – 1990. – С. 34–36.

В рамках статического подхода чаще всего в качестве признаков выбирались особенности геометрического строения символов, как, например, это показано в исследовании Н. Кардо, М. Ревеню, Б. Викторри и М.Дж. Ревилле<sup>1</sup>. Либо, использовалась функция плотности вероятности направлений штрихов в качестве характеризующего параметра, что было описано в публикации Р. Сабурина и Ж. П. Друара<sup>2</sup>. Таким образом одной из центральных проблем того времени как в динамическом, так и в статическом подходах, является выбор характеристик почерка, которые можно использовать для обучения нейросети<sup>3</sup>.

Кроме этого, как замечают Ф. Леклерк и Р. Пламондон в своём обзорном исследовании, ученым пришлось столкнуться со множеством проблем, некоторые из которых так и не были решены<sup>4</sup>. Во-первых, это частично затронутая проблема применения дихотомических алгоритмов для решения задач идентификации. Хотя в то время предлагалось использовать различные подходы к решению проблемы, такие как создание «самостоятельных подделок» или разработка «моносетей», на тот момент они не принесли результатов.

Во-вторых, проблемой стал сам процесс «обучения» нейронных сетей, поскольку для полноценной и максимально точной работы алгоритма требовалось использовать больше число «обучающих» образцов, чем в «классических» аналитических системах. В то же время у экспертов и исследователей в распоряжении чаще всего находится не больше сотни образцов почерка, что, разумеется, не всегда хватает для удовлетворительных

---

<sup>1</sup> Cardot H. et al. Des reseaux neuronaux pour l'authentification de signatures manuscrites // Proc. CNED'92: Colloque National sur VEcrit et le Document, Nancy. – 1992. – С. 250–255.

<sup>2</sup> Sabourin R., Drouhard J.P. Off-line Signature Verification Using Directional PDF and Neural Networks // Proceedings of the 11th ICPR, The Hague. – 1992. – Т. 321. – С. 321–325.

<sup>3</sup> Важно понимать, что ИНС того времени не могли анализировать изображения целиком, вследствие чего им предварительно передавались необходимые признаки. Современные ИНС могут анализировать изображение полностью и самостоятельно.

<sup>4</sup> Leclerc F., Plamondon R. Automatic signature verification: The state of the art—1989–1993 // International journal of pattern recognition and artificial intelligence. – 1994. – Т. 8. – №. 03. – С. 643–660.

результатов. Из-за этого, несмотря на активное развитие методов изучения почерка с помощью нейросетей, в экспертной практике зарубежных стран этот метод на то время не получил широкого распространения.

В свою очередь отечественная криминалистика и судебная экспертиза вернулась к вопросам внедрения искусственных нейронных сетей только в середине 2000-х гг. До этого времени разработка программных комплексов ЭВМ велась преимущественно над измерением метрических характеристик почерка<sup>1</sup>. Так, в 1985 г. Н.Г. Сахаровым на основе результатов экспериментальных исследований, проведённых во ВНИИСЭ, был предложен программный комплекс «МАК». Данный комплекс предназначался для автоматизации расчетной части комплексной методики установления подлинности кратких и простых подписей. Базировался алгоритм на разработанной одноименной методике 1984 г., разработанной во ВНИИСЭ<sup>2</sup>. Ее адаптация для ЭВМ стала возможной за счёт процедур, формализующих процессы выделения признаков.

В последствии, уже к 1987 г. также во ВНИИСЭ был разработан анализатор изображений «Маджискан-2А» и созданный для него пакет программ «Телемак». Данный пакет состоял из трех программ: «HAND» – использовалась для измерения кривизны звеньев почерковых объектов, «TEL» – производила совмещение на экране криволинейных участков исследуемой подписи со значениями радиуса, именуемого в шаблоне-трафарете, и «ANA» – осуществляла обработку данных, полученных в ходе применения предыдущих программ. Основной функцией «ANA» было определение информативности как отдельных участков подписи, так и вычисление суммарной информативности. Установленные программой значения служили обоснованием для соответствующего вывода эксперта-почерковеда. В

---

<sup>1</sup> Полякова А.В., Мартынова Я.А. Генезис разработки и внедрения компьютерных технологий в судебно-почерковедческой экспертизе // Законность и правопорядок. – 2022. – № 3(35). – С. 50–54.

<sup>2</sup> Дутова Н. В. и др. Дифференциация подлинных подписей и подписей, выполненных с подражанием после предварительной тренировки // Методическое письмо. М.: ВНИИСЭ. – 1984.

дальнейшем, как отмечается П. М. Кошмановым: «На базе анализатора изображения «Маджискан-2А» по аналогичному с программой «Телемак» принципу были разработаны программы «MERA», «Око», «Маска». Программа «MERA» (А. В. Смирнов) предназначена для исследования кратких почерковых записей. Программы «ОКО», «Маска» (Н. Г. Сахарова) создавались для измерения кривизны локальных участков подписей»<sup>1</sup>.

Возвращаясь к нейросетевым алгоритмам необходимо отметить, что основная заслуга по их популяризации принадлежит С.Д. Кулику и Н.А. Никонец, которые занимались данной проблематикой в период с 2008 по 2016 гг. Изначально их внимание было уделено решению относительно простых диагностических задач, а именно установления пола и возраста исполнителя рукописи при помощи указанных алгоритмов. Для этого ими была разработана программа «FNWE v.1.0», и подсистема распознавания «RSFNWE v.1.0». Также совместно с сотрудниками ЭКЦ МВД РФ была создана методическая база для данной программы<sup>2</sup>.

Последняя их работа была посвящена использованию и адаптации существующих почерковедческих методик для идентификационного поиска исполнителя рукописи при помощи нейросетей, в которой ими было отмечено, что на 2016 г., как, впрочем, и сегодня, полноценных автоматизированных систем, позволяющих решать криминалистические идентификационные задачи, отсутствуют. При этом на их взгляд использование нейронных сетей и специально разработанных для них методик исследований позволит избежать ошибок, которые могут возникнуть из-за взаимосвязи различных признаков

---

<sup>1</sup> Кошманов М.П., Кошманов П.М. Этапы и основные направления внедрения компьютерных технологий в судебное почерковедение и почерковедческую экспертизу // Эксперт-криминалист – 2008–№3. – С. 37–39.

<sup>2</sup> Кулик С.Д., Никонец Д.А. Автоматизация классификационно-диагностических почерковедческих исследований с помощью нейронных сетей // Информационные технологии. – 2012. – № 1. – С. 70–75.

почерка, что, как считается, значительно улучшит качество и объективность экспертного исследования<sup>1</sup>.

Помимо упомянутых ранее исследователей вопросами решения идентификационных задач судебно-почерковедческой экспертизы в чуть более поздний период также занимались А.И. Иванов, А.И. Газин, Е.И. Качайкин, Д. Ю. Андреев. Авторами проводили экспериментальные работы по адаптации программы «БиоНейроАвтограф»<sup>2</sup>. Тем самым они попытались решить проблемы идентификации при помощи подходов биометрии. В своем исследовании они применили нейронную сеть для извлечения биометрических параметров из исследуемой рукописи и образцов для сравнительного исследования. Основная идея заключалась в том, чтобы на основе извлеченных биометрических параметров вычислить «индивидуальный ключ» – 256 битный код, который можно сравнить с аналогичным «ключом», составленного из биометрических параметров исследуемого объекта.

Как можно видеть, на протяжении истории исследователи из разных стран активно интересовались возможностью внедрения и применения самообучающегося алгоритма, а именно ИНС, для решения задач СПЭ. Однако несмотря на многочисленные научные работы по этой теме, практической реализации данное направление в широкой экспертной практике не получило. Вследствие новизны нейросетевых алгоритмов они были достаточно несовершенны и плохо оптимизированы. Кроме этого, сказалось и несовершенство средств компьютерной техники того времени, которые не позволяли производить большой объем вычислений за приемлемый временной срок.

Тем не менее, научные работы по использованию нейросетей в сфере почерковедения, проводимые с 1960-х по 2000-е гг., являются важным

---

<sup>1</sup> Кулик С.Д., Никонец Д.А. Использование существующих почерковедческих методик для идентификационного поиска исполнителя рукописи // Нейрокомпьютеры: разработка, применение. – 2016. – № 9. – С. 64–70.

<sup>2</sup> Иванов А.И., Газин А.И., Качайкин Е.И., Андреев Д.Ю. Автоматизация почерковедческой экспертизы, построенная на обучении больших искусственных нейронных сетей // Модели, системы, сети в экономике, технике, природе и обществе. – 2016. – № 1(17). – С. 249–257.

теоретическим базисом для современных исследований, поскольку многие положения и проблемы, которые были тогда описаны, актуальны и сегодня.

### **§ 1.3. Современные подходы использования искусственных нейронных сетей для решения задач судебно-почерковедческой экспертизы**

#### **1.3.1 Отечественная практика**

Как было показано ранее, тема возможности применения ИНС для решения задач судебно-почерковедческой экспертизы не является новой. Тем не менее полноценных научных трудов в виде монографических исследований по данной проблематике в отечественной литературе содержится немного. Во многом это объясняется активным развитием новых архитектур нейросетей, которые начали внедрять повсеместно относительно недавно – примерно с 2015 г. До этого времени область искусственных нейронных сетей была преимущественно прерогативой небольшого круга специалистов. В настоящее время оборудование и программное обеспечение более доступны широкому кругу лиц для проведения собственных экспериментов с нейросетями.

Если говорить в целом о возможности применения алгоритмов ИИ в практике эксперта-почерковеда, то одной из немногочисленных современных работ в этой области можно назвать исследование А.Н. Охлупиной<sup>1</sup>. Хотя автор и делает акцент на применении ДСМ-метода<sup>2</sup> и несколько критично смотрит на использование нейросетевых алгоритмов в почерковедческих исследованиях, сам методический подход по интеграции интеллектуальных систем в действующие методики судебно-почерковедческой экспертизы путем

---

<sup>1</sup> Охлупина А.Н. Теоретические, методические и организационно-тактические основы применения интеллектуальных систем в судебно-почерковедческом исследовании подписей: автореферат дис. ... кандидата юридических наук: 12.00.12 – М., 2019.

<sup>2</sup> 1. Охлупина А. Н. Вопросы применения интеллектуальных систем в целях криминалистического исследования подписей // Энциклопедия Судебной Экспертизы: Научно-практический журнал. – 2016. – № 1 (8). [Электронный ресурс]. URL: [https://proexpertizu.ru/theory\\_and\\_practice/pocherk/682/?ysclid=mbvzihnjkf925370900](https://proexpertizu.ru/theory_and_practice/pocherk/682/?ysclid=mbvzihnjkf925370900) (дата обращения: 12.01.2025).



их слияния на аналитической стадии исследования, а также автоматизация процесса оценки выявленных признаков при помощи вышеуказанного метода, представляется весьма интересным и главное достаточно наглядным для последующей оценки заключения эксперта органами расследования и судом.

Кроме этого, можно выделить работу М.В. Бобовкина, О.А. Диденко и А.Е. Нестерова, в рамках которой был разработан прототип нейросетевого программного комплекса «Фрося»<sup>1</sup>. По задумке авторов эта программа представляет собой систему, в которой нейронные сети используются для сбора статистических данных о частных признаках почерка и вывода интерактивных подсказок по дифференциации того или иного признака. Предполагается, что это позволит снизить влияние субъективного фактора на аналитической стадии судебно-почерковедческого исследования и положительно повлияет на качество и объективность экспертного заключения.

Разработанный комплекс является важным шагом в попытке внедрения нейросетевых алгоритмов в практику экспертов-почерковедов и вызывает интерес за счёт своей технической реализации, не говоря уже о перспективности и инновационности благодаря использованию современных подходов в разработке искусственных нейронных сетей. Однако, как отмечают сами авторы их программный комплекс: «Является инструментом, осуществляющим вспомогательные функции, и не призван полностью автоматизировать процесс идентификации исполнителя рукописи»<sup>2</sup>. На наш взгляд это является существенным ограничением по использованию функционала современных искусственных нейронных сетей.

Также известен проект NSP-SigVer под руководством Д.В. Бахтеева, в котором используется алгоритм ИНС для верификации подписи<sup>3</sup>. В качестве

---

<sup>1</sup> Бобовкин М.В., Диденко О. А., Нестеров А.Е. Компьютерное моделирование раздельного и сравнительного исследования частных признаков почерка на основе программного комплекса «Фрося» // Судебная экспертиза – 2021–№3 (67). – С. 62–71.

<sup>2</sup> Там же – С. 70.

<sup>3</sup> Bakhteev D. V., Sudarikov R. NSP Dataset and Offline Signature Verification //Quality of Information and Communications Technology: 13th International Conference, QUATIC 2020,

базовой архитектуры они выбрали сверточную сиамскую нейронную сеть. По словам авторов, им удалось обучить нейросеть с высокой точностью отличать поддельные подписи от оригинальных на наборе данных CEDAR — 94.37%. Однако отмечается, что на других данных система демонстрирует более низкие результаты. Кроме этого, для экспериментальной работы ими была собрана большая база данных подписей и их имитаций, выполненных на кириллице. Количество образцов подлинных подписей составляет 12 596 – по 56 от каждого участника эксперимента. Поддельных подписей было отобрано порядка 28 056, т. е. каждую подлинную подпись приходится порядка 2–3 имитаций. На данный момент это самая большая база данных в СНГ сегменте, собранная для решения задачи идентификации по подписи.

Нельзя не указать и разработку компании «Т-информ», в которой SNN используется для: «... анализа рукописных материалов на предмет определения неоднородности почерка и принадлежности текста разным авторам»<sup>1</sup>.

### 1.3.2. Зарубежная практика.

Если мы говорим о современных зарубежных публикациях, посвященных вопросам применения ИНС в экспертном исследовании почерка, то здесь можно отметить высокую степень использования CNN различных конфигураций<sup>2</sup>. При этом в большинстве работ свёрточные слои используются для извлечения признаков почерка<sup>3</sup>, тогда как линейные

---

Faro, Portugal, September 9–11, 2020, Proceedings 13. – Springer International Publishing, 2020. – С. 41–49.

<sup>1</sup> Аналитическая система АСПИАД / [Электронный ресурс] // Т-информ: [сайт]. – URL: <https://tinform.ru/solutions/aspiad/> (дата обращения: 01.08.2024).

<sup>2</sup> Hameed M. M. et al. Machine learning-based offline signature verification systems: A systematic review // Signal Processing: Image Communication. – 2021. – Т. 93. – С. 116139.

<sup>3</sup> В данном контексте подразумеваются те особенности почерка, которые нейронная сеть самостоятельно выявляет в процессе обучения.

полносвязные слои нацелены на классификацию авторов. Обычно, выглядит это следующим образом<sup>1</sup>:

1. Производится сканирование множества рукописей от различных авторов, имитации этих рукописей, либо берется готовый набор данных на подобии CEDAR, ICDAR 2011 SigVer и GPDS150;

2. Полученные изображения сегментируются на какие-либо фрагменты. Это могут быть отдельные символы, группа символов, либо просто случайная часть общего изображения определенной формы и размера. Исследование также может проводиться и без сегментации рукописей. Обычно это происходит в случаях, когда в качестве данных выступают подписи. Сам процесс сегментации необходим по двум причинам. Во-первых, это позволяет уменьшить количество производимых вычислений нейронной сетью за счёт удаления малоинформативных и неинформативных фрагментов документа. Во-вторых, благодаря сегментации происходит увеличение набора данных, что потенциально может повысить точность сети.

3. Подготовленные данные загружаются в сверточную нейронную сеть, которая обучается на них. Обычно архитектура такой сети включает несколько сверточных блоков, извлекающих разнообразные признаки с разных уровней изображения, и полносвязный классификатор с N-количеством выходных нейронов, где N – это число предполагаемых исполнителей.

При этом большинство исследователей не обучают свою нейронную сеть с «нуля», а применяют «трансферное обучение»<sup>2</sup>. Как показывают исследования<sup>3</sup>, в большинстве случаев анализ признаков любого объекта в CNN проходит по одному и тому же принципу – сначала извлекаются базовые

---

<sup>1</sup> Мищук В.А. Использование искусственных нейронных сетей для решения задач судебно-почерковедческой экспертизы: анализ зарубежного опыта // Теория и практика судебной экспертизы. 2025. Т. 20. № 1. С. 44–65.

<sup>2</sup> Трансферное обучение – подход в машинном обучении, при котором уже обученную нейросеть используют для решения новой задачи на новом наборе данных.

<sup>3</sup> Zeiler M. D., Fergus R. Visualizing and understanding convolutional networks // Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part I 13. – Springer International Publishing, 2014. – С. 818-833.

элементы в виде линий, которые в дальнейшем объединяются в единую сложную текстуру. Эту особенность вполне можно использовать для того, чтобы применить уже хорошо обученную сеть либо ее фрагменты для решения другой задачи. Обычно, такие фрагменты «замораживают», т. е. их весовые коэффициенты не корректируются при обратном распространении ошибки. Описанный прием как правило позволяет существенно увеличить точность модели в рамках проекта за минимальное время при последующем «дообучении» не замороженных блоков.

Как показывает практика, многие исследователи используют подобную схему решения задачи идентификации. Среди них можно выделить следующих:

- Специалисты Факультета информационных технологий и вычислительной техники Исламского университета Азад применили несколько предварительно обученных CNN: Resnet-18, Resnet-34, Resnet-50, Resnet-101 и Resnet-152. Они заменили стандартный классификатор на свой собственный, предназначенный для идентификации автора рукописи. В качестве данных были использованы сегментированные строки арабского текста в виде небольших квадратных фрагментов, на которых происходило обучение сети. Средняя точность ИНС составила 99%. В то же время автором заверяется, что предлагаемая им модель применима и для других видов письменности, а именно к латинице<sup>1</sup>;

- Ученые Факультета компьютерных и информационных наук Токийского университета сельского хозяйства и технологий использовали для обучения нейросети изображения отдельных иероглифов, которые были случайным образом выбраны из всей рукописи. При этом алгоритмом обрабатывается не одно изображение за одну итерацию, а кортеж из нескольких изображений. Это позволяет выявить при помощи CNN признаки

---

<sup>1</sup> Khosroshahi S.N.M. et al. Deep neural networks-based offline writer identification using heterogeneous handwriting data: an evaluation via a novel standard dataset // Journal of Ambient Intelligence and Humanized Computing. – 2022. – С. 1–20.

из множества изображений иероглифов, выполненных одним автором, и объединить их. Авторы предложили несколько способов объединения признаков: усреднение, максимизация и усреднение методом К-средних. Благодаря этому подходу исследователи достигли точности прогнозирования в 92.38%<sup>1</sup>;

– Специалисты лаборатории LASTID предложили интересный подход к сегментации. В качестве обучающих данных они использовали как слова, так и отдельные фрагменты в виде символов и наборов символов. Для анализа этих сегментов использовались две ветви CNN: одна ветвь анализировала слова, а другая – их фрагменты. Как указывают авторы, такой подход позволяет извлекать признаки почерка с разных уровней, объединять их и тем самым повышать точность системы. Собственно, благодаря такому методу исследователям удалось достигнуть точности принятия решения системой в 99.75%<sup>2</sup>.

Как можно заметить, многие исследователи применяют описанный подход к решению задачи определения автора рукописи. Однако, П. Кумар и А. Шарма в своей работе предложили другой метод анализа, обходясь без предварительной сегментации. Они считают, что сегментация – это узкое место в процессе обработки данных, которое существенно влияет на точность всей системы. Как отмечается в их публикации: «Этапы предварительной обработки в любой системе распознавания образов играют ключевую роль, поскольку ошибки, возникающие на этих этапах, значительно снижают производительность системы»<sup>3</sup>.

Чтобы реализовать модель ИНС, которая способна анализировать исследуемые документы без предварительной сегментации, исследователями

---

<sup>1</sup> Nguyen H. T. et al. Text-independent writer identification using convolutional neural network // Pattern Recognition Letters. – 2019. – Т. 121. – С. 104–112.

<sup>2</sup> Chahi A. et al. WriterINet: a multi-path deep CNN for offline text-independent writer identification // International Journal on Document Analysis and Recognition (IJDAR). – 2023. – Т. 26. – №. 2. – С. 89–107.

<sup>3</sup> Kumar P., Sharma A. Segmentation-free writer identification based on convolutional neural network // Computers and Electrical Engineering. – 2020. – Т. 85. – С. 3.

была предложена следующая архитектура сети: вся структура состоит из трех блоков слоёв свертки, при помощи которых происходит извлечение признаков. Благодаря процедуре max-pooling, применяемой между этими блоками, входное изображение последовательно делится на ячейки размером  $4 \times 4$ ,  $8 \times 8$  и  $16 \times 16$ , тем самым каждая ячейка представляет собой какой-либо участок исследуемого документа, из которой извлекаются признаки.

В этом случае признаком является вектор, который распределяет вероятность того, что конкретный фрагмент документа был написан определённым человеком. Затем используется механизм выбора регионов, который позволяет отбирать ячейки, где максимальная вероятность для каждого из потенциальных авторов составляет от 10% до 50%. Это необходимо для того, чтобы исключить ячейки с минимальной и максимальной вероятностью, так как они могут вносить значительные погрешности в определение настоящего автора рукописи.

Сам процесс идентификация писателя осуществляется при помощи алгоритма «голосование ячеек». Суть данного алгоритма, как пишут П. Кумар и А. Шарма, сводится к следующему: «Каждая выбранная ячейка голосует за свой предсказанный класс писателей и увеличивает оценку соответствующего писателя на вес ячейки. Таким образом, класс писателей, имеющий наибольший итоговый балл, объявляется писателем документа»<sup>1</sup>. Используя данный подход, авторы смогли достичь точности получаемых результатов в пределах от 96% до 99%.

Надо заметить, что современные исследования не ограничиваются использованием только сверточных нейронных сетей. Например, Ш. Хеа и Л. Шомакер, помимо CNN, применяли и закрытый рекуррентный блок – одну из модификаций RNN<sup>2</sup>. Предложенный ими подход основан на том, что сверточные блоки разбивают длинные текстовые строки на отдельные

---

<sup>1</sup> Kumar P., Sharma A. Segmentation-free writer identification based on convolutional neural network // Computers and Electrical Engineering. – 2020. – Т. 85. – С. 8.

<sup>2</sup> He S., Schomaker L. GR-RNN: Global-context residual recurrent neural networks for writer identification // Pattern Recognition. – 2021. – Т. 117. – С. 107975.

горизонтальные или вертикальные фрагменты, из которых извлекаются значимые признаки. GRU напротив, рассматривает эти признаки как последовательность, изучая которую система определяет автора исследуемой рукописи. Описанный метод позволил авторам делать правильные прогнозы на уровне 96.5%.

Нельзя не упомянуть и применение сиамских нейронных сетей для решения задачи верификации автора рукописи. Подобную архитектуру в своих работах использовали специалисты Центра компьютерного зрения Автономного университета Барселоны<sup>1</sup>, а также В. Кумар и С. Сундарам<sup>2</sup>. Используя SNN, исследователи смогли достичь высокой точности прогнозирования в решении задачи верификации – 85.5% и 86.78% соответственно.

Существуют и более оригинальные предложения. Например, В. Сиюэ и Ц. Шицзе обратили внимание на то, что для обучения нейронной сети во многих работах используются как оригинальные, так и сфальсифицированные рукописи<sup>3</sup>. Однако по объективным причинам не всегда возможно получить доступ к образцам, которые имитируют оригинальные изображения. Это ставит вопрос о том, как обучать ИНС в таких условиях. Чтобы решить эту проблему, они предложили использовать генеративно-сопоставительную нейронную сеть. Их идея заключается в том, чтобы обучить дискриминатор распознавать оригинальные подписи исполнителя, тогда как поддельные изображения создаются генератором, который обучается максимально точно воссоздавать оригиналы. Именно на таких «поддельных» подписях дискриминатор учится отличать фальсификацию от настоящих подписей конкретных людей. Результаты экспериментов показали, что предложенный

---

<sup>1</sup> Dey S. et al. Signet: Convolutional siamese network for writer independent offline signature verification // arXiv preprint arXiv:1707.02131. – 2017.

<sup>2</sup> Kumar V., Sundaram S. Siamese based Neural Network for Offline Writer Identification on word level data // arXiv preprint arXiv:2211.14443. – 2022.

<sup>3</sup> Wang S., Jia S. Signature handwriting identification based on generative adversarial networks // Journal of Physics: Conference Series. – IOP Publishing, 2019. – Т. 1187. – №. 4. – С. 042047.

метод позволяет достичь высокой точности определения подлинности рукописи в 91.2%.

Последнее, на что хотелось обратить внимание, это работы, посвящённые интерпретации получаемых нейросетью результатов. Этот вопрос становится всё более актуальным и вызывает интерес у многих специалистов. Однако на данный момент исследований в этой области пока не так много.

Например, Х. Као и Ч. Вен использовали метод визуализации карт значимости<sup>1</sup>, предложенный К. Симонян, А. Ведальди и Э. Зиссермаи<sup>2</sup> для сверточных нейронных сетей. Суть данного способа интерпретации сводится к тому, чтобы на основе расчета производной полученного прогноза относительно входного изображения получить области, которые в наибольшей степени влияют на полученный результат. Иными словами, «... величина производной показывает, какие пиксели должны быть изменены в наименьшей степени, чтобы повлиять на оценку класса в наибольшей степени»<sup>3</sup>. Используя данный метод Х. Као и Ч. Вен продемонстрировали, что CNN после ее обучения на наборе «подлинных» и «поддельных» рукописей действительно использует некоторые закономерности почерка, а не сторонний шум изображения. Так, ими было выдвинуто утверждение, что: «... поворотная точка и пересечение штрихов часто используются в качестве важной основы для проверки подписи»<sup>4</sup>. Однако авторам не удалось определить, на сколько сильно выявленные нейросетью закономерности коррелируют с теми признаками почерка, которыми пользуются эксперты-почерковеды в своей работе.

---

<sup>1</sup> Kao H. H., Wen C. Y. An offline signature verification and forgery detection method based on a single known sample and an explainable deep learning approach // Applied Sciences. – 2020. – Т. 10. – №. 11. – С. 3716.

<sup>2</sup> Simonyan K. Deep inside convolutional networks: Visualising image classification models and saliency maps // arXiv preprint arXiv:1312.6034. – 2013.

<sup>3</sup> Там же – С. 1140–1141.

<sup>4</sup> Kao H. H., Wen C. Y. An offline signature verification and forgery detection method based on a single known sample and an explainable deep learning approach // Applied Sciences. – 2020. – Т. 10. – №. 11. – С. 3726.



Исправить этот недостаток попытался М. Марциновский, который предложил свою модель сверточной нейронной сети с максимальной степенью интерпретируемости<sup>1</sup>. Идея, лежащая в основе его работы, состоит в том, чтобы взять обычную сверточную нейронную сеть определенной архитектуры, к примеру VGG16, и заменить ее базовый классификатор на новый, состоящий из двух полносвязных слоев. Первый слой, принимающий информацию из сверточных слоев VGG16, состоит из 84 нейронов с сигмоидальной функцией активации. Каждый из этих нейронов соответствует определенному признаку почерка по системе, предложенной Р. Хубером и А. Хедриком<sup>2</sup>. Предполагается, что каждый из нейронов будет выдавать значение «0» или «1», тем самым сигнализируя об отсутствии либо наличии соответствующего признака в исследуемой рукописи. Таким образом, итоговый вектор из этой последовательности «0» и «1» передается в выходной полносвязный слой, состоящий из N-нейронов, где N – число предполагаемых авторов, образцы почерка которых были предоставлены системе для обучения. Как итог, финальный вектор ИНС выдает в качестве результата: «... вектор нулей с единственной «1», которая соответствует рассматриваемому автору (одна метка – идентификатор; множество классов – писатели)»<sup>3</sup>. Иными словами, идентификатор в виде «1» указывает на то проверяемое лицо, которое, как предполагается, является исполнителем исследуемой рукописи.

В ходе экспериментов автору удалось достичь точности получаемых результатов в 96–99%. Кроме того, он утверждает, что цель по интерпретации результатов, полученных с помощью нейросети, была им достигнута. Автор даже продемонстрировал это путем применения метода визуализации карт значимости, который описывался ранее. В то же время автор резонно указывает следующее: «... можно утверждать, что модель выучила умеренное

---

<sup>1</sup> Marcinowski M. Top interpretable neural network for handwriting identification // Journal of Forensic Sciences. – 2022. – Т. 67. – №. 3. – С. 1140–1148.

<sup>2</sup> Huber R. A. Handwriting Identification: Facts and Fundamentals. – 1999.

<sup>3</sup> Marcinowski M. Top interpretable neural network for handwriting identification // Journal of Forensic Sciences. – 2022. – Т. 67. – №. 3. – С. 1142.

количество неизвестных признаков, которые действительно совпадают по значению и частоте с характеристиками, которые мы определили. Эти признаки могут соответствовать характеристикам почерка или быть по крайней мере, сильно коррелировать с ними»<sup>1</sup>. Иными словами, М. Марциновский сам не до конца уверен в том, что модель использует именно те признаки почерка, которые были заданы исследователем.

Если затрагивать область диагностических исследований, где также стараются интерпретировать результаты работы ИНС, то можно вспомнить работу специалистов из Пекинского университета Цзяотун, в которой описано применение двухпутевой CNN с механизмом сверточного внимания<sup>2</sup> для дифференциации писателей по половому признаку путем анализа рукописных текстов<sup>3</sup>. Результаты экспериментов, проведенных авторами, демонстрируют, что их нейросетевая модель способна с достаточно высокой точностью определять, какие элементы изображения могут свидетельствовать о гендерной принадлежности исполнителя рукописи.

Кроме того, имеются исследования, в которых используется механизм вычисления «взвешенного значения по градиенту отображения активации класса»<sup>4</sup>. Данный способ схож с описанным методом визуализации карт значимости, однако если в последнем градиент рассчитывается относительно входного изображения, то в GradCAM это происходит относительно карт признаков, получаемых при анализе этого изображения сверточными слоями сети. Применительно к исследованию почерка данный метод был использован исследователями из Университета им. Бен-Гуриона для визуализации признаков, которые, как предполагается, позволяют

---

<sup>1</sup> Marcinowski M. Top interpretable neural network for handwriting identification // Journal of Forensic Sciences. – 2022. – Т. 67. – №. 3. – С. 1145.

<sup>2</sup> Woo S. et al. CBAM: Convolutional block attention module // Proceedings of the European conference on computer vision (ECCV). – 2018. – С. 3–19.

<sup>3</sup> Xue G. et al. ATP-DenseNet: a hybrid deep learning-based gender identification of handwriting // Neural Computing and Applications. – 2021. – Т. 33. – С. 4611–4622.

<sup>4</sup> Selvaraju R.R. et al. Grad-cam: Visual explanations from deep networks via gradient-based localization // Proceedings of the IEEE international conference on computer vision. – 2017. – С. 618–626.

дифференцировать документы, написанные в разные периоды истории. Благодаря этому методу авторы предположили, что: «...некоторых случаях сеть «просматривает» определенные буквы во входных данных, например, буквы «ламед» в византийском полуквадрате, «эй» в византийском квадрате, «бет», «реш» в восточном полуквадрате и «алеф» в восточном квадрате ... других случаях сеть ориентируется на глобальную компоновку участка, например, на все ашкеназские типы, итальянский квадрат и, в некоторой степени, сефардский полуквадрат»<sup>1</sup>. Иными словами, нейронная сеть ориентируется на определенные стили письма в рукописи.

Данный список исследований не является исчерпывающим. В настоящее время публикуется множество работ, посвященных использованию искусственных нейронных сетей для анализа почерка. Однако даже на основе этих публикаций можно сделать определённые выводы о современном состоянии этого научного направления, а также о его тенденциях и актуальных проблемах, что будет рассмотрено далее.

---

<sup>1</sup> Droby A. et al. Digital Hebrew Paleography: Script Types and Modes // Journal of Imaging. – 2022. – Т. 8. – №. 5. – С. 143.

## **ГЛАВА 2. ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ ТИПОВЫХ ЗАДАЧ СУДЕБНО-ПОЧЕРКОВЕДЧЕСКОЙ ЭКСПЕРТИЗЫ**

### **§ 2.1. Оценка текущего положения практики использования искусственных нейронных сетей для решения отдельных задач судебно-почерковедческой экспертизы**

#### **2.1.1. Общая оценка современного состояния темы**

В предыдущих разделах работы мы продемонстрировали, что тема интеграции искусственных нейронных сетей в область судебно-почерковедческой экспертизы имеет давнюю историю, причем как в отечественной практике, так и в зарубежной. Благодаря этому накоплен значительный теоретический и практический опыт в этой области. В частности, за счет развития систем биометрической идентификации и верификации личности по почерку были сформированы различные подходы к их проектированию и применению. Согласно последним обзорным исследованиям, научным публикациям, а также материалам международных конференций и симпозиумов, некоторые из них уже начали применяться в других странах для решения стандартных задач экспертизы почерка на уровне экспериментальных проектов<sup>1</sup>. Формирование целых подходов в изучении рукописных объектов с помощью ИНС и других компьютерных алгоритмов, а также их практическое применение, свидетельствует о высоком уровне теоретической и практической разработанности этой научной области.

Поэтому неудивительно, что, несмотря на значительные достижения в этом направлении, по-прежнему существует множество проблем разного уровня. Среди них можно выделить:

---

<sup>1</sup> Deviterne-Lapeyre M., Ibrahim S. Interpol questioned documents review 2019–2022 // Forensic Science International: Synergy. – 2023. – Т. 6. – С. 100300.

1) Обзор общих границ возможностей искусственного интеллекта и нейронных сетей в судебной экспертизе. Этот аспект изучался такими исследователями, как Е.Р. Россинская<sup>1</sup>, А.И. Хмыз<sup>2</sup>, В.Б. Вехов и П. С. Пастухов<sup>3</sup>, а также Д.В. Бахтеев<sup>4</sup> в контексте общей судебно-экспертной деятельности. Применительно к судебно-почерковедческой экспертизе и технической экспертизе документов этот вопрос рассматривался А.Ф. Купиным и А.С. Коваленко<sup>5</sup>, С.М. Бобовкиным, Я.А. Климовой и В.П. Полуниным<sup>6</sup>, а также Д.В. Бахтеевым<sup>7</sup>, А.А. Коляда<sup>8</sup> и А.Н. Охлупина<sup>9</sup>.

2) Правовое регулирование применения ИИ-алгоритмов в судебно-экспертной деятельности. Эту тему исследовали А.В. Кокин<sup>10</sup> и Ю.Д. Денисов<sup>11</sup>, которые анализировали алгоритмическую предвзятость в

<sup>1</sup> Россинская Е.Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы // Вестник Университета имени О.Е. Кутафина (МГЮА). 2024. № 3(115). С. 21–33.

<sup>2</sup> Хмыз А.И. Использование возможностей искусственного интеллекта в судебной экспертизе // Вестник экономической безопасности. 2022. № 5. С. 224–227.

<sup>3</sup> Вехов В.Б., Пастухов П.С. Искусственный интеллект в решении криминалистических задач // Государственное и муниципальное управление в России: состояние, проблемы и перспективы: Материалы Всероссийской научно-практической конференции, Пермь, 12 ноября 2020 года. – Пермь: Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации, 2020. – С. 8–16.

<sup>4</sup> Бахтеев Д.В. Искусственный интеллект в криминалистике: состояние и перспективы использования / Д. В. Бахтеев // Российское право: образование, практика, наука. – 2018. – № 2(104). – С. 43–49.

<sup>5</sup> Купин А.Ф., Коваленко А.С. К вопросу о возможностях применения систем искусственного интеллекта при криминалистическом исследовании документов и их реквизитов // Теория и практика судебной экспертизы. 2023. Т. 18. № 4. С. 28–35.

<sup>6</sup> Бобовкин С.М., Климова Я.А., Полуни В.П. Использование возможностей цифровой криминалистики (на примере судебно-почерковедческой экспертизы) // Вестник Волгоградской Академии МВД России. 2022. № 3 (62). С. 109–117.

<sup>7</sup> Бахтеев Д.В. Предэкспертная верификация подложных подписей: человеческий и машинный подходы // Российское право: образование, практика, наука. 2023. № 4. С. 4–10.

<sup>8</sup> Коляда А.А. О проблеме автоматизации почерковедческих исследований // Вопросы криминологии, криминалистики и судебной экспертизы. – 2019. – № 2(46). – С. 160–167.

<sup>9</sup> Охлупина А.Н. К вопросу о современных возможностях исследования объектов судебно-почерковедческой экспертизы. Вестник Московского университета МВД России. 2020(6):212–4.

<sup>10</sup> Кокин А.В. Судебная экспертиза в эпоху четвертой индустриальной революции (Индустрии 4.0) // Теория и практика судебной экспертизы. 2021. Т. 16. № 2. С. 29–36.

<sup>11</sup> Кокин А.В., Денисов Ю. Д. Искусственный интеллект в криминалистике и судебной экспертизе: вопросы правосубъектности и алгоритмической предвзятости // Теория и практика судебной экспертизы. 2023. Т. 18. № 2. С. 30–37.

программах и возможность предоставления ИИ правосубъектности. Кроме этого, стоит отметить О.И. Андрееву, В.В. Иванова, А.Ю. Нестерова и Т.В. Трубникову<sup>1</sup>, которые анализировали применение ИИ и нейросетей с точки зрения законодательства о персональных данных и допустимости их использования в качестве источника доказательственной информации по делу.

3) Организационно-тактические проблемы, связанные с привлечением специалистов по машинному обучению и анализу данных в судебно-экспертных исследованиях, а также с необходимостью расширения компетенций экспертов-почерковедов в связи с внедрением ИИ-технологий. Эти вопросы обсуждались Е.Р. Россинской<sup>2</sup> и С.М. Бобовкиным<sup>3</sup>.

4) Интеграция нейросетевых алгоритмов в общую методологию судебной экспертологии и в экспертные методики отдельных родов и видов судебной экспертизы. Этот аспект рассматривали Е.В. Чеснокова, А.И. Усов, Г.Г. Омелянюк и М.В. Никулина<sup>4</sup>, а также И.А. Лапина, Е.С. Карпухина и В.О. Кузнецов<sup>5</sup>.

Перечисленные вопросы являются важными и тоже будут рассмотрены в настоящей работе применительно к судебно-почерковедческой экспертизе. Тем не менее, на наш взгляд, сегодня более актуальными являются следующие проблемы:

– Интерпретируемость нейросетевых алгоритмов;

<sup>1</sup> Андреева О.И., Иванов В.В., Нестеров А.Ю., Трубникова Т.В. Технологии распознавания лиц в уголовном судопроизводстве: проблема оснований правового регулирования использования искусственного интеллекта // Вестник Томского государственного университета. – 2019. – № 449. – С. 201–212.

<sup>2</sup> Россинская Е.Р. Система теории цифровизации судебно-экспертной деятельности // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 20–32.

<sup>3</sup> Бобовкин С. М. Особенности формирования компетентности судебного эксперта при производстве почерковедческих экспертиз изображений рукописей // Криминологический журнал. 2024. № 1. С. 19–23.

<sup>4</sup> Чеснокова Е.В., Усов А.И., Омелянюк Г.Г., Никулина М.В. Искусственный интеллект в судебной экспертологии. // Теория и практика судебной экспертизы. 2023. Т. 18. № 3. С. 60–77.

<sup>5</sup> Усов А.И., Омелянюк Г.Г., Лапина И.А., Карпухина Е.С., Кузнецов В.О. Роль цифровой трансформации в развитии судебной экспертологии // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 47–57.

– Проблема постановки задачи и ее решения.

Несложно заметить, что они носят преимущественно технический характер и на первый взгляд могут показаться незначительными. Однако эти проблемы непосредственно влияют на возможность эффективной интеграции ИНС и иных подобных систем как в судебно-почерковедческую экспертизу, так и в судебно-экспертную деятельность в целом. Мы считаем, что прежде, чем пытаться решить более общие вопросы организационно-тактического, правового и методологического характера, необходимо разработать технически отлаженный прототип алгоритма, либо, по крайней мере, заниматься этими вопросами параллельно.

Не будем отрицать того факта, что перечисленные вопросы играют важную роль в процессе разработки данного алгоритма и нейросетевой системы в целом. Судебная экспертиза регулируется законом особенно строго, поэтому любые методы и технические средства, которые планируется внедрить в экспертную практику, должны соответствовать определённым критериям. Однако стараться проводить какие-либо обобщения, не имея реальной экспериментальной базы, представляется преждевременным. Именно поэтому мы выделили конкретно этот перечень основных технических проблем.

### **2.1.2 Проблема интерпретируемости искусственных нейронных сетей**

Наиболее важной и очевидной является возможность интерпретации результатов, полученных с помощью нейросетей и других схожих систем. Сам термин «интерпретация» происходит от латинского «interpretatio», что означает «разъяснение, истолкование»<sup>1</sup>. В контексте судебной экспертологии «интерпретируемость» можно рассматривать как возможность для других

---

<sup>1</sup> Интерпретация / [Электронный ресурс] // Научно-образовательный портал «Большая российская энциклопедия»: [сайт]. – URL: <https://bigenc.ru/c/interpretatsiia-bd27d1> (дата обращения: 11.03.2025).

участников судебного процесса понять и оценить заключение судебного эксперта. Рассмотрим это детальнее.

В соответствии со ст. 8 Федерального закона от 31 мая 2001 года № 73-ФЗ «О государственной судебно-экспертной деятельности в Российской Федерации», результаты экспертного исследования должны основываться на положениях, позволяющих проверить обоснованность и достоверность сделанных выводов на основе общепринятых научных и практических данных. Методология судебной экспертологии дополняет это законодательное требование. В частности, она предписывает, что применяемые в экспертизе методы должны отвечать критериям научной обоснованности, точности и надежности получаемых результатов. Кроме того, само заключение судебного эксперта должно содержать подробное описание исследования с указанием использованных методов<sup>1</sup>. Неотъемлемой частью заключения эксперта является иллюстративный материал, который наглядно показывает как процесс исследования, так и подтверждает полученные результаты и выводы, сделанные экспертом на их основе.

Все перечисленное делает исследование интерпретируемым, поскольку практически любой человек, в первую очередь другой специалист или эксперт, обладающий специальными знаниями в соответствующей области, может оценить достоверность и объективность экспертного заключения<sup>2</sup>. Именно поэтому в судебно-экспертной деятельности важное значение придаётся не только конечному результату, полученному с использованием определённых методов, но также и подробному объяснению причин, вследствие которых был получен именно этот результат, а не какой-либо другой. В рамках СПЭ это означает, что эксперт выявляет, описывает и оценивает наиболее важные для решения поставленной перед ним задачи общие, частные и диагностические признаки почерка. Отражение этого процесса в тексте экспертного заключения

---

<sup>1</sup> Основы судебной экспертологии: учебно-методическое пособие – М.: ФБУ РФЦСЭ при Минюсте России, 2023. – С. 317–327.

<sup>2</sup> Также это позволяет проверить, насколько соответствует схема решения поставленной экспертной задачи типовой методике исследования.



позволяет другим людям понять, насколько обоснованы и достоверны выводы эксперта-почерковеда.

Однако при использовании нейросетевых алгоритмов мы сталкиваемся с проблемой интерпретируемости полученных результатов. Преимущественно это связано с тем, что в модели используется большое количество искусственных нейронов и синаптических связей между ними, которые, как было показано ранее, являются ее основными параметрами. Также нельзя забывать, что эти параметры не отвечают за конкретные признаки объектов. Во время обучения сети любой из нейронов или группа нейронов могут обнаружить какую-либо закономерность в данных и использовать её для прогнозирования. Либо наоборот, эта закономерность может быть полностью проигнорирована. Бывают и ситуации, когда весь прогноз может строиться на активации одного единственного нейрона, как это было показано в исследовании компании Apple<sup>1</sup>. Перечисленные факторы, а также сложность исследуемых данных, затрудняет выявление признаков, на основе которых ИНС рассчитывает итоговые результаты.

Таким образом, то, что позволяет нейросетевым алгоритмам решать задачи, которые трудно алгоритмизировать, одновременно препятствует глубокому пониманию механизма их работы. Мы можем знать архитектуру сети, процесс обработки данных в ней и другие особенности её функционирования. Однако понимание того, какие именно закономерности выявляет нейросеть, как они влияют на точность прогнозов и какие параметры модели отвечают за анализ конкретных участков данных, представляет собой весьма трудоемкую задачу. По сути, нейросеть, обученная на конкретном наборе данных, сама становится объектом для исследования.

Конечно, можно пойти по пути «наименьшего сопротивления», как предлагают некоторые исследователи. Их аргументация строится на том, что если программа работает эффективно, даже несмотря на невозможность её

---

<sup>1</sup> Yu M. et al. The super weight in large language models // arXiv preprint arXiv:2411.07191. – 2024.

интерпретации, то в конечном счёте эта интерпретация для системы становится в принципе необязательной. К примеру, как указывают Б. Гарретт и С. Рудински, некоторые технические специалисты выступают против интерпретируемых систем, опасаясь, что это может негативно сказаться на точности прогнозов<sup>1</sup>.

Эта позиция во многом согласуется с общей тенденцией зарубежной практики по математизации судебно-почерковедческой экспертизы, что хорошо видно на примере последних исследований, научных отчетов и докладов. Например, в докладе NAS прямо указано, что для подтверждения надёжности и воспроизводимости используемых методов в СПЭ необходимо провести их количественную оценку<sup>2</sup>. Конечно, такой подход к математизации и компьютерной автоматизации процесса экспертного исследования почерка может способствовать его объективизации. Об этом говорят и некоторые отечественные исследователи. К примеру, А.Ф. Купин в своем недавнем исследовании продемонстрировал, как при помощи обычных программных вычислительных средств можно дифференцировать нажимные характеристики штрихов, а также измерять кривизну элементов письменных знаков<sup>3</sup>. Нельзя не согласиться, что эти признаки имеют высокую степень информативности.

Однако излишняя математизация, на наш взгляд, приводит к сложности в оценке заключения эксперта лицами, не обладающими специальными знаниями, но являющимися участниками рассматриваемого дела. В подтверждение этого можно вновь обратиться к исследованию Б. Гарретта и

---

<sup>1</sup> Garrett B. L., Rudin C. Interpretable algorithmic forensics // Proceedings of the National Academy of Sciences. – 2023. – Т. 120. – №. 41. – С. e2301842120.

<sup>2</sup> National Research Council et al. Strengthening forensic science in the United States: a path forward. – National Academies Press – 2009. – С. 328

<sup>3</sup> Купин А.Ф. Применение пакета прикладных программ matlab при производстве судебных почерковедческих экспертиз // Цифровые технологии современной криминалистики, использование специальных знаний: Материалы конференции, проведенной в рамках XXVII Международной выставки средств обеспечения безопасности государства «Интерполитех-2023», Москва, 18 октября 2023 года. – М.: Московская академия Следственного комитета Российской Федерации, 2024. – С. 179–185.

С. Рудински. Они установили, что суды зачастую безоговорочно принимают в качестве доказательств результаты судебных экспертиз, в которых использовались не поддающиеся интерпретации алгоритмы. Однако результаты, полученные с помощью таких систем, могут быть недостоверными. Как показывает практика, даже самые точные аналитические системы могут совершать ошибки, особенно если в их основе лежит самообучающийся алгоритм. К сожалению, уже имеются прецеденты, когда суды принимали неверные решения, основываясь на ошибочных прогнозах не интерпретируемых биометрических систем<sup>1</sup>. Похожую тенденцию отмечают и отечественные исследователи. Например, Ш.Н. Хазиев и А.Н. Штохов указывают, что в последнее время наблюдается увеличение числа ошибочных биометрических идентификаций, по фактам которых назначаются судебные экспертизы<sup>2</sup>.

Справедливости ради необходимо сказать, что биометрические и иные подобные программные комплексы изначально разрабатываются как средство оперативной идентификации и верификации личности. Поэтому они в целом не должны выполнять функцию по объяснению своих выводов. Однако если такие программы начнут применять в судебной экспертизе без необходимой адаптации, то это может привести к увеличению количества ошибочных заключений.

Отсутствие интерпретируемости также не позволяет выявлять так называемые «галлюцинации» у ИНС и иные схожие явления. Последние исследования в этой области показывают, что нейросети склонны делать выводы, основываясь не на реальных данных, а на случайных помехах, посторонних объектах в структуре данных, метаданных и иной прочей информации<sup>3</sup>. Также нередки случаи, когда алгоритм слишком сильно

---

<sup>1</sup> Garrett B. L., Rudin C. Interpretable algorithmic forensics // Proceedings of the National Academy of Sciences. – 2023. – Т. 120. – №. 41. – С. e2301842120.

<sup>2</sup> Хазиев Ш.Н., Штохов А.Н. Судебные экспертизы по делам об ошибочной биометрической идентификации. 2024. Т. 19. № 3. С. 88–102.

<sup>3</sup> В качестве примера см. Baker B. et al. Monitoring reasoning models for misbehavior and the risks of promoting obfuscation //arXiv preprint arXiv:2503.11926. – 2025.

акцентирует внимание на отдельных участках данных, игнорируя при этом другую, потенциально полезную информацию, как это было показано в уже упомянутом исследовании Appel.

Резюмируя, можно с уверенностью утверждать, что для успешного внедрения ИНС в судебно-почерковедческую экспертизу необходимо их интерпретировать. Как выражаются зарубежные коллеги, нужно сделать нейросеть «прозрачным ящиком». На сегодня существует множество различных способов интерпретации результатов, получаемых при помощи ИИ-систем<sup>1</sup>. В предыдущем разделе мы ознакомились с некоторыми работами, которые были посвящены этой теме в контексте исследования почерка. Однако авторы этих исследований не были полностью уверены в своих выводах. Действительно, как показывают эксперименты в области компьютерного зрения, при обработке одного и того же изображения разные модели могут выделять разные важные участки<sup>2</sup>. При этом они могут показывать сопоставимые результаты по точности прогнозирования. Несложно понять, что данный факт потенциально может отрицательно сказаться на процессе стандартизации и выработке единого подхода к выявлению и описанию признаков почерка.

Однако сегодня, благодаря развитию искусственных нейронных сетей с механизмом внимания, появилась возможность использовать этот вычислительный прием для более точной интерпретации полученных результатов. Поэтому в рамках нашего экспериментального исследования, которое будет описано далее, первая задача заключается в том, чтобы определить, насколько сильно результаты интерпретации нейронных сетей, полученные с помощью attention, совпадают с реальными признаками почерка. Как показывают некоторые немногочисленные исследования в этой области,

---

<sup>1</sup> Шевская Н.В. Объяснимый искусственный интеллект и методы интерпретации результатов // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, № 2(33).

<sup>2</sup> Das A. et al. Human attention in visual question answering: Do humans and deep networks look at the same regions? // Computer Vision and Image Understanding. – 2017. – Т. 163. – С. 90–100.

подобные механизмы действительно могут предоставить полезную информацию.

### 2.1.2. Проблема постановки задачи и ее решения.

Вторая проблема является более сложной и комплексной<sup>1</sup>. Для того чтобы лучше в ней разобраться, рассмотрим типовую схему проектирования и обучения нейронных сетей, которая состоит из следующих основных этапов (рис. 10)<sup>2</sup>:



Рисунок 10. Процесс проектирования моделей в машинном обучении

1) Определение задачи. На этом этапе формируется основа проекта<sup>3</sup>: устанавливается цель, которую должна решить нейросеть, предварительно выбирается ее архитектура и анализируемые данные. Ранее мы упоминали, что сегодня существует множество областей, в которых применяются ИНС.

<sup>1</sup> Следует подчеркнуть, что далее по тексту основное внимание будет уделено задачам, связанным с криминалистической идентификацией, которые наиболее часто встречаются в современной практике судебно-почерковедческой экспертизы.

<sup>2</sup> Fenner M. Machine learning with Python for everyone. – Addison-Wesley Professional, 2019.

<sup>3</sup> Проект в данном контексте – это деятельность, направленная на разработку и использование нейросетевой модели для достижения конкретных целей. Проект включает в себя этапы планирования, выбора архитектуры нейросети, анализа данных и реализации модели. Примерами проектов могут служить научные исследования, программные комплексы или бизнес-идеи, где нейросеть решает определённые задачи.

Однако, когда речь заходит в целом о постановке задачи и типовой схеме её решения, то обычно выделяют основания, представленные в Приложении №2. Сюда обычно относят классификацию, регрессию, снижение размерности данных и т. д. Именно эти задачи во многом определяют общий подход к практической реализации конкретного проекта.

2) Сбор обучающих данных. Когда задача и общий подход к ее решению определены, начинается процесс сбора обучающих данных. Этот этап также является важным, поскольку, как неоднократно упоминалось, нейронные сети и другие алгоритмы машинного обучения обычно самостоятельно вырабатывают правила обработки данных в процессе своего обучения. Это отличает их от классических компьютерных программ, где логика работы с входной информацией прописывается специалистом заранее. Поэтому от количества и качества собранных данных напрямую зависит итоговая точность и эффективность разрабатываемой модели.

3) Проектирование архитектуры. Хотя внутреннее устройство нейросети проектируется преимущественно во время постановки задачи, это не означает, что оно остаётся неизменным на протяжении всего исследования. По большей части на первом этапе формируется лишь общее представление о том, как можно ее можно решить. Конкретные детали и нюансы определяются в процессе выполнения различных этапов проекта. Поэтому они могут меняться с течением времени. На основе таких постепенных изменений как правило и происходит эволюционирование способов решения наиболее типовых задач в машинном обучении.

4) Обучение и оценка модели. Это завершающая часть всего проекта, поскольку на основе полученных результатов решается, насколько эффективным является избранный на предыдущих этапах подход. Именно оценка полученных результатов позволяет определить, что разработанная ИНС может быть использована в практической деятельности. Если же модель не справляется с поставленной перед ней задачей, особенно на контрольной выборке, выясняются причины, по которым это происходит. Таких причин

может быть множество, начиная от проблем, связанных с самой архитектурой нейросети, заканчивая проблемами предварительной подготовки данных перед их анализом. Также может выясниться, что собранная информация в целом непригодна для решения поставленной задачи или сама постановка задачи оказывается неверной, что может привести к полному пересмотру проекта.

Теперь, опираясь на описанную выше схему, подробнее рассмотрим современный типовой подход к проектированию и обучению ИНС для решения задачи, связанной с идентификацией человека по рукописи. Начнем с самой постановки задачи.

Согласно общей теории криминалистики<sup>1</sup> и положениям судебной экспертологии<sup>2</sup>, идентификацией является процесс установления индивидуально-конкретного тождества объекта<sup>3</sup>. Если масштабировать это определение до судебно-почерковедческой экспертизы, то согласно ГОСТ Р 59508–2021 «Судебно-почерковедческая экспертиза. Термины и определения» идентификационной задачей является: «Установление с использованием методики судебно-почерковедческой идентификационной экспертизы конкретного исполнителя рукописи либо факта выполнения разных рукописей одним и тем же лицом, либо разными лицами в соответствии с вопросами, поставленными перед экспертом органом или лицом, назначившими экспертизу». Упрощая, можно говорить о следующих возможностях экспертизы почерка<sup>4</sup>:

– определить, действительно ли человек, чьи образцы предоставлены для сравнительного исследования, является исполнителем исследуемой

<sup>1</sup> Криминалистика: учебник / Т. В. Аверьянова, Р. С. Белкин, Ю. Г. Корухов, Е. Р. Россинская. 4-е изд., перераб. и доп. М.: Норма: ИНФРА-М, 2023.

<sup>2</sup> Россинская Е.Р. Теория судебной экспертизы (Судебная экспертология): учебник / Е.Р. Россинская, Е.И. Галяшина, А.М. Зинин; под ред. Е.Р. Россинской. 2-е изд., перераб и доп. М.: Норма: ИНФРА-М, 2025.

<sup>3</sup> Мультимодальное издание «Судебная экспертиза: перезагрузка». Часть II. Энциклопедический словарь теории судебной экспертизы. – М.: ЭКОМ, 2012. – С. 109–110.

<sup>4</sup> Судебно-почерковедческая экспертиза документов: учеб.-практ. пособие / М. В. Жижина; под ред. Е. П. Ищенко. М.: Юрлитинформ, 2006.

рукописи. При этом, согласно типовой методике экспертного идентификационного исследования, эта задача может решаться даже в случаях, когда представленный на экспертизу текст, подпись или краткая запись выполнены с подражанием почерку другого человека<sup>1</sup>;

– установить, что две и более исследуемых рукописей выполнены одним либо разными лицами. При этом, согласно упомянутой методики, это также можно сделать в случаях подражания чужому почерку<sup>2</sup>;

Нельзя не отметить и процедуру сопоставления между собой предоставленных образцов для сравнения, поскольку в силу различных причин может выясниться, что рукописи, якобы выполненные одним автором, на самом деле написаны разными лицами.




Рисунок 11. Типичная схема системы биометрической идентификации исполнителя рукописи

Теперь рассмотрим, как смежные задачи ставятся и решаются в сфере биометрии, которая также занимается вопросами исследования почерка. Для начала стоит указать, что биометрия выделяет две категории отдельных задач: идентификация и верификация<sup>3</sup>. Согласно ГОСТ Р 54412–2019 (ISO/IEC TR

<sup>1</sup> Подробнее см., например, Типовые экспертные методики исследования вещественных доказательств. Ч. I / Под ред. канд. техн. наук Ю.М. Дильдина. Общая редакция канд. техн. наук В. В. Мартынова. – М.: ЭКЦ МВД России, 2010.

<sup>2</sup> Однако на практике это довольно сложная задача, поскольку такие почерковые объекты обычно содержат не так много полезной информации.

<sup>3</sup> Брюхомицкий Ю.А. Биометрические технологии идентификации личности: учебное пособие / Ю. А. Брюхомицкий: Южный федеральный университет. Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2017.



24741:2018) «Информационные технологии. Биометрия. Общие положения и примеры применения» биометрическую идентификацию можно определить как процесс обработки компьютерной системой входных биометрических данных (например, подписи) с целью поиска совпадающих биометрических контрольных шаблонов в базе данных биометрических регистраций. Проще говоря, биометрическая система проверяет, есть ли исследуемый образец в базе данных. Иначе это можно определить как процесс сравнения по схеме «одни ко многим» (рис. 11). Причем обычно результатом такого поиска является ранжированный список наиболее вероятных авторов.

Верификация, согласно положениям ГОСТ ISO/IEC 24713-1-2013 «Информационные технологии. Биометрические профили для взаимодействия и обмена данными. Часть 1. Общая архитектура биометрической системы и биометрические профили», представляет собой процесс, при котором программа производит сравнение исследуемого образца с некоторым шаблоном либо контрольным образцом. В контексте исследования почерка верификацию можно описать как процедуру сопоставления исследуемой подписи с одним или несколькими образцами для сравнения, которые были предоставлены конкретным человеком.

На первый взгляд все перечисленные процедуры сильно похожи друг на друга. Однако при детальном рассмотрении можно выявить их некоторые существенные отличия. Для начала сопоставим биометрическую и криминалистическую идентификации. С одной стороны, схема работы идентификационных биометрических систем «один ко многим» хорошо согласуется с общей методологией почерковедения. Как отмечала В. Ф. Орлова: «Количественная методика, предполагающая идентификацию исполнителя, также может быть построена на базе алгоритма дифференциации на два класса»<sup>1</sup>. Нельзя не отметить, что на основе алгоритмов разделения

---

<sup>1</sup> Орлова В.Ф. и др. Судебно-почерковедческая экспертиза: общая часть // Теоретические и методические основы (Под науч. ред. ВФ Орловой, 2-е изд., РФЦСЭ при Минюсте РФ. – М.: Наука. – 2006. – С. 312–320.

объектов на два класса можно создать метод, позволяющий классифицировать объекты на любое конечное количество категорий (рис. 12). Иными словами, задачу криминалистической и биометрической идентификации можно упростить до бинарной или многоклассовой классификации.




Рисунок 12. Схема дифференциации на три и более классов.

Действительно, наиболее часто в судебно-почерковедческой экспертизе ставится вопрос: «Выполнена ли рукопись от имени ФИО проверяемым лицом?». И на этот вопрос можно дать только два объективных ответа: «да» или «нет»<sup>1</sup>. Если эксперт приходит к положительному выводу, то задача считается решённой. В противном случае мы<sup>2</sup> ищем нового предполагаемого исполнителя и проверяем его по той же схеме. Вся процедура поиска происходит до тех пор, пока не будет найден истинный исполнитель рукописи. Этот процесс напоминает дерево решений, где поиск осуществляется от корневого узла к листьям. Похожий принцип идентификации используется в биометрических системах, основанных на «классических» алгоритмах принятия решений.

Однако, когда мы говорим о самообучающихся программах, такие как нейронные сети, мы обнаруживаем, что с ними описанный принцип работает несколько хуже. Эксперт, будучи человеком, который постоянно взаимодействует с окружающей средой и имеет субъективный опыт, по

<sup>1</sup> Мы намеренно упрощаем возможные формы выводов, поскольку они в большей степени относятся к процессу конкретного экспертного исследования и объектам этого исследования.

<sup>2</sup> Подразумеваются органы следствия и суд.

умолчанию предполагает, что представленная на экспертизу рукопись может быть выполнена не проверяемым лицом. То же самое подразумевается и в самой методике исследования, когда предлагается разделить объекты на два класса, ведь в реальности объективно истинными могут только две ситуации: либо рукопись или ее фрагмент была выполнена конкретным человеком, либо нет<sup>1</sup>.

В свою очередь самообучающиеся машины не имеют собственного субъективного опыта взаимодействия с окружающим миром. Они работают и обучаются только на тех данных, которые ей предоставлены человеком. Соответственно, весь ее «опыт» ограничен обучающей выборкой. Если говорить более формально, то, когда нейросеть обучается классифицировать определённое множество объектов<sup>2</sup>, она разделяет их на определённые группы. Каждая группа соответствует образцам почерка одного из предполагаемых исполнителей, что можно рассматривать в качестве «биометрического шаблона» – усредненный образ всех данных, характерный для конкретного класса. Этот шаблон не является явным, поскольку представляет собой определенные числовые значения весов синапсов.

При обработке новых данных, таких как исследуемые рукописи, нейросеть «сравнивает» их с этим неявным шаблоном, пытаясь найти соответствие между исследуемым образцом и известными ей классами объектов. Обычно это выражается в виде многомерного вектора, который показывает, насколько вероятно, что образец относится к определённому классу. Если исполнителем нового образца почерка является одно из проверяемых лиц, то идентификация проходит без проблем.

Проблемы возникают в случае, когда рукопись была написана «неизвестным» человеком, чьи образцы почерка по объективным причинам не

---

<sup>1</sup> Аналогичное предусматривается и при разработке биометрических систем верификации и идентификации, построенных на применении классических алгоритмов. Подробнее см., например, Баланов А.Н. Биометрия. Разработка и внедрение систем идентификации: учебное пособие для вузов / А. Н. Баланов. – Санкт-Петербург: Лань, 2024.

<sup>2</sup> Здесь речь идет именно о классификации, а не о делении объектов на классы, как это реализуется, например, в алгоритме К-ближайших соседей.

использовались для обучения нейронной сети. В силу этого система не знает о существовании еще одного потенциального автора. Однако, из-за особенностей своего внутреннего устройства, основанного на принципах классификации объектов, модель относит исследуемую рукопись к автору с наиболее похожим почерком, что приводит к ошибочному выводу. Именно об этой проблеме писал Л.Г. Эджубов, говоря следующее: «Алгоритмы подобного класса предназначены для решения задачи дихотомии, т. е. разделения множества объектов на два (и более – *прим.*) класса. Нельзя не заметить, что задача дихотомии не совпадает с задачей, стоящей обычно перед экспертом при идентификации»<sup>1</sup>.

Действительно, если обратиться к последним исследованиям в этой области, то можно обнаружить, что средняя точность нейросетей, построенных по принципу классификации потенциальных исполнителей, составляет от 90 до 100% на тестовой подвыборке обучающих данных<sup>2</sup>. Однако если для тестирования используется другой набор данных, на котором нейросеть не обучалась или обучалась частично, то средняя точность прогнозирования снижается<sup>3</sup> примерно на 10–20%<sup>4</sup>.

Из этого следует, что машина с высокой точностью может распознавать преимущественно только тех авторов, чьи образцы почерка использовались для обучения. Если исследуемая рукопись была выполнена не одним из проверяемых лиц, а сторонним человеком, то модель с высокой долей вероятности отнесёт её к автору с наиболее схожим почерком. Как уже

---

<sup>1</sup> Журавель А.А., Трошко Н.В., Эджубов Л.Г. Использование алгоритма обобщенного портрета для опознания образов в судебном почерковедении // Правовая кибернетика. – М.: Наука. – 1970. – С. 215.

<sup>2</sup> Hameed M. M. et al. Machine learning-based offline signature verification systems: A systematic review // Signal Processing: Image Communication. – 2021. – Т. 93. – С. 116139.

<sup>3</sup> Похожая ситуация наблюдалась в одном из наших исследований, см. Мищук В.А. Использование модуля сверточного внимания для интерпретации результатов работы сиаамской нейронной сети при идентификации рукописных подписей // Теория и практика судебной экспертизы. 2025. Т. 20. № 1.

<sup>4</sup> Необходимо уточнить, что исследователи либо прямо заявляли о том, что их система не предназначена для выявления «неизвестных» авторов, либо вносили изменения в алгоритм прогнозирования, чтобы попытаться решить эту задачу.

упоминалось, это происходит главным образом потому, что у нейросети нет представления о других возможных классах/авторах, чьи образцы не использовались для обучения и не могут быть использованы по объективным причинам. Система ограничена только обучающей выборкой, что повышает вероятность возникновения ошибок второго рода.

Важно подчеркнуть, что здесь мы в первую очередь говорим о программной реализации дихотомических алгоритмов. Сама по себе дихотомия теоретически допустима в методике экспертного исследования. Однако на уровне самообучающейся программы её реализация вызывает ряд сложностей, особенно если следовать наиболее распространенному подходу, описанному ранее.

Структура:

→Подлинные подписи:

- Наименование папки: 001, 002, 003, ..., NNN
- Каждая папка содержит 10 подлинных изображений подписей конкретного пользователя.
- Пример:
  - 001 содержит 10 подлинных изображений подписи пользователя 001.
  - 002 содержит 10 подлинных изображений подписи пользователя 002.

→Поддельные подписи:

- Наименование папки: 001\_forg, 002\_forg, 003\_forg, ..., NNN\_forg
- Каждая папка содержит 10 поддельных изображений подписей соответствующего пользователя.
- Пример:
  - 001\_forg содержит 10 поддельных изображений подписи пользователя 001.
  - 002\_forg содержит 10 поддельных изображений подписи пользователя 002.

Рисунок 13. Типичная структура набора данных, используемого для решения задачи идентификации рукописей

Конечно, можно рассмотреть возможность создания ещё одного класса, в котором будут собраны изображения рукописей множества авторов. Например, если обратиться к структуре наиболее популярных наборов данных для биометрической идентификации личности по почерку, то можно заметить, что в каждом классе представлено два подкласса: «оригинальные» изображения рукописей конкретного автора и их фальсификации,

выполненные иными людьми (рис. 13). Однако здесь необходимо учесть два важных аспекта:

– Во-первых, такой подход трансформирует идентификационную задачу в диагностическую, которая будет нацелена на выявление признаков, указывающих на подлинность исследуемого образца. Другими словами, задача сводится к определению, является ли рукопись оригинальной или поддельной. В свою очередь криминалистическая идентификация направлена на установление индивидуально-конкретного тождества, т. е. на определение конкретного автора рукописи, даже если она выполнена с подражанием чужому почерку. Сегодня ни одна из существующих открытых баз данных не предназначена для решения подобной задачи;

– Во-вторых, важной проблемой остаются свойства человеческого почерка. Несмотря на его уникальность для каждого человека, существует вероятность высокого его сходства между разными авторами. Это может привести к ситуации, когда почерк настоящего исполнителя окажется похожим на почерк другого лица. В таком случае нейронная сеть по-прежнему остается уязвимой к ошибкам второго рода, особенно если условный класс «подделок» был составлен недостаточно качественно и значительно отличается от анализируемой рукописи. Более того, из-за вариационности признаков почерка и влияния различных внутренних и внешних сбивающих факторов возможно возникновение обратной ситуации, когда система, обученная на «старых» образцах рукописи конкретного автора, не сможет распознать «актуальный» почерк человека.

Если говорить о попытке решить задачу криминалистической идентификации путем ее представления в виде задачи биометрической верификации, которая подразумевает прямое сравнение исследуемой рукописи с контрольным шаблоном, то здесь тоже есть определенные ограничения. Прежде всего, верификация концептуально предполагает два важных аспекта:

– В биометрических системах верификации сравнение осуществляется только между неизвестным экземпляром рукописи и контрольным шаблоном,

исполнитель которого нам известен. То есть мы не можем сравнить между собой две рукописи неизвестных исполнителей. Технически это можно реализовать, но тогда возникает вторая проблема;

– Как мы выяснили, процесс верификации подразумевает, что один из экземпляров сравниваемой пары, а именно контрольный шаблон, должен быть подлинным. Поэтому в нём обычно отсутствуют диагностические признаки, которые указывали бы на необычные условия его выполнения и, следовательно, на его неподлинность. В свою очередь, исследуемый образец может быть как подлинным, так и поддельным. В последнем случае он с высокой долей вероятности будет содержать признаки необычного выполнения. Из-за этого мы снова приходим к задаче бинарной классификации – распределению подлинных и неподлинных рукописей на две группы. Вследствие этого возникают все проблемы, которые мы рассмотрели ранее.

Кроме того, как показывают последние исследования в области верификации личности по почерку с использованием нейросетей, подобные проекты также сталкиваются с проблемой обобщения и зависимости алгоритма от набора данных. К примеру, некоторые исследователи отмечают, что точность прогнозирования системы при тестировании на других данных может снижаться на 20–40%<sup>1</sup>.

Здесь мы переходим ко второму аспекту, который затрудняет адаптацию современных нейронных сетей к задачам судебно-почерковедческой экспертизы. Многие современные ИНС обучаются решать конкретные задачи на основе больших объёмов разнообразных данных. Проще говоря, «глобально». Такой подход хорошо зарекомендовал себя в других областях науки. Однако в судебной экспертизе, особенно в судебно-почерковедческой, эксперт имеет дело с ограниченным набором данных, который обладает уникальными особенностями. Как мы видели на примерах, нейросети могут быть чувствительны к подобным типам данных. Поэтому нет полной гарантии,

---

<sup>1</sup> Ruiz V. et al. Off-line handwritten signature verification using compositional synthetic generation of signatures and Siamese Neural Networks // Neurocomputing. – 2020. – Т. 374. – С. 30–41.

что модель, обученная на одном наборе условных подписей, будет так же точно прогнозировать результаты на другом наборе.

Тут уместно вспомнить слова Е.Р. Россинской, которая отметила: «Если модель была обучена год назад, то факты, которые имели место за последний год, ей недоступны для оперирования, поэтому процесс обучения и верификации должен осуществляться на постоянной основе с разумной периодичностью»<sup>1</sup>. В случае судебно-почерковедческой экспертизы, учитывая вариационность почерка, подобная верификация и «обновление» ИНС будут происходить слишком часто. Это, скорее всего, не позволит создать стабильную работающую систему, поскольку её придётся постоянно обучать заново на актуальной в конкретный момент времени информации.

Исходя из вышеизложенного, можно сделать вывод, что на данном этапе развития нейронных сетей попытки решить криминалистические идентификационные задачи путём их представления как задач классификации авторов не представляются эффективными. Теоретически, можно создать систему, которая будет работать с большим количеством потенциальных исполнителей, однако это, вероятно, потребует значительных ресурсов для обучения и обслуживания подобной нейронной сети. Поэтому, на наш взгляд, более целесообразным является сосредоточение усилий на локальных способах обработки данных и обучении нейросети на тех образцах, которые непосредственно предоставлены эксперту для исследования. Это и есть вторая задача нашего экспериментального исследования.

### **2.1.3. Постановка задачи экспериментального исследования и используемые данные**

В следующем разделе мы подробно рассмотрим структуру нейросетевых моделей, которые будут использованы для решения задач интерпретации и локальной обработки данных в контексте криминалистической

---

<sup>1</sup> Россинская Е.Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы // Вестник Университета имени О.Е. Кутафина (МГЮА). 2024. № 3(115). – С. 31.



идентификации. Здесь же мы сосредоточимся на самой постановке задачи и данных, которые будут задействованы в экспериментальном исследовании.

На протяжении всей работы мы неоднократно подчеркивали, что в настоящее время одной из наиболее распространенных задач является криминалистическая идентификация человека по его подписи<sup>1</sup>. Принимая во внимание методологию судебно-почерковедческой экспертизы, а также существующие экспертные методики и научные работы в этой области, становится ясно, что процесс идентификации возможен даже в тех случаях, когда исследуемая подпись выполнена с подражанием чужому почерку. Поэтому неотъемлемой частью нашего эксперимента является имитация подписей некоторых участников, а также получение экспериментальных образцов подписей от них же.

| Номер набора данных | ОБУЧАЮЩАЯ ВЫБОРКА     |                                |                                                              | ТЕСТОВАЯ ВЫБОРКА                  |                                                              |                                                       |
|---------------------|-----------------------|--------------------------------|--------------------------------------------------------------|-----------------------------------|--------------------------------------------------------------|-------------------------------------------------------|
|                     | Число проверяемых лиц | Общее число обучающих образцов | Число предоставленных образцов от каждого из проверяемых лиц | Общее число исследуемых рукописей | Число исследуемых рукописей, выполненных проверяемыми лицами | Число исследуемых рукописей, выполненных иными лицами |
| №1                  | 3                     | 420                            | 140                                                          | 80                                | 60 (по 20 рукописей от каждого исполнителя)                  | 20 (выполнены одним лицом)                            |
| №2.1 <sup>2</sup>   | 5                     | 500                            | 100                                                          | 400                               | 200 (по 100 рукописей от каждого исполнителя)                | 200 (по 100 рукописей от каждого исполнителя)         |
| №2.2 <sup>16</sup>  | 4                     | 400                            | 100                                                          | 500                               | 200 (по 100 рукописей от каждого исполнителя)                | 300 (по 100 рукописей от каждого исполнителя)         |
| №3                  | 3                     | 120                            | 40                                                           | 100                               | 0                                                            | 100 (выполнены одним лицом)                           |

Таблица 1. Используемые в работе наборы данных

<sup>1</sup> Использование подписи в качестве основного объекта исследования удобно и в плане вычислительной мощности, поскольку с графической точки зрения подпись представляет собой «цельный» объект небольшого размера.

<sup>2</sup> Наборы №2.1 и 2.2 представляют собой часть одного большого набора данных. В экспериментах они использовались как контрольные выборки друг для друга. Остальные наборы данных имеют свои собственные тестовые выборки.

Таким образом, для проведения экспериментального исследования мы подготовили четыре набора данных, которые имеют следующую структуру (таблица 1) (см. Приложение №12):

– Обучающий набор, который представляет собой экспериментальные образцы подписей, выполненные проверяемыми лицами. Каждая подпись разделена на две части: основную обучающую подвыборку, которая составляет 70%, и тестовую, предназначенную для предварительного тестирования модели, составляющую 30%. Тестовый набор необходим для оценки эффективности обучения нейронной сети и выявления возможных признаков переобучения модели;

– Контрольный набор данных, представляющий собой подписи, которые «были предоставлены эксперту на исследование». В этот набор входят как «подлинные» образцы подписей проверяемых лиц (в том числе и выполненные с подражанием чужому почерку), так и подписи, выполненные другими людьми, чьи образцы отсутствуют в обучающей выборке. Иными словами, этот набор данных служит для оценки работы модели по двум ключевым параметрам: 1) насколько точно модель распознает «известные» ей образцы подписей, выполненных проверяемых лиц; 2) насколько эффективно обученная ИНС может выявлять «сторонние» подписи, исполнителей которых она не знает.

В нашем исследовании мы решили не использовать свободные образцы подписей проверяемых лиц, так как считаем, что это может усложнить процесс обучения нейросети из-за значительных различий в транскрипции между свободными и экспериментальными образцами подписей<sup>1</sup>. Хотя это

---

<sup>1</sup> Также важно уточнить, что в своей работе мы ориентируемся только на результаты экспериментальных исследований, полученных другими исследователями, занимающихся проблемой интеграции ИНС в область судебно-почерковедческой экспертизы (описано в предыдущем разделе), а также немногочисленную практику применения программы «ОКО-1» в экспертной практике для исследования малообъемных рукописей. Объясняется подобная эмпирическая база тем, что ИНС является сравнительно новым алгоритмом, который еще не использовался в реальной практике производства судебно-почерковедческой экспертизы. Надо заметить, что эксперты-почерковеды в целом с недоверием относятся к количественным и иным математическим методам исследования

потенциально может повлиять на точность прогнозирования, использование только экспериментальных образов, как предполагается, позволит обучаемой нейросети сосредоточиться на анализе сопоставимых подписей.

Поскольку обучающая выборка была ограничена (не более 150 изображений каждого класса), мы решили увеличить разнообразие данных, применив рандомизированные геометрические преобразования (масштабирование и вращение). Качественно это не влияет на исходное состояние подписей. Однако из-за различных числовых значений пикселей в первоначальной и обработанной подписи на каждом участке заставляет нейронную сеть адаптировать во время обучения свои параметры так, чтобы обобщить данные, а не просто запомнить их.

Также все изображения конвертированы в градации серого цвета, чтобы минимизировать влияние посторонних факторов, таких как фон и цвет материала письма, на итоговый результат классификации.

## **§ 2.2. Возможные подходы применения искусственных нейронных сетей для решения задачи идентификации исполнителя подписи.**

### **Архитектура нейросетевых моделей**

#### **2.2.1. Общая схема решения задачи**

Базируясь на положениях и данных, приведенных в предыдущем разделе, нами предлагается следующая общая схема обучения и использования искусственной нейронной сети, предназначенной для криминалистической идентификации автора исследуемой подписи (рис. 14):




Рисунок 14. Общая схема обучения и использования искусственной нейронной сети, предназначенной для криминалистической идентификации автора исследуемой рукописи

1) Предварительная подготовка данных. Если проводить аналогию с общей методикой идентификационного экспертного исследования, то этот этап можно сравнить со стадией предварительного исследования. Отличие заключается в дополнительной работе с самими данными, а именно с исследуемой рукописью и образцами для сравнительного анализа. Помимо сканирования или фотографирования и внесения их в память компьютера, необходимо провести их предварительную обработку, некоторые варианты которой будут рассмотрены далее.

2) Создание нейронной сети и ее обучение. Поскольку процесс идентификации включает в себя сравнение признаков, обнаруженных в исследуемом объекте, с признаками, выявленными в предоставленных образцах для сравнения, нейронная сеть, используемая для решения этой задачи, также должна быть способна проводить сопоставление всех изучаемых объектов.

Для этой цели хорошо подходят сиамские нейронные сети, которые в последнее время стали активно применяться для анализа рукописей и выявления подделок. В отличие от «классических» искусственных нейронных сетей, которые работают по принципу классификации объектов, SNN предназначены для сопоставления пар объектов. Такие системы обычно используются для биометрической верификации. Однако благодаря собранным данным и некоторым изменениям в алгоритме прогнозирования мы

адаптировали сиамскую нейросеть для решения задач криминалистической идентификации.




Рисунок 15. Устройство и схема работы сиамской нейронной сети

В целом, математический принцип работы SNN заключается в использовании двух нейронных сетей с общими обучаемыми параметрами<sup>1</sup>. Эти сети кодируют похожие объекты похожими векторами, как показано на рисунке 5. Это достигается путем преобразования указанных объектов в векторы определённой размерности. По сути, нейронная сеть выполняет задачу по снижению размерности входных данных определённым образом.

Так, если сравниваемые между собой объекты принадлежат к одному классу, то их векторы, описывающие эти объекты, должны быть сопоставимы по определённым критериям. Например, если рассматривать такую метрику, как евклидово расстояние, то объекты будут похожи друг на друга только тогда, когда расстояние между их векторами в N-мерном пространстве стремится к нулю. Напротив, если объекты относятся к разным классам, то описывающие

<sup>1</sup> Эта особенность и дала название этой структуре – сиамская нейронная сеть. Хотя на самом деле это больше теоретическое название, поскольку на практике обычно используется одна и та же нейросеть.

их вектора будут находиться на расстоянии, пропорциональном степени их различия.

Подводя итог, можно сказать, что идея и процесс обработки данных в SNN заключаются в двух основных моментах:

- Кодирование входных данных определённым образом. Результатом такого кодирования становится вектор меньшей размерности, который представляет объект в более сжатом виде. Причем этот вектор может иметь любую желаемую размерность и хранить любые числовые значения. Главное, чтобы он адекватно описывал исходные данные.

- Сравнение полученных векторов по определённому критерию.

Благодаря перечисленным особенностям для SNN обычно не имеет значения, были ли образцы конкретного класса в обучающей выборке. В нашем случае это означает, что даже если образцы конкретного автора отсутствуют в обучающем наборе данных, система всё равно сможет их закодировать. Окончательный прогноз в любом случае основывается не на одном итоговом векторе, полученном при анализе конкретного экземпляра данных, а на сравнении этого вектора с векторами других объектов. Как итог, в результате сравнительного исследования появляется потенциальная возможность определить, была ли исследуемая рукопись написана одним из предполагаемых авторов, чьи образцы почерка использовались для обучения SNN, или же её написал кто-то другой.

Нельзя не отметить и высокую гибкость устройства SNN, поскольку в качестве базовой вычислительной системы можно использовать ИНС с практически любой архитектурой. Если исследуемые данные являются изображениями, то в качестве основы можно использовать сверточные нейронные сети, такие как VGG, ResNet и другие. Если же данные имеют вид последовательности векторов, как это часто бывает в машинном переводе и обработке естественного языка, то можно применять рекуррентные нейросети и другие подобные архитектуры.

Единственными значительными недостатками сиамских нейросетей являются более сложная процедура обучения и значительный объем вычислений, необходимых для работы системы. Поэтому, чтобы повысить эффективность модели, можно разделить весь процесс обучения на два этапа. Так как SNN фактически представляет собой единую нейросеть, на первом этапе целесообразно применить классический подход к классификации исполнителей рукописей<sup>1</sup>. Это позволит системе получить базовое представление о данных и научиться предварительно различать их. Затем обученный фрагмент такого «классификатора» можно использовать в качестве основы для SNN. Последнюю, в свою очередь, можно дообучить<sup>2</sup>, чтобы она решала задачу сопоставления объектов.

Весь описанный процесс можно сравнить с аналитической стадией экспертного исследования, за исключением того, что выявление и анализ признаков почерка проводится нейросетью.

3) Сравнение исследуемой рукописи с образцами всех предполагаемых авторов. Чтобы обеспечить более объективные результаты, мы применили схему сравнения, которая обычно используется в «классических» биометрических системах, не основанных на нейронных сетях. Эта схема предполагает создание явного шаблона для сопоставления<sup>3</sup>, который формируется на основе образцов рукописей, предоставленных проверяемым

---

<sup>1</sup> Фактически на этом этапе мы обучаем кодирующую часть нейронной сети (encoder), которая отвечает за извлечение признаков почерка и уменьшение их размерности.

<sup>2</sup> Дообучение искусственной нейронной сети – процесс дальнейшего обучения предварительно натренированной нейросети на новых данных, относящихся к той же или смежной задаче. Этот метод позволяет адаптировать сеть под новые условия или улучшать её точность в конкретной области. Благодаря этому достигается сохранение ранее приобретённых общих знаний и возможность эффективного переноса опыта для решения новых специализированных задач.

<sup>3</sup> Необходимость создания такого шаблона объясняется тем, что в традиционной схеме биометрической верификации применяется метод сравнения «один к одному», то есть сопоставление исследуемого объекта с контрольным образцом. Однако в почерковедении, учитывая вариационность почерка, такой подход с большой вероятностью окажется неэффективным.

лицом<sup>1</sup>. В дальнейшем система сравнивает все новые входные данные с этим шаблоном, что будет продемонстрировано далее<sup>2</sup>.

Мы не первые предложили подобную схему решения. Например, в 2016 г. А.И. Иванов, А.И. Газин, Е.И. Качайкин и Д.Ю. Андреев разработали похожую схему, которая также во многом основана на общей методике судебно-почерковедческой экспертизы<sup>3</sup>. Основное отличие нашей схемы заключается в типе используемых данных и постановке задачи. Исследователи в своей работе сосредоточились на выявлении факта фальсификации подписи человека. При этом в качестве обучающих данных они использовали «подлинные» образцы подписи и их фальсифицированные версии, которые были выполнены самими исследователями. В контексте методики экспертного исследования это можно рассматривать как подготовку экспериментальных образцов экспертом-почерковедом<sup>4</sup>. В нашей работе мы ориентируемся в принципе на идентификацию автора рукописи независимо от того, является она подлинной или поддельной, а также используем для обучения системы только предоставленные образцы для сравнительного исследования.

### 2.2.2. Процедура сравнения

Для проведения сравнительного анализа и принятия решения мы задействовали четыре различных метода, которые применялись независимо друг от друга (Приложение №13). Первые два из них основаны на прямом сопоставлении исследуемой подписи с заранее подготовленным шаблоном данных, процедура формирования которого описана ниже. Два других метода построены на использовании «классических» алгоритмов машинного

---

<sup>1</sup> В некоторых исследованиях, где для идентификации автора рукописи используются нейронные сети, применяется похожая схема сравнения. Например, см. в Chen Z. et al. Level online writer identification // International Journal of Computer Vision. – 2021. – Т. 129. – №. 5. – С. 1394–1409.

<sup>2</sup> Мы также использовали схемы, основанные на методе опорных векторов. Более подробную информацию см. далее.

<sup>3</sup> Иванов А.И., Газин А.И., Качайкин Е.И., Андреев Д.Ю. Автоматизация почерковедческой экспертизы, построенная на обучении больших искусственных нейронных сетей // Модели, системы, сети в экономике, технике, природе и обществе. – 2016. – № 1(17). – С. 249–257.

<sup>4</sup> Нельзя не заметить, что подобный подход потенциально может быть неэффективным в силу перечисленных ранее свойств почерка человека.



обучения, таких как ON-SVM и SGD SVM – вариации классического метода опорных векторов, в котором применяется упомянутый ранее стохастический градиентный спуск. Рассмотрим все эти методы по порядку:

1) Сравнение на основе косинусного сходства векторов. Этот метод является одним из наиболее удобных в использовании. В отличие от евклидова расстояния, где диапазон возможных значений может варьироваться от нуля до бесконечности, результаты, полученные с помощью косинусного сходства, находятся в пределах от «-1» до «1»<sup>1</sup>. Если результат близок к «1», это свидетельствует о высокой степени сходства между векторами. Следовательно, две сравниваемые рукописи, вероятно, были написаны одним и тем же автором. Значения, сильно отличающиеся от «1», находящиеся, например, в промежутке от «0.5» до «-1», указывают на значительные различия между векторами. Это в свою очередь, свидетельствует о том, что рукописи, скорее всего, были созданы разными людьми.

Учитывая вариационность почерка, мы не можем просто сравнить исследуемую рукопись с одним контрольным образцом, написанным проверяемым лицом, и на основе этого сравнения делать какие-либо выводы. Это потенциально может привести к ошибке. Кроме того, наше исследование в этом случае не будет полным и всесторонним, так как мы проигнорируем признаки, которые встречаются в других сравнительных образцах. Поэтому в нашей схеме мы провели несколько операций, чтобы создать типовой шаблон для последующего сравнения.

В частности, после обучения нейронной сети все элементы обучающей выборки сопоставляются между собой. Цель этой процедуры – собрать статистические данные о распределении прогнозов по всем возможным классам. Поскольку полученные значения находятся в диапазоне от «-1» до

---

<sup>1</sup> Здесь и далее мы описываем процедуру, которая использовалась только для полных сиамских нейронных сетей (см. текст ниже). В моделях, где применялся вектор прогноза, полученный с помощью полносвязного классификатора, не проводилось сопоставление всех образцов друг с другом. Вместо этого все результаты сразу усреднялись, после чего формировалась таблица типового шаблона.

«1», для каждого экземпляра данных можно определить, на образцах каких классов он получает то или иное значение. Например, при сравнении с образцами из одного класса можно ожидать, что большинство результатов будут находиться в пределах от «0.9» до «1». С другой стороны, при сравнении с изображениями из других классов эти значения могут находиться, например, в диапазоне от «-1» до «0.5–0.7».

При этом ожидается, что статистические значения сравнения изображений с одним классом будут сопоставимы. Например, при сравнении экспериментальных образов подписи из выборки №1 (потенциальный автор №1) с экспериментальными образцами из выборки №2 (потенциальный автор №2) наиболее часто встречаемым результатом будет «0.25». В свою очередь, при сопоставлении изображения из выборки №1 с изображениями из выборки №3 наиболее часто будет встречаться прогноз «-0.5».

На основе этих данных можно составить таблицу распределения значений сравнения. Например, для экземпляра данных №1 из выборки №1 при его последовательном сравнении со всеми остальными элементами обучающей выборки получится вектор вида «[0.95, 0.20, -0.45]». Из него видно, что исследуемый образец с высокой степенью вероятности выполнен первым проверяемым лицом, что фактически так и есть.

Можно предположить, что при последующем сравнении остальных рукописей, предоставленных предполагаемым исполнителем №1, будут получены схожие векторы. Путем их усреднения, а также проведения описанных операций над всеми остальными экземплярами подписей, предоставленных другими авторами, можно получить таблицу размера  $N \times N$ , где  $N$  означает количество классов, то есть всех проверяемых лиц. Это и есть базовый шаблон, с которым будет сравниваться исследуемая рукопись.

Такая сложная схема формирования типового шаблона обусловлена необходимостью минимизировать влияние сравнительных образцов, которые по разным причинам могут давать локальные всплески принадлежности к другим классам. В то же время, чтобы сохранить эти всплески, помимо

типового шаблона, создается аналогичная таблица, в которой содержатся не усреднённые значения принадлежности к классу, а стандартное отклонение для каждой возможной позиции.

Сам процесс сравнения исследуемой рукописи с шаблоном осуществляется в два этапа:

- Во-первых, исследуемая рукопись сравнивается со всеми образцами, предоставленными потенциальными авторами, по описанной ранее схеме. Результатом этого сравнения становится вектор размером  $1 \times N$ , где каждый элемент  $N$  представляет степень возможной принадлежности к определённому классу.

- Во-вторых, полученный вектор с помощью косинусного сходства последовательно сравнивается с каждой строкой типового шаблона. В результате сопоставления формируется вектор  $N \times 1$ , каждый элемент которого находится в диапазоне от «-1» до «1». Итоговый прогноз вычисляется путем выбора одного максимального элемента, значение которого должно превышать определенный порог. Например, если полученный вектор имеет вид «[0.95, 0.2, -0.2]» при пороге «0,9», это означает, что наиболее вероятным исполнителем исследуемой рукописи является автор №1. Во всех остальных случаях, когда ни одно из значений не превышает установленный порог или несколько значений его превышают, считается, что рукопись, предоставленная на экспертизу, не была выполнена ни одним из проверяемых лиц.

2) Сравнение на основе среднего значения и стандартного отклонения. Этот метод сравнения во многом повторяет ранее описанные операции. Отличие заключается в том, что здесь прогнозы, полученные в результате анализа исследуемой рукописи и сравнительных образцов, сравниваются напрямую. Решающую роль в этом методе играют не только средние значения таблицы типового шаблона, но и стандартные отклонения этих значений.

Например, если вектор, полученный при анализе исследуемого образца, имеет вид «[0.95, 0.2, -0.2]», а одна из строк таблицы содержит значения «[0.9, 0.3, -0.1]» со стандартными отклонениями «[0.05, 0.1, 0.05]», то считается, что

эта рукопись выполнена проверяемым лицом №1, так как практически все соответствующие значения попадают в интервал  $\ll[0.9 \pm 0.05, 0.3 \pm 0.1, -0.1 \pm 0.05]\gg$ .

При этом в качестве порога используется количество позиций, которые можно отбросить при сравнении. Например, можно заметить, что значение  $-0.1$  не входит в интервал  $-0.1 \pm 0.05$ . Однако, учитывая возможные погрешности в вычислениях, результатами по этой позиции можно пренебречь при формировании итогового прогноза.

3) Метод опорных векторов для одноклассовой классификации. В отличие от двух предыдущих подходов к сравнению, метод одноклассового SVM не использует таблицу шаблонов усреднённых значений, а ориентирован на выявление аномалий. То есть, мы не усредняем результаты сопоставления элементов обучающей выборки между собой, а используем их непосредственно для обучения SVM.

Причем для повышения точности прогнозов обучается не одна модель SVM, а несколько – по количеству проверяемых лиц. Так каждая модель учится распознавать только одного предполагаемого автора, тогда как остальных она считает посторонними, т. е. «аномалией». Такой подход позволяет более точно сформировать область принятия решения в  $N$ -мерном пространстве, поскольку множество, образованное при анализе одного предполагаемого автора, может сильно влиять на множество другого. Например, одно множество может находиться слишком близко или далеко от всех остальных, что может привести к образованию пространства, которое алгоритм посчитает областью верных прогнозов. В эту область могут попасть сторонние образцы, что может привести к ошибке.

Сам процесс принятия решения во многом похож на предыдущие методы сравнения: исследуемая рукопись сопоставляется со всеми обучающими данными, а результаты усредняются до вектора  $1 \times N$ . Затем этот вектор последовательно и независимо анализируется моделями ON-SVM, в результате чего получается вектор  $1 \times N$ , состоящий из множества « $-1$ » и одной

единственной «1». Позиция этой «1» в векторе и определяет, кем из проверяемых лиц была выполнена исследуемая рукопись.

При этом, как и в случае использования метрики косинусного сходства, если было получено несколько меток принадлежности к определенному автору или все результаты оказались отрицательными, исследуемая рукопись считается выполненной не одним из проверяемых лиц.

4) Метод опорных векторов для одноклассовой классификации с использованием стохастического градиентного спуска. Этот метод полностью повторяет ранее описанный подход, основанный на ON-SVM. Отличие заключается лишь в применении SGD, который, как ожидается, способен повысить точность прогнозов.

### **2.2.3. Интерпретация полученных результатов**

Для интерпретации и визуализации полученных результатов мы независимо друг от друга использовали вариации моделей с тремя механизмами внимания, которые в своей основе базируются на применении сверточных блоков. Объясняется это тем, что в этой работе мы анализируем изображения подписей. В связи с этим наиболее эффективным является применение именно attention, построенного на CNN, так как это потребует меньших вычислительных ресурсов, также позволит учитывать пространственную информацию. Мы выбрали следующие attention:

1) Self-Attention на CNN. Как было указано в предыдущем разделе, впервые механизм самовнимания был реализован в архитектуре Transformer, разработанной в 2017 г. Принцип работы Self-Attention построен на проведении следующих операций (Приложение №9)<sup>1</sup>:

– Проекция входных данных. Каждое входное значение независимо преобразуется тремя полносвязными слоями нейронов, формируя три вектора: запрос (Query – Q), ключ (Key – K) и значение (Value – V). Эти векторы

---

<sup>1</sup> Vaswani A. et al. Attention is all you need // Advances in neural information processing systems. – 2017. – Т. 30.

представляют собой различные аспекты входной информации, необходимые для определения внутренних взаимосвязей в ней.

– Вычисление карты внимания. Для определения того, насколько один элемент входной информации релевантен другому, вычисляется скалярное произведение между вектором запроса (Q) одного элемента и вектором ключа (K) другого элемента. После этого к полученным значениям применяется функция активации softmax. Так алгоритм вычисляет карту внимания (attention map), которая показывает, насколько сильно один элемент входных данных связан со всеми остальными. Высокие значения в карте внимания указывают на сильную взаимосвязь и, следовательно, большую важность для дальнейшей обработки.

– Взвешивание значений. Полученная карта внимания используется в качестве весов для векторов значений (V). Умножая карту внимания на матрицу V, мы получаем взвешенное представление входной последовательности. Элементы, на которые модель обратила больше внимания (согласно карте внимания), вносят больший вклад в итоговое представление.

– Выходное представление. После агрегирования взвешенных значений получается выходное представление, которое аккумулирует наиболее релевантную информацию из входной последовательности с учетом установленных взаимосвязей.

Описанный механизм позволяет модели Transformer эффективно обрабатывать последовательные данные, учитывая контекст каждого элемента и его связь с остальными элементами последовательности.

Однако в «классическом» варианте Self-Attention требует значительных вычислительных ресурсов компьютера, что затрудняет его адаптацию для решения задач компьютерного зрения. Несмотря на некоторые успешные проекты с использованием архитектуры Transformer в этой области, она по-прежнему слабо оптимизирована для работы с изображениями.

Чтобы сократить потребление ресурсов при обработке этого типа данных, Х. Чжан, Я. Гудфеллоу, Д. Метаксас и О. Одена предложили заменить

полносвязные слои на блоки свертки (Приложение №15)<sup>1</sup>. При этом значения  $Q$  и  $K$  определяются как в обычном Self-Attention, но их размер соответствует массивам, обрабатываемым CNN.

Для расчета карты внимания массивы  $Q$ ,  $K$  и  $V$  преобразуются в стандартные для Self-Attention размеры, после чего выполняются все описанные ранее операции. Итоговое выходное представление преобразуется до формы входных данных и используется для дальнейших вычислений.

Для интерпретации полученной карты внимания она также приводится к форме, аналогичной входной информации. Затем значения по каналам внимания нормализуются и усредняются, что позволяет получить единую карту, которую можно масштабировать до исходного изображения.

2) Cross-Attention. Этот механизм внимания был разработан специалистами факультета компьютерных наук и инженерии Университета штата Нью-Йорк в Буффало (Приложение №17)<sup>2</sup>. По своей структуре он напоминает Self-Attention, но с одной важной модификацией. Этот вид внимания можно реализовать только в сямской архитектуре нейронной сети, так как для вычисления  $Q$  используется один экземпляр данных, а для  $K$  и  $V$  – другой экземпляр, с которым осуществляется сравнение. Это позволяет определить, насколько сильно отдельные участки одного изображения коррелируют с участками другого.

Чтобы получить полное представление о возможной взаимной корреляции двух изображений, используется один блок Cross-Attention. Этот блок последовательно вычисляет внимание сначала для одного объекта относительно другого, а затем для другого относительно первого. Как показали исследователи в своей работе, такой подход демонстрирует, какие схожие признаки присутствуют в сравниваемой паре изображений.

---

<sup>1</sup> Zhang H. et al. Self-attention generative adversarial networks // International conference on machine learning. – PMLR, 2019. – С. 7354–7363.

<sup>2</sup> Shaikh M. A. et al. Attention based writer independent verification // 2020 17th International Conference on Frontiers in Handwriting Recognition (ICFHR). – IEEE, 2020. – С. 373–379.

3) Модуль сверточного внимания. Этот вид attention был разработан в 2018 г. С. Ву, Ч. Паком, Ч. Ли и И. Квоном (Приложение №16)<sup>1</sup>. В отличие от модулей Self- и Cross-Attention, которые обычно применяются для обработки последовательностей или установления связей между различными входными данными, СВАМ напрямую использует свойства карт признаков, генерируемых сверточными слоями, для определения наиболее важных элементов в ней. Иными словами, СВАМ представляет собой механизм внимания, специально разработанный для сверточных нейронных сетей.

Основной принцип работы СВАМ заключается в последовательном применении двух взаимодополняющих блоков внимания: канального внимания и пространственного внимания.

Блок канального внимания фокусируется на определении того, какие каналы в карте признаков являются наиболее информативными. Для этого входная карта признаков сжимается в пространстве с помощью операций глобального среднего и глобального максимального pooling, создавая два векторных представления размерностью  $C \times 1 \times 1$ , где  $C$  – количество каналов. Эти векторы затем проходят через общую небольшую многослойную полносвязную нейросеть, после чего результаты поэлементно складываются и пропускаются через сигмоидную функцию активации. Полученные веса применяются к исходной карте признаков, масштабируя важность каждого канала. Таким образом, блок канального внимания позволяет сети выделять наиболее значимые типы признаков, обнаруженных сверточными фильтрами.

Блок пространственного внимания, в свою очередь, определяет, где именно в карте признаков расположены наиболее важные пространственные области. На вход этого блока поступает карта признаков, вычисленная блоком канального внимания. Пространственное сжатие информации осуществляется путем применения операций максимального и среднего pooling вдоль канальной оси, благодаря чему мы получаем две двумерные карты признаков

---

<sup>1</sup> Woo S. et al. CBAM: Convolutional block attention module // Proceedings of the European conference on computer vision (ECCV). – 2018. – С. 3–19.



размерностью  $1 \times H \times W$ , где  $H$  и  $W$  – высота и ширина карты признаков. Эти карты конкатенируются и обрабатываются одним сверточным слоем, после чего применяется сигмоидная функция активации для получения карты пространственного внимания. Умножение этой карты на входную карту признаков позволяет выделить пространственно значимые регионы.

Комбинированное применение канального и пространственного внимания позволяет СВМ эффективно выявлять как наиболее важные признаки, так и их точное пространственное расположение, что, как уверяют создатели, способствует улучшению производительности CNN в различных задачах компьютерного зрения.

#### **2.2.4. Модели искусственных нейронных сетей, созданные в рамках экспериментального исследования**

Обобщая все ранее изложенные концепции, мы разработали четыре базовые модели:

1) Обычная сверточная нейронная сеть на основе ResNet (Приложение №14). Эта архитектура известна благодаря использованию так называемых «остаточных блоков», которые обеспечивают лёгкую оптимизацию нейросети независимо от её глубины, то есть количества слоёв. Это способствует повышению качества обучения системы, минимизируя эффект «затухающих градиентов». В нашем исследовании данная нейросеть служит основой для оценки влияния интегрированных модулей внимания на точность прогнозирования.

2) Архитектура, построенная на использовании Self-Attention (Приложение №15). Устройство данной сети во многом полностью повторяет архитектуру оригинальной нейросети Transformer, а именно ее кодировщика. Исключением является только то, что все возможные блоки были заменены на сверточные блоки. В частности, следующий после Self-Attention вычислительный блок, состоящий из небольшого полносвязного слоя, был заменен на остаточный сверточный блок с последующей нормализацией выходных значений.

Помимо этого, после некоторых слоев Self-Attention и остаточного блока применялась операция максимального pooling, чтобы постепенно нейросеть могла выявлять более общие признаки в данных. Мы также отказались реализации от Multi-Head Attention – модуля, который объединяет несколько блоков Self-Attention для параллельных вычислений и получения разных представлений об анализируемой информации. Это решение обусловлено высокой вычислительной стоимостью Multi-Head Attention.

Благодаря этому подходу нами была создана нейронная сеть, состоящая из 12 слоёв сверточного Self-Attention. При этом, после каждого уровня полученная карта внимания сохраняется для последующего анализа, не связанного с обучением модели.

3) CNN с модулями CBAM (Приложение №16). В этой архитектуре процесс обработки данных осуществляется с использованием базовой архитектуры ResNet и модулей CBAM, интегрированных на разных уровнях этой сети.

Причем важно подчеркнуть, что в отличие от модели с Self-Attention, в этой нейросети модули CBAM не передают информацию с определённого уровня нейросети последующим слоям. Это было сделано для того, чтобы карты внимания, выявляемые блоком attention, оказывали минимальное влияние на результаты работы этих слоёв. Предполагается, что такой прием позволит извлекать максимум информации из изображения, выявляя как «глубинные» признаки объекта, так и «высокоуровневые», то есть наиболее общие. Фактически, наши блоки attention служат «хранилищем» наиболее важных признаков, полученных с разных уровней базовой нейросети, что обеспечивает практически такой же анализ входного изображения, как и в обычной ResNet. В свою очередь, модули CBAM выявляют и сохраняют наиболее значимую информацию с этих уровней.

Поскольку полученные карты внимания различаются по размеру из-за признаков, извлечённых с разных уровней ResNet, они интерполируются до размера наибольшей карты внимания. Это позволяет в дальнейшем

производить их более точное масштабирование до размеров исходного анализируемого изображения. Таким образом, мы можем накладывать выявленные карты внимания на изображение исследуемого объекта с минимальными искажениями, что потенциально даёт возможность визуально определить наиболее информативные участки рукописи. После интерполяции все полученные карты объединяются в один массив, который обрабатывается финальным модулем СВМ для определения наиболее значимых признаков. В результате классификатор, устройство которого будет описано далее, должен вычислять прогноз на основе наиболее значимой информации о признаках почерка исследуемой рукописи, а не всего массива возможных данных.

4) Архитектура, основанная на Cross-Attention. Нейронная сеть с этим механизмом внимания во многом повторяет структуру модели с Self-Attention (Приложение №17). Разница заключается только в том, что ИНС с Cross-Attention выполняется только в сиамском варианте из-за вычислительных особенностей, которые были описаны ранее. В связи с этим, модель с модулем обучается полностью «с нуля», т. е. у нее нет первичного представления об анализируемых подписях из обучающей выборки.

Если говорить об устройстве классификатора в описанных нейросетях, то здесь нами было реализовано два подхода:

- Первый базируется на использовании обычного полносвязного классификатора (далее – FC). Чтобы приспособить его для решения задачи криминалистической идентификации, мы сделали его, а также в целом саму нейросеть частично сиамской в соответствии со схемой, описанной в первой настоящего раздела. В частности, после обучения нейросети на определённом наборе данных, мы проанализировали все образцы для сравнительного исследования. Результаты этого анализа в дальнейшем использовались либо для обучения ON-SVM и SGD ON-SVM, а также для создания типового шаблона для каждого предполагаемого исполнителя;

- Второй подход основан на преобразовании обученных моделей в вариант с сиамской архитектурой, который состоит из предварительно

обученного кодировщика и двух полносвязных слоев нейронов. Последние преобразуют информацию, полученную из последнего слоя кодировщика, в вектор размером  $1 \times 128$ . После этого все имеющиеся данные последовательно сопоставляются между собой, как это было описано ранее.

Таким образом у нас в общем счете имеется семь разновидностей базовых нейросетевых моделей, которые сначала учатся анализировать исходные образцы подписей, предоставленные проверяемыми лицами, а затем проходят тестирование на контрольной выборке.

В качестве функции потерь для обучения наших нейросетей использовали категориальную кросс-энтропию (Cross Entropy Loss) для FC-моделей, и функцию потерь, вычисленную на основе косинусного сходства (Cosine Embedding Loss) для сиамских нейросетей. В качестве оптимизатора использовалась модификация стохастического градиентного спуска – оптимизатор Adam. Обучение проходимо в течение 60 эпох для FC-моделей и в течение 110 циклов для SNN (60 эпох для обучения encoder-блока и 50 для обучения самой нейросети).

## **§ 2.3. Анализ и оценка результатов применения искусственной нейронной сети в решении задачи идентификации исполнителя подписи**

### **2.3.1. Оценка точности модели**

Для оценки эффективности моделей мы использовали критерии, указанные в таблице 2. Сама оценка и процедура тестирования проводились в три этапа:

– На первом этапе оценивалась общая эффективность модели по результатам обучения. Осуществлялось это при помощи тестовой подвыборки, выделенной из общего обучающего набора. Благодаря этому определялось, насколько эффективно модели в целом могут осуществлять классификацию экспериментальных образцов подписи, предоставленных потенциальными исполнителями.

– На втором этапе мы проводили обычное тестирование, которое осуществлялось на контрольном наборе данных, где помимо «известных» нейросети авторов содержались имитации подписей, выполненных другими лицами. Суть обычного тестирования заключается в выявлении порога, при котором модель делает минимум ошибок первого и второго рода. Эта процедура проводилась путем последовательного анализа всех данных из контрольного набора данных. Выбирая определенный порог, все модели делали прогнозы, после чего производился расчет ошибок первого и второго рода. Так, постепенно повышая порог, выявлялся оптимальный, при котором достигался минимальный EER.

– На третьем этапе определялось, как на точность модели влияет отсутствие «негативных» примеров. Идея заключается в том, что на предыдущем этапе тестирования ввиду наличия образцов подписей, на которых модель не обучалась, можно опытным путем подобрать такой порог, при котором нейросеть будет уверенно выявлять «чужие» образцы подписей. Однако в реальном экспертном исследовании вся выборка ограничена теми образцами, которые были предоставлены эксперту для проведения сравнительного исследования. Иными словами, у нас отсутствуют «негативные» примеры данных, тогда как сама исследуемая рукопись существует в условиях «неопределенности». Поэтому, чтобы попробовать преодолеть эту проблему, нами было проведено выявление такого порога, при котором нейросеть достигает максимальной точности принятия решения при анализе образцов, предоставленных проверяемыми лицами. После выявления этого порога на тестовой выборке определялось, насколько сильно модель отклоняется от классификации потенциально известных данных, так и насколько уверенно она выявляет те образцы, которые были выполнены сторонними авторами.

|               |                                                                    | Прогноз                                           |                                                   |                                               |
|---------------|--------------------------------------------------------------------|---------------------------------------------------|---------------------------------------------------|-----------------------------------------------|
|               |                                                                    | Положительный                                     | Отрицательный                                     |                                               |
| Целевая метка | Подлинная (образец, выполненный автором, известным нейронной сети) | Верная идентификация (TP)                         | Ложноотрицательная ошибка – ошибка 1-го рода (FN) | $FRR = \frac{FN}{TP + FN}^1$                  |
|               | Сторонняя                                                          | Ложноположительная ошибка – ошибка 2-го рода (FP) | Верное выявление стороннего образца (TN)          | $FAR = \frac{FP}{TN + FP}^2$                  |
|               |                                                                    | $ACC = \frac{TP+TN}{TP+TN+FP+FN}^3$               |                                                   | $ERR^4$ , определяется как: $FRR \approx FAR$ |

Таблица 2. Критерии, используемые для оценки эффективности моделей

В результате проведенных экспериментов были получены данные, представленные в Приложениях №18–25. Начнем с результатов обучения самих моделей. Как можно видеть по таблице в Приложении №18, все модели достигли приемлемых и сопоставимых между собой результатов. В частности, среднее значение точности принятия решения составляет  $95.73 \pm 5.45\%$  при значении  $LOSS^5$  в  $0.07621 \pm 0.08047$ . Причем не было замечено, чтобы модели, построенные по принципу классификации, как-то существенно превосходили siamoские нейронные сети либо наоборот. В частности, на первом видеел моделей точность достигает  $96.78 \pm 3.38\%$  при  $LOSS$  в  $0.09986 \pm 0.09042$ , тогда как у SNN эти показатели достигают  $94.94 \pm 6.60\%$  и  $0.05847 \pm 0.06983$  соответственно.

<sup>1</sup> False Rejection Rate (FRR) – коэффициент ложного отказа, который показывает, как часто система не признает подлинность зарегистрированного в ней пользователя (ошибка 1-го рода).

<sup>2</sup> False Acceptance Rate (FAR) – коэффициент ложного доступа, который показывает, как часто система ошибочно идентифицирует посторонний образец как одного из зарегистрированных пользователей (ошибка 2-го рода).

<sup>3</sup> Accuracy (ACC) – общая точность системы, которая рассчитывается как отношение количества верных прогнозов к их общему числу.

<sup>4</sup> Equal Error Rate (ERR) – показатель эффективности системы, при котором обе ошибки (FRR и FAR) эквивалентны.

<sup>5</sup> LOSS – значение функции потерь. Показывает, насколько хорошо прогнозы модели соответствуют целевым меткам.

В то же время хотелось бы выделить три важных момента<sup>1</sup>:

– Во-первых, если обратить внимание на графики обучения всех моделей, представленных в приложении №2, то можно заметить, что нейронные сети с Self-Attention обучаются стабильнее других моделей. В свою очередь модели без attention характеризуются значительными колебаниями в точности и значениях LOSS на протяжении всех циклов обучения. У нейросетей с Self-Attention эти колебания минимальны. Надо заметить, что все модели с механизмом внимания (кроме Cross-Attention), обучаются более стабильно. Это позволяет предположить, что механизм внимания помогает точнее выявлять признаки и закономерности в изображениях рукописей, по крайней мере если речь идет об анализе локального набора данных.

– Во-вторых, хотя нейросети показали высокие результаты в прогнозировании, нельзя не заметить, что при работе с небольшим набором данных (всего 40 образцов для сравнения) все модели обучались нестабильно. Это говорит о том, что несмотря на использованные приемы аугментации данных нейросетям не хватает примеров рукописей для стабильного обучения. Из этого можно сделать вывод, что для успешного обучения нейронной сети в рамках локального подхода необходимо как минимум 100 образцов. По крайней мере, это справедливо в тех случаях, когда анализируется именно изображение подписи.

– В-третьих, хотелось бы отдельно выделить модели с Cross-Attention. Как показали эксперименты, нейросети с подобным механизмом внимания обучаются наиболее нестабильно. Чтобы добиться приемлемых результатов, приходилось использовать приемы трансферного обучения: сначала обучать модель на одном наборе данных, а затем на другом. Однако причина подобного явления заключается не в самом механизме attention, а в самой архитектуре и подходе к обучению. Поскольку модуль Cross-Attention предполагает создание

---

<sup>1</sup> Отдельно выделим факт, что модели с механизмом внимания обучаются дольше моделей, в которых он отсутствует. Однако объясняется это во многом нехваткой вычислительных ресурсов использованного в работе оборудования.

нейросети только в сиамском варианте, это лишает нас возможности отдельно обучить encoder, как это было сделано для предыдущих моделей. Данная ситуация усложняет процедуру обучения, так как модель не имеет предварительного представления об анализируемых данных, что приводит к посредственным результатам. Это подтверждается попытками обучить другие SNN-модели по аналогичной схеме. В связи с этим предположение, что для более эффективного обучения нейросетей с сиамской архитектурой необходимо сначала обучить их часть, отвечающую за общее кодирование и анализ данных, т. е. encoder, подтверждается.

Если переходить к результатам обычного тестирования, отметим, что большая часть моделей показала хорошие или приемлемые результаты (Приложение №20–22). Разберем их более детально.

Для начала хотелось бы выделить сиамскую нейросеть с Self-Attention, которая показала точность прогнозирования в  $92.20 \pm 6.37\%$ . EER при этом составил 10.23%. Достигнуты данные результаты благодаря использованию метода сравнения, построенного на применении одноклассового классификатора SVM со стохастическим градиентным спуском.

Надо заметить, что этот подход сравнения оказался самым эффективным. В частности, при детальном анализе было установлено, что модели в связке с данным механизмом прогнозирования имеют лучшие показатели точности:  $86.17 \pm 9.68\%$  для моделей, построенных по принципу классификации, и  $91.01 \pm 7.25\%$  в случае применения сиамской архитектуры. Данное явление вполне объяснимо: поскольку метод опорных векторов является одним из методов машинного обучения, следовательно, мы имеем механизм, который также может обучаться на предоставленных ему данных. Если добавить к этому еще использование SGD для оптимизации алгоритма, получается, что подобный механизм классификации позволяет «дообучить» нейронную сеть. Благодаря этому процент возможных ошибок, совершаемых нейросетью, снижается.



В частности, модели, которые были построены на использовании Cross-Attention, также повысили свою точность в прогнозировании: если на других подходах сравнения данные модели демонстрировали точность от  $44.68 \pm 23.15\%$  до  $70.58 \pm 23.61\%$ , то с использованием SGD ON-SVM этот показатель повышается до  $84.18 \pm 10.99\%$ . Это лишний раз подтверждает сделанный ранее вывод, что отрицательный вклад в такие посредственные результаты вносит не модуль attention, а сам подход к обучению.

Стоит в целом отметить, что модели, в которых интегрированы механизмы Cross-Attention, вероятнее всего, очень чувствительны ко входным данным, на что указывают и исследователи, разработавшие данный модуль<sup>1</sup>. Этот вывод основан на дополнительных тестированиях, в ходе которых было установлено, что применение процедур аугментации к данным приводит к значительному повышению точности прогнозов. Обратная ситуация происходит, когда такие процедуры не применяются. Данные результаты свидетельствуют о возможной переобучении моделей, что обусловлено отсутствием у них первоначального представления об анализируемой информации, характерного для других типов SNN-моделей<sup>2</sup>.

Надо сказать, что сиамские нейронные сети в целом лучше и стабильнее справляются с задачей криминалистической идентификации исполнителя подписи. Так, при использовании разных методов сравнения были получены следующие результаты:  $85.46 \pm 10.17\%$ ,  $79.31 \pm 5.70\%$ ,  $84.44 \pm 12.06\%$  и  $91.01 \pm 7.25\%$ <sup>3</sup>. В моделях, построенных по принципу классификации, данные показатели составили  $83.46 \pm 8.63\%$ ,  $68.16 \pm 4.19\%$ ,  $80.03 \pm 13.67\%$  и  $86.17 \pm 9.68\%$  соответственно. В то же время классификационные модели показали лучшую

---

<sup>1</sup> Zhang H. et al. Self-attention generative adversarial networks // International conference on machine learning. – PMLR, 2019. – С. 7354–7363.

<sup>2</sup> Вследствие этого результаты, полученные при помощи моделей, в которых интегрирован Cross-Attention, в дальнейший расчет не рассматриваются и будут анализироваться отдельно.

<sup>3</sup> Результаты указаны в следующем порядке: сравнение при помощи косинусного сходства, сравнение при помощи среднего значения и стандартного отклонения, сравнение методом одноклассовой классификации SVM, сравнение методом одноклассовой классификации SVM со стохастическим градиентным спуском.

точность в выявлении «сторонних» образцов подписей, исполнителей которых нейронная сеть не знает:  $84.98 \pm 9.19\%$  против  $81.12 \pm 10.09\%$ <sup>1</sup>.

На основании результатов, полученных в ходе обычного тестирования, можно сделать вывод о том, что нейронные сети демонстрируют высокую эффективность как в задаче выявления подписей, выполненных сторонними авторами, так и в распознавании подписей, выполненных известными системе исполнителями. Однако следует отметить снижение точности прогнозирования по сравнению с результатами, полученными на тестовой подвыборке обучающего набора данных. Это снижение может быть объяснено тем, что модель должна не только осуществлять биометрическую идентификацию известных ей исполнителей, но и обнаруживать подписи, выполненные неизвестными авторами.

В то же время ситуация несколько меняется в условиях условного отсутствия «негативных» примеров, когда порог подбирается можно сказать «вслепую» (Приложение №23–25). Как было ранее отмечено, в нашем исследовании в подобной ситуации мы ориентировались на порог, при котором достигается максимальная точность в распознавании образцов подписи, предоставленных проверяемыми лицами. Благодаря такому подходу были получены достаточно интересные результаты.

Так, самой эффективной оказалась сиамская нейронная сеть без механизма внимания, которая достигла показателя точности в  $83.83 \pm 2.64\%$  и EER в 19.20%. Хотя данный результат уступает показателям, полученным на предыдущем этапе, он остается удовлетворительным с учетом условий «неопределенности», обусловленных отсутствием «негативных» примеров, для которых можно было бы определить оптимальный порог идентификации. Этот факт вновь поднимает вопрос о целесообразности формирования почерковедом экспериментальной выборки на основе предоставленных материалов для последующей калибровки модели, применяемой в экспертизе.

---

<sup>1</sup> Однако FC-модели, на удивление, демонстрируют меньшую точность в классификации известных нейросети авторов, по сравнению с SNN:  $68.81 \pm 13.48\%$  против  $81.60 \pm 8.03\%$ .

Примечательно, что указанный результат был достигнут с использованием метода сравнения, основанного на сопоставлении средних значений и стандартного отклонения, зафиксированных в типовом шаблоне. Надо сказать, что этот подход, в совокупности с использованием SNN, оказался наиболее стабильным в применении. С его помощью были получены следующие результаты:  $83.83 \pm 2.64\%$ ,  $84.05 \pm 5.36\%$ ,  $75.85 \pm 12.76\%$  и  $65.53 \pm 20.93\%$ . В свою очередь, сравнение при помощи SGD ON-SVM, напротив, оказалось одним из самых нестабильных:  $54.75 \pm 38.21\%$ ,  $45.50 \pm 33.30\%$ ,  $43.20 \pm 31.32\%$  и  $68.03 \pm 23.16\%$ .




Рисунок 16. Визуализация вероятностей принадлежности к одному из возможному классов в случае, когда рукопись выполнена исполнителем, которого модель знает




Рисунок 17. Визуализация вероятностей принадлежности к одному из возможному классов в случае, когда рукопись выполнена исполнителем, которого модель не знает<sup>1</sup>

<sup>1</sup> На рисунке видно, но не несмотря на схожесть распределения вероятностей принадлежности к классам, имеются отдельные существенные отличия, которые улавливает модель при прогнозировании.

Во многом это обусловлено ограниченным числом возможных порогов, характерных для данного метода сравнения. Так, при использовании средних значений и стандартных отклонений, зарегистрированных в типовом шаблоне, количество возможных порогов ограничено числом классов (авторов), участвующих в исследовании. Благодаря этому имеется возможность даже визуально сопоставить полученные результаты (рис. 16, 17). В случае применения методов, таких как SVM, количество потенциальных порогов значительно превышает указанное, поскольку оно может принимать любое значение в интервале от 0 до 1.

Немало важно и то, что модели при описываемом подходе выбора порога, основанного на максимизации точности в распознавании известных классов, склонны к лучшему распознаванию известных авторов, что видно из диаграммы Приложения №25. Что интересно, местами степень распознавания даже превосходит результаты, полученные при обычном тестировании. В свою очередь в отношении образцов, выполненных сторонними авторами, модели склонны совершать ошибки второго рода, что справедливо для методов сравнения, в которых используется ON-SVM или SGD ON-SVM. При использовании других методов сравнения результаты получаются более стабильными.

Также нельзя не заметить существенное превосходство SNN-моделей над нейросетевыми классификаторами. В частности, при сравнении результатов прогнозирования, полученных FC-моделями и сиамскими нейронными сетями, разница в точности при применении различных методов сопоставления варьируется от 2 до 20%. Особенно заметна эта разница при распознавании рукописного текста, созданного известными авторами нейронных сетей: отклонение в точности составляет от 7 до 40%.

В завершение данного подраздела можно констатировать, что современные нейронные сети, при интеграции с дополнительными инструментами для принятия решений, обладают способностью не только точно осуществлять традиционную биометрическую идентификацию авторов

по экспериментальным образцам подписей, но и выявлять «неизвестные» экземпляры рукописей, авторство которых нейронная сеть объективно определить не может. Это достигается даже при анализе ограниченных выборок, включая материалы, предоставленные эксперту-почерковеду для сравнительного исследования.

В совокупности данные возможности позволяют решать задачи криминалистической идентификации. Причем наибольшую эффективность в этом демонстрируют сиамские нейронные сети. Кроме этого, было установлено, что интегрированные механизмы внимания не оказывают как-то негативного эффекта на получаемые прогнозы. Более того, в некоторых случаях они даже повышали точность результатов анализа.

Однако необходимо отметить существующие проблемы, связанные с процессом идентификации, в частности, с выбором оптимального порога. Экспериментальные данные свидетельствуют о том, что даже незначительные отклонения от «идеального» порога могут привести к некорректным результатам. Хотя некоторые методы сравнения позволяют минимизировать данный эффект, проблема остается актуальной.

Потенциальным решением данной проблемы является интерпретация и визуализация признаков и характеристик почерка, используемых нейронной сетью для прогнозирования, что будет рассмотрено в следующем подразделе. Тем не менее, представляется целесообразным доработать существующие или разработать новые методы для вычисления итогового результата, чтобы повысить объективность и достоверность исследования.

### **2.3.2. Оценка результатов интерпретируемости**

Если говорить о степени интерпретируемости полученных прогнозов, то здесь результаты получились достаточно неоднозначными. Рассмотрим их по порядку в зависимости от используемых механизмов внимания:

1) СВМ. Данный механизм внимания показал достаточно среднюю степень информативности интерпретируемости результатов. Первоначально

хотелось бы отметить, что зоны, выделенные на карте внимания<sup>1</sup>, варьируются от достаточно небольших областей, до сравнительно крупных. Причем в большей степени они концентрируются именно вокруг отдельных признаков почерка в количестве не более трех-четырех штук. В основном, такими признаками чаще всего становятся точки пересечения движений, а также форма движений при выполнении и соединении элементов подписи (рис. 18, Приложение №26).




Рисунок 18. Пример визуализации карт внимания у модели с СВМ

Причем в как правило такие признаки действительно могут быть достаточно информативными. Например модель, обученная на наборе данных №1, достаточно часто выделяла точку пересечения первого и второго элементов прописной буквы «К». В свою очередь нейронная сеть, обученная на dataset №2.1 в большей степени выделяла нижние части безбуквенных элементов.

Также внимание обращалось и на вид соединения этих же элементов. В частности, в предыдущем примере ИНС обращала внимание на интервальный вид соединения первого и второго элементов прописной буквы «М»<sup>2</sup>. Кроме этого, можно выделить зоны активации в районах росчерка практически всеми

<sup>1</sup> Напомним, что в силу особенностей архитектуры мы получаем только одну общую карту внимания.

<sup>2</sup> В то же время остается не совсем ясным, действительно ли модель подразумевала именно этот признак, а не точку начала первого элемента.

моделями. Так, достаточно часто выделялись такие признака как форма соединения безбуквенных элементов с росчерком, точка пересечения в самом росчерке, а также форма движения при выполнении левой части росчерка. При этом нельзя не заметить, что зона внимания чаще всего располагается не непосредственно на признаке, а как область рядом с ним.

Если говорить о сопоставлении признаков, выявленных между исследуемой рукописью и наиболее сопоставимым образцом для сравнительного исследования, то были выявлены следующие закономерности:

- Положительный ответ модели, положительный пример<sup>1</sup> – признаки имеют отдельные зоны переселения между собой, хоть и не полностью перекрывают друг друга по части выявляемых признаков. При этом местами наблюдаются случаи, когда признаки объективно отличаются, но нейросеть вероятнее всего выделяет их как схожие;

- Отрицательный ответ, положительный пример – результаты примерно схожие, что и в первом случае. Из этого следует вывод, что хоть модель и пришла к неверному выводу, однако при помощи механизма внимания видно, что отдельные признаки совпадают между собой. Потенциально это может служить основанием для пересмотра вывода, к которому пришла модель. В то же время возникают и ситуации, когда эти зоны отсутствуют, что вероятно приводит к отрицательному ответу. В связи с данным фактом становится не совсем ясным, в силу каких причин модель дает отрицательный ответ при наличии совпадающих областей;

- Положительный ответ, отрицательный пример<sup>2</sup> – имеют как противоположные зоны активации, так при пересекающиеся. При этом пересекающиеся зоны активации в части выявляемых признаков в большей степени все же имеют отличия, чем сходства.

---

<sup>1</sup> Подразумевается, что в качестве исследуемой рукописи выступало изображение подписи, исполнителя которой модель знает.

<sup>2</sup> Подразумевается, что в качестве исследуемой рукописи выступало изображение подписи, исполнителя которой модель не знает.

– Отрицательный ответ, отрицательный пример – повторяются все те же ситуации, что и в предыдущих примерах. В частности, имеются как пересекающиеся зоны с несколько отличающимися признаками, так и с полностью отличающимися.

Справедливости ради отметим, что приведенная характеристика в большей части является общей, и, если рассматривать каждый набор данных в отдельности, можно выявить неравномерность в эффективности обнаружении признаков почерка. В частности модель, обученная на dataset №2.2 была в большей степени склонна выявлять зоны «пустых активаций», т. е. места на изображении, где в принципе отсутствуют штрихи подписи.

Также интересным наблюдением стала высокая степень корреляции выявляемых признаков между FC- и SNN-моделями. Это не удивительно, поскольку сиамские модели использовали encoder уже обученной нейросети, построенной по принципу классификации. Однако нельзя не заметить и некоторые отличия. В частности SNN-модель, обученная на dataset №2.2, в отличие от своей FC-версии, была уже менее склонна к выявлению пустых областей, что может свидетельствовать о незначительном улучшении эффективности кодировщика.

В остальном можно сказать, что хоть CBAM и может выявлять некоторые признаки почерка, однако делает это не всегда уверенно и точно.

2) Self-Attention. В отличие от архитектуры с CBAM, нейросети, построенные на сверточном Self-Attention, предоставляют несколько карт внимания, полученных с разных уровней модели (Приложение №27). Теоретически это расширяет возможности для интерпретации. Однако на практике это происходит не совсем так, как ожидается.






Рисунок 19. а) Пример визуализации карт внимания с верхних уровней у модели с Self-Attention б) Пример визуализации карт внимания с нижних уровней у модели с Self-Attention

В частости, по результатам эксперимента было установлено, что примерно половина карт внимания не несут в себе какой-либо полезной информации. Зоны активации, особенно на первых слоях сети, характеризуются небольшим размером и как правило покрывают всю подпись целиком (рис. 19а). Объяснить данное явление можно тем, что на верхних слоях выделяет самые элементарные признаки, в виде небольших фрагментов штрихов подписи, что подтверждается исследованием, проведенным еще в 2013 г. М. Зейлером и Р. Фергусом<sup>1</sup>. В силу этого они еще не сгруппированы в более крупный кластер, по которому можно было бы оценивать сам вид признака и его информативность.

Более информативные характеристики модели выявляются на более глубинных уровнях (рис. 19б). В частости в ходе исследования было выявлено,

<sup>1</sup> Zeiler M. D., Fergus R. Visualizing and understanding convolutional networks //Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I 13. – Springer International Publishing, 2014. – С. 818–833.

что они появляются примерно на четвертом-шестом уровнях. По размеру зон активации они меньше, чем аналогичные, которые выявляет модуль СВМ, однако располагаются несколько точнее по отношению к реальным особенностям почерка, а также в большем количестве. Что примечательно, Self-Attention выявляет схожие признаки, что и СВМ. В частности модель, обученная на наборе данных №1, также акцентировала внимание на форме соединения безбуквенных элементов и росчерка, точках пересечения в росчерке и прописной букве «К».

Однако добавлялись и новые признаки, как например петлевая форма соединения второго и третьего элементов прописной буквы «К» (набор данных №1), а также точка начала первого элемента прописной буквы «М» и точка соединения движений второго и третьего элементов прописной буквы «М» (набор данных №2.1). Что примечательно, все перечисленные признаки выявлялись как классификационными моделями, так и нейросетями с сиамской архитектурой<sup>1</sup>.

Что касается сопоставимости признаков между исследуемой рукописью и сравнительными образцами, то здесь результаты во многом сопоставимы с теми, что были полученные при помощи модуля СВМ. Исключением является только то, что Self-Attention выделяет больше зон активации, которые лучше друг с другом коррелируют. В связи с этим ситуаций, когда сопоставимые признаки приводят к разным результатам, стало меньше. Вследствие этого визуально определить факт того, что исследуемая рукопись и конкретный образец были выполнены или не выполнены одним исполнителем, стало немного проще, даже если сама модель совершила ошибку.

В то же время увеличилось число зон «пустых активаций», особенно на финальных уровнях обработки данных. Стали встречаться ситуации, когда механизм внимания выделял практически всю подпись либо ее фрагмент, либо

---

<sup>1</sup> Разница заключалась в основном только в размерах зоны активации – прим.

напротив, помечал в качестве информативной зоны пространство вокруг рукописи.

Таким образом, на основе полученных данных, можно прийти к выводу о некотором превосходстве Self-Attention над СВАМ по части интерпретации прогнозов, сделанных моделью. В то же время нейронная сеть, построенная на первом механизме внимания, вероятно, оказалась слишком глубокой, что привело увеличению числа зон пустых активаций. Также в этой сети не использовался анализ всех полученных карт внимания с последующим формированием единой информационной карты признаков, как это было реализовано в случае с СВАМ. В связи с этим в дальнейшем было бы целесообразно провести подобное исследование.




Рисунок 20. а) Пример визуализации карт внимания с верхних уровней у модели с Cross-Attention б) Пример визуализации карт внимания с нижних уровней у модели с Cross-Attention

3) Cross-Attention. Несмотря на посредственные результаты прогнозирования моделей, основанных на Cross-Attention, сама интерпретация этих прогнозов получилась весьма успешной (Приложение №28). По структуре полученные карты внимания похожи те, которые вычислялись моделями с механизмом Self-Attention. В частности, карты внимания, полученные с первых слоев модели, также характеризуются малой

информативностью в связи с небольшими размерами зон активации, которые преимущественно покрывают всю ее область (рис. 20а). Более информативные признаки можно наблюдать начиная с четвертого-шестого слоя (рис. 20б).

Так же, как и остальные модели, нейронные сети с Cross-Attention преимущественно концентрируются на выявлении таких признаков как размещение точек движения, а также форма движения при выполнении и соединении элементов письменных знаков. Что примечательно, нейронная сеть качественно выявляет почти все те же признаки, что и другие модели. Например, ИНС, обученная на наборе данных №1, также акцентировала внимание на такие признаки как точка пересечения второго и третьего элементов прописной буквы «К», форма соединения первого и второго элементов прописной буквы «К», а также точка пересечения штрихов росчерка, равно как и форма движения при выполнении элементов росчерка.

Говоря о сопоставимости выявляемых признаков, выявляемых в исследуемой рукописи и образцах, предоставленных для сравнения, нужно указать, что она лучше, чем в CBAM и Self-Attention. В частности, были выявлены такие закономерности:

– При сопоставлении исследуемой рукописи и сравнительного экземпляра, которые были выполнены одним лицом, на разных уровнях наблюдаются сильные пересечения выявляемых признаков. В частности модель, обученная на dataset №1, отмечала схожие зоны в области расположения точки пересечения росчерка и/или точки пересечения второго и третьего элементов прописной буквы «К». В свою очередь нейросеть, обученная на наборе данных №2.1, больше концентрировалась в районе росчерка и прописной буквы «М». Надо заметить, что схожие области выявлялись даже в случаях, когда модули вычисления прогнозов приходили к неверным результатам. Это позволяет предположить, что основные проблемы, связанные с неверной идентификацией автора, возникают в большей степени из-за механизма принятия решения, тогда как сама модель, точнее модуль

Cross-Attention, в целом может определять, что две подписи выполнены одним автором.

– При сравнении исследуемой рукописи и контрольного образца, которые были выполнены разными лицами, наблюдалась обратная ситуация. На картах внимания разного уровня было видно, что в одном случае модель концентрируется на одном участке подписи, тогда как у другого экземпляра отмечаются другие характеристики. Причем в некоторых случаях эти различия показывались уже на первых уровнях модели. В частности, модель, анализирувавшая dataset №1, в исследуемых рукописях, выполненных неизвестными модели авторами, чаще отмечала зона ближе к началу подписи, тогда как в образцах для сравнительного исследования выделялась область в месте расположения росчерка. Это же справедливо и для других моделей, обученных на других наборах данных.

В то же время укажем, что и в Cross-Attention нередко наблюдаются области «пустых активаций», пересекающиеся зоны с похожими признаками, даже когда сравниваемые экземпляры рукописей выполнены разными авторами, а также смещение зон активаций в сторону относительно реального расположения штрихов и активация на всю величину подписи. Последнее особенно было характерно для модели, обученной на наборе данных №3. Причиной этого, скорее всего, является низкая точность модели, которая была вызвана небольшим количеством используемых для обучения данных.

Тем не менее, идея Cross-Attention о вычислении значимых областей в изображениях подписи при их непосредственном сопоставлении друг относительно друга, видится весьма перспективной в использовании.

Таким образом, на базе всего перечисленного, можно сделать следующие выводы:

1) Модули внимания действительно могут помочь в понимании отдельных аспектов то, какие признаки выявляет нейронная сеть. Более того, визуализация выявленных признаков в ряде случаев позволяет определить, действительно ли исследуемая подпись выполнена одним из проверяемых лиц.

Нельзя не заметить и то, что многие модели, которые обучались независимо друг от друга, выявляли схожие закономерности почерка при анализе конкретных наборов данных, что подтверждает гипотезу о том, что механизмы внимания для прогнозирования все же используют отдельные признаки почерка.

2) Несмотря на положительные результаты, нельзя не сказать и о достаточно серьезных проблемах в интерпретации. Хотя модуль attention и выявляют отдельные закономерности в рукописях, однако имеется не мало случаев, когда зона внимания смещается основательно самого штриха, либо в целом располагается на пустом участке, где какие-либо штрихи отсутствуют. Кроме того, степень интерпретируемости зависит еще и от общей эффективности самой модели. Если нейросеть имеет небольшую точность прогнозирования, то и степень интерпретации также будет посредственной. В наших экспериментах это обычно проявлялось в виде одной большой зоны активации, которая охватывала всю подпись.

Стоит указать и на факты игнорирования достаточно информативных признаков почерка. К примеру, как показали наблюдения, модели концентрировались в основном на начальной части подписи и росчерке, когда как центральный фрагмент почти всегда оставался незамеченным.

На основе этого можно выдвинуть предположение, что система, в частности модули attention, фокусируются главным образом на геометрических особенностях подписи, в то время как такие признаки, как направление движений при выполнении письменных знаков и их элементов, последовательность отдельных элементов и другие подобные параметры, вероятно, остаются без внимания или не распознаются. В силу этого можно заключить, что центральная проблема в вопросе анализа рукописи нейросетями с последующей интерпретацией полученных результатов заключается в самих данных – изображениях подписи.

Действительно, многие исследователи неоднократно отмечали, что «статические» рукописи информационно намного беднее, чем аналогичные

цифровые варианты. В силу этого модели выявляют только ту информацию, которую непосредственно «видят» на картинке с подписью либо другим рукописным объектом. Это объясняет, почему в некоторых случаях механизмы внимания придают значимость пустым областям, не содержащим штрихов рукописи.

Поэтому, применение сверточных нейронных сетей и механизмов внимания, построенных на сверточных блоках, рассматривается нами как переходный вариант в извлечении признаков почерка. Более целесообразным видится переход к преобразованию изображений рукописи в формат, аналогичному цифровому, что будет более детально рассматриваться в следующем разделе.

В остальном эксперимент по интерпретации прогнозов, полученных с помощью нейронных сетей, стоит признать достаточно успешным<sup>1</sup>. В связи с этим на базе полученных результатов можно проектировать общие методические рекомендации по использованию данных модулей в рамках судебно-почерковедческой экспертизы<sup>2</sup>.

---

<sup>1</sup> Однако в реальной экспертной практике представленные механизмы внимания на наш взгляд не применимы, по крайней мере если говорить об исследовании почерка.

<sup>2</sup> Информация об использованном в работе оборудовании и средах разработки представлена в Приложениях №29, 30.

### **ГЛАВА 3. МЕТОДИЧЕСКИЕ И ОРГАНИЗАЦИОННО-ТАКТИЧЕСКИЕ РЕКОМЕНДАЦИИ И ПРЕДЛОЖЕНИЯ ПО ИСПОЛЬЗОВАНИЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ В СУДЕБНО-ПОЧЕРКОВЕДЧЕСКОЙ ЭКСПЕРТИЗЕ**

#### **§ 3.1. Место искусственных нейронных сетей в методике судебной почерковедческой экспертизы**

##### **3.1.1. Интеграция искусственных нейронных сетей на уровне частных экспертных методик**

Переходя к интеграции искусственных нейронных сетей в судебную почерковедческую экспертизу с методологической точки зрения, обратимся к понятию «метод» и «методика» судебной экспертизы. Метод экспертного исследования обычно трактуют как систему действий и операций по решению практических экспертных задач<sup>1</sup>. Здесь следует подчеркнуть, что в этом контексте экспертную задачу стоит воспринимать в узком смысле, а именно как отдельный этап получения определенной информации об объекте исследования. Данная информация позволяет эксперту сформулировать обоснованный ответ на поставленный перед ним вопрос. Такое уточнение необходимо из-за того, что обычно результаты, полученные при использовании одного метода исследования, нельзя назвать полными, так как они отражают только одну сторону исследуемого объекта. Из-за этого на их основе нельзя сформулировать объективный и всесторонний вывод по поставленному перед экспертом вопросу.

Поэтому отдельные методы «объединяют» в рамках методики экспертного исследования в – систему категорических или альтернативных научно обоснованных предписаний по выбору и применению в определенной последовательности и в определенных существующих или создаваемых

---

<sup>1</sup> Энциклопедия судебной экспертизы / Под ред. Т.В. Аверьяновой, Е.Р. Россинской. – М.: Юристъ, 1999.



условиях методов, приемов и средств (приспособлений, приборов и аппаратуры) для решения экспертной задачи<sup>1</sup>. Проще говоря, методику можно определить как программу или алгоритм действий эксперта, в соответствии с которой он применяет те или иные методы для решения поставленной перед ним задачи. Причем в зависимости от результатов, полученных при применении конкретного метода, эксперт решает, достаточно ли информации было выявлено для того, чтобы ответить на поставленный перед ним вопрос<sup>2</sup>.

Причем очевидно, что судебно-экспертная деятельность характеризуется широким спектром вопросов, подлежащих разрешению. Вследствие этого не существует универсальной методики исследования, применимой ко всем случаям. Поэтому чаще всего их разрабатывают для решения наиболее типичных экспертных задач, что определяет их иерархическую систему. В контексте судебно-почерковедческой экспертизы данная система выглядит следующим образом<sup>3</sup>:

1) Общая методика экспертного исследования – формально ее можно представить в виде стадий экспертного исследования, так как она в целом определяет процедуру и содержание решения задач судебно-почерковедческой экспертизы как рода криминалистической экспертизы. Принципы данной методики зависят от класса задач, стоящих перед экспертом. В связи с этим выделяют два основных вида общей методики СПЭ: идентификационная и диагностическая методика исследования рукописей.

2) Частная методика (или типовая методика) – данная группа методик конкретизирует порядок и содержание решения задач определенного вида и подвида судебно-почерковедческой экспертизы, учитывая специфику исследуемой рукописи и условия ее выполнения. Особенностью частной методики является ее комплексный характер, который предполагает

---

<sup>1</sup> Основы судебной экспертологии: учебно-методическое пособие – М.: ФБУ РФЦСЭ при Минюсте России, 2023 – С. 298.

<sup>2</sup> Здесь очень сильно просматривается аналогия с деревом решения, когда компьютерная программа при обработке данных приходит к тому или иному выводу.

<sup>3</sup> Почерковедение и почерковедческая экспертиза / под ред. В. В. Серегина: учебник – Волгоград: ВА МВД России, 2014. – С. 12.

использование различных методов, включая качественно-описательные, количественные (модельные), инструментальные и машинные.

В силу этого в экспертной практике для решения одной и той же задачи могут применяться несколько методик, включающих в себя разный комплекс методов. Например, в судебно-экспертных учреждениях Минюста РФ используются преимущественно две методики для идентификации исполнителя подписи. Первая, качественно-описательной, основана на качественном анализе общих, частных и диагностических признаках почерка и их сравнении между собой<sup>1</sup>. Вторая методика комплексная, включает измерение структурно-геометрических характеристик подписи<sup>2</sup>. Обе указанные методики направлены на решение одной задачи, однако используют различные методы и подходы, что обуславливает различия в условиях и требованиях их применения. В то же время их совместное использование повышает объективность экспертного исследования, особенно в сложных случаях.

3) Конкретная методика – предназначена для решения конкретной экспертной задачи, которая характеризуется уникальностью и индивидуальностью. Несмотря на общую постановку вопроса экспертизы почерковеду, процесс исследования включает анализ конкретной рукописи, образцов для сравнительного исследования, выполненных конкретными лицами. По этой причине в ходе каждой отдельно взятой судебно-почерковедческой экспертизы используемые типовые методики могут модифицироваться или комбинироваться в зависимости от получаемых результатов.

Возвращаясь к приведенному выше примеру, отметим, что в некоторых случаях качественно-описательная методика не позволяет дать категоричный

---

<sup>1</sup> Судебно-почерковедческая экспертиза малообъемных почерковых объектов. Вып. 3. Методика исследования подписей. Методическое пособие для экспертов / Под ред. В. Ф. Орловой. М.: РФЦСЭ. 1997.

<sup>2</sup> Комплексная методика установления подлинности (неподлинности) кратких и простых подписей. Методическое пособие для экспертов. – М.: ВНИИСЭ, 1987.

ответ на поставленный вопрос. В таких ситуациях может быть использована комплексная методика, результаты которой могут подтвердить и дополнить выводы, полученные с помощью качественно-описательной методики. Это позволяет эксперту прийти к более объективному заключению, сформулировав его в категорической форме.

На основе перечисленного интеграция нейронных сетей в процесс исследования рукописей может быть рассмотрена с двух основных позиций: модификация существующих или разработка новых частных экспертных методик, в рамках которых будут использоваться ИНС, и внедрение этих алгоритмов в структуру общей методики исследования. Учитывая, что передовые технологии прежде всего используют для создания новых и совершенствования существующих типовых методик, целесообразно первоначально рассмотреть именно эту сторону вопроса. Для этого сформулируем несколько базовых положений, к которым мы будем обращаться:

1) Применение в судебно-почерковедческой экспертизе искусственных нейронных сетей (согласно описанной выше процедуре), на наш взгляд, должны рассматриваться как метод исследования. Соответственно, как и любой другой метод, анализ объектов судебной экспертизы при помощи ИНС должен соответствовать требованиям, установленным судебной экспертологией, а также действующему законодательству. В частности, должны соблюдаться такие критерии как законность<sup>1</sup>, научная обоснованность, точность, надежность и воспроизводимость получаемых результатов.

2) Для обеспечения выполнения перечисленных требований наиболее эффективным представляется применение нейронных сетей для решения конкретных задач и подзадач. В качестве примера можно привести типовую методику идентификационного исследования подписи, которая включает

---

<sup>1</sup> Подробнее правовая сторона вопроса интеграции искусственных нейронных сетей рассматривается в следующем разделе.

решение таких задач, как определение способа выполнения исследуемого объекта, условий, в которых была выполнена подпись, установление факта выполнения образцов подписи одним и тем же лицом и другие<sup>1</sup>. По нашему мнению, только четкое формулирование задач и подзадач гарантирует точность получаемых результатов, так как это позволяет однозначно определить, какие результаты и прогнозы может выдавать ИНС.

В принципе можно создать единую нейросетевую систему, которая будет способна решать все эти задачи одновременно. Однако в этом случае вновь возникают такие проблемы, как интерпретируемость результатов, их контроль и оценка со стороны эксперта, особенно если речь идет о промежуточных стадиях, как например определение условий выполнения рукописи.

3) Как было определено ранее, на сегодняшний день можно выделить два подхода к обучению нейронных сетей: «глобальный» и предложенный нами «локальный» подходы к анализу данных. Напомним, что «глобальный» подход предполагает обучение нейронной сети так, чтобы она решала какую-то задачу в общем. В отличие от него, «локальный» подход направлен на обучение нейронной сети на конкретных данных, в частности, на образцах для сравнительного анализа, выполненных проверяемыми лицами. Учитывая возможность формулирования конкретных задач и подзадач для различных алгоритмов, указанные подходы могут быть использованы для решения задач различной степени общности.

Например, процедуру кодирования, речь о которой пойдет ниже, определение условий выполнения рукописи и иные схожие подзадачи можно рассматривать как более общие, «глобальные». Для их решения целесообразно разработать такую же «глобальную» нейросетевую модель, специализирующуюся на выполнении именно этих задач. Обучение такой модели может быть осуществлено по классической схеме, включающей сбор

---

<sup>1</sup> Типовые экспертные методики исследования вещественных доказательств. Ч. I / Под ред. канд. техн. наук Ю.М. Дильдина. Общая редакция канд. техн. наук В. В. Мартынова. – М.: ЭКЦ МВД России, 2010. – С. 300–320.

большого объема данных, их разметку, загрузка их в нейросетевой алгоритм и т. д. Причем благодаря своей универсальности, подобная нейросеть может быть применена в различных экспертных исследованиях конкретного рода/вида.

В то же время алгоритмы, разработанные в рамках «локального» подхода, будут больше предназначены уже для решения более узкоспециализированного спектра задач, таких как идентификация исполнителя подписи.

4) Неотъемлемой частью процесса разработки и внедрения нейросетевых технологий должна стать их валидация. Причем подходы к валидации, как представляется, должны варьироваться в зависимости от специфики решаемых задач и их общности. Например, для моделей, разработанных в рамках «глобального» подхода, можно использовать схему, предложенную Е.Р. Россинской, которая предполагает создание верифицированных наборов данных для обучения и тестирования моделей<sup>1</sup>.

В свою очередь нейросети и иные аналитические средства, разрабатываемые для решения конкретных задач в рамках отдельных экспертиз, следует валидировать в соответствии с общей схемой валидации экспертных методик<sup>2</sup>. В этом случае оцениваться будет не столько точность алгоритма, сколько корректность и эффективность самого подхода к решению задачи, то есть процедурная валидность избранного метода. Примером такого подхода является комплексная методика установления подлинности (неподлинности) кратких и простых подписей<sup>3</sup> и базирующийся на ее основе

---

<sup>1</sup> Россинская Е.Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы // Вестник Университета имени О.Е. Кутафина (МГЮА). – 2024. – № 3(115). – С. 21–33.

<sup>2</sup> Подробнее см. Усов А. И., Омелянюк Г.Г., Бебешко Г.И., Любецкая И.П., Афанасьев И.Б. Методологические особенности валидации судебно-экспертных методик // Теория и практика судебной экспертизы. 2023. Т. 18. № 1. С. 76–96.

<sup>3</sup> Комплексная методика установления подлинности (неподлинности) кратких и простых подписей. Методическое пособие для экспертов. – М.: ВНИИСЭ, 1987.

программный комплекс «ОКО-1»<sup>1</sup>. Так, в каждой отдельно взятой судебно-почерковедческой экспертизе при исследовании рукописей выявляются индивидуальные оценки геометрических параметров ее элементов. При этом сама процедура измерения, оценки и формулирования выводов является достаточно надежной и формализованной. Аналогичный подход может быть применен к локальным нейросетевым методам анализа.

5) Способствовать надежности получаемых результатов независимо от общности задачи должна стать обязательная интерпретируемость результатов работы ИНС. Это позволит судебному эксперту оценивать получаемые прогнозы и корректировать их при необходимости, например, если он установит ошибку работы алгоритма. Такая возможность реализована, например, в АДИС «Папилон»<sup>2</sup>.

6) Хотя изображения подписи и иных рукописных объектов можно использовать для обучения ИНС, однако, как показывают результаты различных исследований, в том числе и нашего, это менее эффективно, чем изучение цифровых рукописей. В связи с этим более продуктивным способом является преобразование «статичных» изображений рукописей в их «динамические» цифровые версии путем процедуры кодирования. В этом случае ее можно рассматривать как подзадачу общего характера в рамках всего исследования<sup>3</sup>.

На этих положениях может быть выработан следующий шаблон типовой методики идентификационного исследования рукописей, в частности подписи:

1) Стадия предварительного исследования. Как и во всех остальных методиках, эксперт изначально знакомится с постановлением/определением о назначении судебной экспертизы и определяет, входят ли поставленные вопросы в его компетенцию. Далее он изучает предоставленные материалы,

<sup>1</sup> Смирнов А. В. Программа «ОКО-1» для исследования кратких и простых почерковых объектов // Теория и практика судебной экспертизы. 2006. № 1 (1). С. 121–124.

<sup>2</sup> АДИС ПАПИЛОН-9. Руководство пользователя // ООО «ИТ-Папилон» – URL: <http://ftp.папилон.рф/products/adis-9/adis-9-u.pdf> (дата обращения: 13.04.2025).

<sup>3</sup> Технические аспекты этого процесса будут рассмотрены в другом разделе. Дальше мы сосредоточимся на процедурной части исследования.

включая исследуемые рукописи (подписи), образцы для сравнительного исследования и другие материалы дела.

В процессе предварительного анализа исследуемых рукописей эксперт, так же, как и в качественно-описательной методике, проводит их структурный анализ и выявляет диагностические признаки, которые могут указывать на необычные условия их выполнения. На этой же стадии могут быть обнаружены признаки, свидетельствующие о выполнении рукописи нерукописными способами.

Относительно образцов для сравнительного анализа эксперт оценивает их достаточность для проведения исследования. Применительно к нашему случаю их должно быть не менее 100 от каждого из проверяемых лиц<sup>1</sup>. Необходимой процедурой является сопоставление образцов между собой, чтобы установить, действительно ли они выполнены одним и тем же человеком. Для этого могут использоваться различные методы, включая сиамские нейронные сети, предварительно обученные для решения подобной задачи, или алгоритмы кластеризации, как например метод К-средних.

Кроме перечисленного, неотъемлемой частью предварительного исследования становится «цифровая фиксация» исследуемой рукописи и всех образцов для сравнительного исследования. Под «цифровой фиксацией» понимается процесс фотографирования или сканирования указанных материалов, а также кодирование полученных изображений. Последнее может осуществляться с использованием специализированных нейронных сетей-кодировщиков. Предполагается, что итоговые результаты работы такого алгоритма будут отражать не только структурно-геометрические характеристики почерка, но и другие важные параметры, такие как направление движений при выполнении элементов письменных знаков, последовательность их выполнения и другие частные признаки почерка<sup>2</sup>.

---

<sup>1</sup> Однако с дальнейшим развитием нейросетевых и иных технологий оно может сократиться.

<sup>2</sup> На текущем этапе интеграции предполагается, что общие признаки почерка в большей степени будут фиксироваться экспертно-почерковедом.

Фактически, эту процедуру можно прировнять к процессу извлечения признаков, который осуществляется сверточными нейросетями. Исключением является только то, что в первом случае этот процесс становится более явным и интерпретируемым.

Важно отметить, что все описанные процедуры могут проводиться параллельно. Например, при фотографировании или сканировании материалов и внесении полученных изображений в память компьютера эксперт может одновременно выявлять диагностические признаки необычных условий выполнения рукописи<sup>1</sup>. В свою очередь, после завершения «цифровой фиксации» всех рукописей их цифровые версии могут быть сопоставлены для установления их принадлежности к тем авторам, от имени которых они были предоставлены.

2) Аналитическое исследование. На данном этапе можно выделить две фазы. Первая фаза – это анализ «цифровой» версии подписей. Этот анализ преследует две основные цели:

- Эксперт выявляет для себя общие, частные и диагностические характеристики почерка.
- Проводится проверка работы кодировщика. Например, может возникнуть ситуация, когда алгоритм некорректно определил последовательность выполнения штрихов в подписи. Обнаружение таких ошибок позволяет внести соответствующие коррективы в полученные данные, что в дальнейшем позволяет избежать неточностей в прогнозировании.

Вторая фаза – анализ признаков с использованием нейронной сети. Этот процесс может осуществляться по предложенной схеме в рамках «локального» подхода, при котором ИНС сначала обучается на образцах для сравнительного

---

<sup>1</sup> Этот вопрос мы исследовали в следующей работе: Мишук В.А. Использование искусственных нейронных сетей для выявления диагностических признаков почерка, свидетельствующих о возможной фальсификации подписи // Материалы X Международной научно-практической конференции, посвященной двадцатилетию Института судебных экспертиз Московского государственного юридического университета имени О. Е. Кутафина (МГЮА), г. Москва, 30–31 января 2025 года. – Москва: Издательский центр Университета имени О.Е. Кутафина (МГЮА), 2025. – С. 205–209.



исследования и потом используется на следующих стадиях. Альтернативно могут применяться другие алгоритмические методы и подходы. Важно, чтобы алгоритм непосредственно исследовал все предоставленные материалы, что позволит ему корректно сопоставить признаки, выявленные в исследуемой рукописи с признаками, установленными в образцах.

3) Сравнительное исследование. На данном этапе также могут быть применены подходы, аналогичные тем, что использовались в настоящей работе, а именно: обучение нейронной сети распознаванию «известных» авторов на основе предоставленных образцов и выявление неизвестных авторов. Кроме того, могут быть задействованы альтернативные алгоритмы принятия решений, включая байесовские нейронные сети, логические нейросети и классические методы принятия решений. Ключевым требованием является способность системы решать задачи криминалистической идентификации, то есть корректно определять отсутствие тождества в случае, если исследуемая подпись объективно истинно не была выполнена ни одним из проверяемых лиц. Либо наоборот, устанавливать факт ее выполнения одним из авторов.

Наиболее значимым аспектом сравнительного анализа является интерпретация полученных результатов. Алгоритм должен демонстрировать, на основании каких выявленных закономерностей был сделан тот или иной прогноз. Кроме этого, для повышения объективности можно рассмотреть возможность реализации механизма, учитывающего не только «внутриклассовые» признаки, то есть закономерности, характерные для всех образцов почерка в рамках конкретного экспертного исследования, но и «межклассовые» признаки, позволяющие оценить информативность выявленных характеристик в контексте всех людей, владеющих определенным видом письменности. Внедрение подобного механизма в рамках предложенной концепции «глобального» и «локального» подходов, вероятно, потребует разработки гибридного способа анализа, при котором информация

о закономерностях почерка сохраняется и подвергается статистическому анализу за пределами экспертного исследования<sup>1</sup>.

4) Оценка полученных результатов и формулирование выводов. Как и в качественно-описательной методике эксперт-почерковед, обладая интерпретируемым форматом полученных данных, имеет возможность самостоятельно оценить значимость выявленных признаков и определить их релевантность для установления тождества или его отсутствия. В процессе анализа эксперт также может выявить потенциальные ошибки в работе алгоритма или напротив, обнаружить дополнительные закономерности, которые усиливают обоснованность результатов, полученных с помощью используемой ИНС.

Таким образом, предлагаемая структура методики идентификационного исследования подписи с применением ИНС основывается на модульном принципе, при котором каждое алгоритмическое средство предназначено для выполнения конкретной задачи. В отличие от создания единой крупной нейросетевой модели, нами предлагается использовать несколько небольших моделей, результаты которых будут использоваться на определенных этапах исследования. Данный подход в некоторых аспектах аналогичен принципам работы мультимодальных моделей, однако предоставляет эксперту возможность на каждом этапе оценки результатов вносить коррективы в случае обнаружения ошибок или несоответствий. Кроме того, такая структура обеспечивает оперативную замену одного алгоритмического средства на другое, более подходящего для выполнения конкретной задачи, что способствует масштабированию описанной схемы до уровня общей методики судебно-почерковедческой экспертизы.

### **3.1.2 Интеграция ИНС на уровне общих методик**

В контексте интеграции технологий искусственного интеллекта, в частности, искусственных нейронных сетей, в общую методику судебно-

---

<sup>1</sup> Подробнее правовые аспекты этого процесса изучаются в следующем разделе.

почерковедческой экспертизы, следует отметить нецелесообразность разработки унифицированных положений, применимых исключительно к определенной группе алгоритмов, включая нейронные сети. Такой подход может стать ограничительным фактором для внедрения и использования более продвинутых вычислительных средств в будущем.

ИНС в судебно-экспертной деятельности необходимо рассматривать как один из методов анализа объектов, относящихся к конкретному виду/роду экспертиз. Учитывая стремительное развитие науки и техники, можно предположить, что в перспективе нейронные сети, являющиеся на сегодняшний день одной из наиболее перспективных технологий в области проектирования ИИ, либо претерпят «эволюционные изменения» за счет разработки новых архитектурных моделей и методов их функционирования, либо будут заменены более совершенными алгоритмическими решениями, основанными на иных методологических подходах.

В связи с вышеизложенным, представляется более обоснованным предложение Е.В. Чесноковой, А.И. Усова, Г.Г. Омелянюка и М.В. Никулиной о разработке общих теоретических положений, регламентирующих внедрение и применение ИИ-технологий в судебно-экспертную практику<sup>1</sup>. Такие положения, на наш взгляд, должны отражать такие позиции как:

- Формулирование четких задач и подзадач, которые должны решать вычислительные системы;
- Обязательная интерпретируемость используемых вычислительных средств;
- Постоянная актуализация используемых алгоритмов и процедур их применения, а также их валидация по аналогии с остальными методами и методиками экспертного исследования.

---

<sup>1</sup> Чеснокова Е.В., Усов А.И., Омелянюк Г.Г., Никулина М.В. Искусственный интеллект в судебной экспертологии. // Теория и практика судебной экспертизы. 2023. Т. 18. № 3. С. 60–77.

Применительно к судебно-почерковедческой экспертизе можно кратко продублировать приведённую ранее схему, несколько ее обобщив:

- Предварительное исследование – ознакомление с поступившими материалами, определение их пригодности, «цифровая фиксация» рукописей с последующим их кодированием;
- Аналитическая стадия – выявление алгоритмом общих, частных и диагностических признаков почерка и их анализ;
- Сравнительное исследование – сопоставление выявленных признаков в исследуемой рукописи и сравнительных образцах с выделением наиболее важных и информативных;
- Оценка полученных результатов и формулирование вывода.

Данная структура общей методики, адаптированной под использование ИИ-технологий, представляется оптимальной и результативной, поскольку она предполагает разработку нескольких специализированных моделей для решения конкретных задач, а не создание единой крупной модели для комплексного решения всех задач одновременно. Такой подход позволяет применять различные методики в процессе обучения и проектирования систем искусственного интеллекта, что способствует повышению их эффективности и адаптивности.

### **§ 3.2. Правовые и организационно-тактические рекомендации по использованию искусственных нейронных сетей в судебно-почерковедческой экспертизе**

#### **3.2.1. Общие правовые вопросы**

Говоря об общей правовой регламентации использования искусственных нейронных сетей и других алгоритмов искусственного интеллекта как в судебно-почерковедческой экспертизе, так и в судебно-экспертной деятельности, важно прежде всего обратить внимание на то, как эти системы будут регулироваться с правовой точки зрения в целом. Как упоминалось

ранее, искусственный интеллект представляет собой идею и научное направление в информатике, в то время как ИНС – лишь одна из практических реализаций этой идеи.

В то же время сегодня эти системы с позиции права во многом схожи. Это неудивительно, поскольку правовые нормы обычно разрабатываются таким образом, чтобы максимально полно охватывать явления или сферы общественной жизни, которые они регулируют. В связи с этим, раз нейронные сети являются частью области искусственного интеллекта, возникает закономерный вопрос: почему бы не попытаться выработать такие универсальные правовые нормы, которые можно было бы применять и к другим практическим реализациям ИИ? Однако сразу же возникает другой логичный вопрос: чем считать эти системы – обычными компьютерными программами или новым явлением?

Как отмечает Г.Г. Камалова: «...вне зависимости от уровня искусственного интеллекта современное право любые компьютерные средства и системы признает средствами деятельности»<sup>1</sup>. Однако ранее мы уже упоминали, что некоторые исследователи и юристы стали придерживаться идеи о наделении ИИ отдельным правовым статусом, вплоть до признания его самостоятельным субъектом права с соответствующими правами и обязанностями. Речь здесь идет прежде всего о так называемом «сильном ИИ»<sup>2</sup>.

В настоящее время в современном российском праве имеется только одно легитимное понятие искусственного интеллекта, которое закреплено в п. «р» ст. 4 Указа Президента Российской Федерации от 10 октября 2019 г. № 490. Звучит оно следующим образом: «Модель искусственного интеллекта – программа для электронных вычислительных машин (ее составная часть),

---

<sup>1</sup> Камалова, Г.Г. Цифровые технологии в судебной экспертизе: проблемы правового регулирования и организации применения // Вестник Удмуртского университета. Серия Экономика и право. – 2019. – Т. 29, № 2. – С. 180–186.

<sup>2</sup> Впервые термин «сильный искусственный интеллект» был использован Дж. Сёрлом в 1980 г. (Searle J. R. Minds, brains, and programs // Behavioral and brain sciences. – 1980. – Т. 3. – №. 3. – С. 417–424).

предназначенная для выполнения интеллектуальных задач на уровне, сопоставимом с результатами интеллектуального труда человека или превосходящем их, использующая алгоритмы и наборы данных для выведения закономерностей, принятия решений или прогнозирования результатов». Как можно видеть, данное определение максимально коррелирует с теми научными представлениями об ИИ-технологиях, которые мы приводили ранее. Это подтверждает ранее высказанное мнение Г. Г. Камаловой о том, что сейчас ИИ-технологии признаются компьютерными программами.

В то же время, когда мы начинаем говорить о «сильном ИИ», ситуация меняется. Сегодня «сильный ИИ» воспринимается многими исследователями как явление, когда «машина» при достижении определенного порога вычислительной мощности будет не только выполнять любые задачи на уровне человека, но и существенно превосходить его в этом. Более того, такая «машина» будет способна осознавать себя как отдельную личность со своими потребностями и целями. В контексте судебно-экспертной деятельности это означает, что такую «программу» уже сложно будет признать техническим средством, которое используется в рамках какого-то метода исследования. В связи с этим, как видится некоторым специалистам, наиболее логичным шагом в этом вопросе становится наделение ИИ определённым правовым статусом в рамках судебного процесса. Иными словами, за ИИ будет закрепляться определенная роль участника судебного процесса.

Однако мы считаем, что подобные предложения являются преждевременными и во многом базируются на искаженных представлениях СМИ об ИИ и нейронных сетях. Для подтверждения нашей позиции детально разберем концепцию «сильного ИИ». Начнем с того, что согласно ей компьютерные программы будут выполнять интеллектуальные задачи на уровне человека и местами превосходить его в этом. Как показывает практика последних нескольких лет, современные искусственные нейронные сети уже превосходят среднестатистического человека в возможности решать некоторые задачи. В частности, исследования Стэнфордского университета

показывают, что нейросети лучше справляются с задачами в области компьютерного зрения и пониманием английского языка<sup>1</sup>.

Однако на фоне этих успехов возникает вопрос: какой ценой достигаются подобные результаты? Современные мультимодальные модели, по сути, остаются математическими алгоритмами. Они отличаются друг от друга, в том числе и от тех, что мы использовали в нашем исследовании, лишь количеством параметров и особенностями внутренних вычислительных блоков. Так, современные мультимодальные модели, такие как GPT-4, Gemini и др., основаны на архитектуре авторегрессионного трансформера, который может обрабатывать как текстовые, так и визуальные данные. Несмотря на различные реализации, структура таких моделей может быть обобщена в виде трёх основных функциональных компонентов (на примере Chameleon)<sup>2</sup>:

- Смешанная вторегрессионная языковая модель (Mixed-Modal Auto-Regressive Language Model), которая представляет собой центральный вычислительный модуль системы. Она обрабатывает векторные представления входных данных, а также выполняет трансформации промежуточных и выходных состояний, формируя семантически значимое содержимое. Условно данный модуль можно рассматривать как «ядро» нейросетевой архитектуры;

- Входные уровни, необходимые для преобразования различных типов входных данных (текст, изображения и пр.) в унифицированное векторное представление. Текстовая информация кодируется напрямую, тогда как визуальные данные предварительно обрабатываются с использованием вариационных кодировщиков или сверточных сетей, после чего также трансформируются в векторы фиксированной размерности;

- Выходные уровни, выполняющие операции по обратному преобразованию: векторные представления интерпретируются декодерами и

---

<sup>1</sup> Maslej N. et al. Artificial Intelligence Index Report 2024 //arXiv preprint arXiv:2405.19522. – 2024.

<sup>2</sup> Team C. Chameleon: Mixed-modal early-fusion foundation models //arXiv preprint arXiv:2405.09818. – 2024.

преобразуются в данные целевой модальности – текстовые фрагменты, изображения либо иные формы выходной информации.

Как можно видеть, даже для решения относительно простых задач по генерации текста, изображений и т. п., необходимо создавать большие математические вычислительные системы, где каждый элемент выполняет собственную задачу. Конечно, в противовес можно указать, что согласно исследованиям последних лет, человеческий мозг также имеет отдельные зоны, настроенные на обработку той или иной информации. Однако, как верно замечают С.И. Никоненко, А.А. Кадури и Е.В. Архангельская, компьютерные системы все равно сильно отстают от возможностей человеческого мозга по обработке информации<sup>1</sup>. Современные нейросети и ИИ-алгоритмы могут быстро находить нужную информацию по запросам пользователей и обучаться на основе данных.

Однако у них есть физические ограничения, которые не позволяют им полноценно развиваться. Сегодня системы искусственного интеллекта функционируют в рамках больших компьютерных центров, вследствие чего они не могут как человек постоянно взаимодействовать со всей окружающей средой. Из-за этого у них отсутствует субъективный опыт, что мы разбирали в контексте проблемы решения задачи криминалистической идентификации.

Нельзя не упомянуть и то, что базовый принцип обучения ИНС, строящийся на методе обратного распространения ошибки и градиентном спуске, не претерпел принципиальных изменений с момента его создания, несмотря на многочисленные модификации. Во многом из-за этого для достижения приемлемых с практической точки зрения результатов ИНС и иные схожие системы необходимо обучать на колоссальных объемах данных в течение длительного времени.

---

<sup>1</sup> Никоненко С. И., Кадури А. А., Архангельская Е. В. Глубокое обучение. Погружение в мир нейронных сетей // СПб.: Питер. – 2018. – С. 30–37.



Более того, это требует значительных объемов вычислительных мощностей, причем как на этапе создания, так и на стадии самой эксплуатации модели. Например, как показывают исследования Д. Кастро, нейронные сети при обучении используют несколько сотен GPU, потребляя при этом от 1.5 до 456 МВт·ч<sup>1</sup>. Для сравнения, энергопотребление мозга человека оценивается в диапазоне от 10 до 25 Вт·ч<sup>2</sup>

Это подводит нас к следующему выводу: на текущем уровне развития науки и техники ИНС и большая часть алгоритмов ИИ действительно сильно превосходят «классические» программы и программные комплексы, а также человека в решении отдельных задач и аналитике. Однако говорить о том, что эти «машины» обладают собственной волей, представляется не очень корректным.

Фактически современные ИИ-системы являются большими самоорганизующимися хранилищами разнообразной информации. Нельзя не признать, что подобные программы действительно могут принимать отдельные решения. Однако делают это они в большей степени статистически, т. е. путем обработки конкретных данных принимают на их основе лучшее решение с точки зрения статистики. В связи с этим говорить о возможности наделения правосубъектностью нейросетевые алгоритмы и иные схожие аналитические модели сильно преждевременно.

Вместе с тем неразумно запрещать использование результатов, полученных с помощью ИИ. Мы показали, что причина таких призывов – сложность интерпретации этих результатов. Действительно, важно, чтобы ИИ-системы могли объяснить, какие закономерности они выявляют, особенно в судебной экспертизе. Но решить эту проблему можно только в техническом поле. Любой законодательный запрет на использование ИИ и нейронных сетей может замедлить интеграцию этих систем в судебно-экспертную деятельность.

---

<sup>1</sup> D. Castro. Rethinking Concerns About AI's Energy Use // Center for Data Innovation. – 2024.

<sup>2</sup> Sandberg A. Energetics of the brain and AI //arXiv preprint arXiv:1602.04019. – 2016.

Резюмируя вышесказанное можно заключить, что на текущем этапе внедрения ИИ-технологий в судебную экспертизу предлагается проводить их нормативно-правовое регулирование на уровне нормативно-технической документации в виде ГОСТ по аналогии с обычными компьютерными программами<sup>1</sup>. Подобные примеры правового регулирования в практике других сфер общества уже существуют. Так, в области медицины уже введены такие государственные стандарты как ГОСТ Р 59525–2021, ГОСТ Р 59921.7–2022, в которых нейросетевые системы и иные схожие алгоритмы признаются техническими средствами. Также в этих стандартах прописаны требования и рекомендации по проектированию, обучению и работе с такими программами. Кроме того, уже сейчас в области криминалистики<sup>2</sup> имеются практические примеры применения систем, построенных на искусственных нейронных сетях.

Безусловно, развитие науки и техники не стоит на месте, и потенциально в будущем возможно появление так называемого «сильного ИИ». Однако, на наш взгляд, поднимать подобную проблему в судебной экспертиологии преждевременно.

Напомним снова – ИИ позиционирует себя именно как научное направление по созданию алгоритмов решения сложных задач, с которыми в конкретный момент времени может справиться только человек. Вследствие этого, когда мы говорим о вопросе интеграции ИИ в СЭД, то в первую очередь имеем в виду идею о внедрении компьютерных и иных схожих вычислительных моделей, направленных на автоматизацию какого-то спектра задач. Иными словами, мы по большей части адаптируем алгоритмы искусственного интеллекта под нужды судебной экспертизы.

Концепция «сильного» искусственного интеллекта сильно отличается от этих положений. Ее суть в основном состоит уже в создании «искусственного

---

<sup>1</sup> Которые уже давно активно используются в судебно-экспертной деятельности.

<sup>2</sup> В 9-ю версию АДИС (AFIS) Папилон внедрена нейросеть / [Электронный ресурс] // Системы Папилон: [сайт]. – URL: <https://www.papillon.ru/about/blog/v-9-uju-versiju-adis-afis-papillon-vnedrena-nejroset/> (дата обращения: 23.04.2025).

разума», т. е., грубо говоря, новой формы жизни. Такая идея имеет право на существование. Однако ее реализация требует других научно-технических решений и философского переосмысления понятий жизни и разума. Это, в свою очередь, повлечет за собой пересмотр всех привычных аспектов жизнедеятельности общества. На фоне этого судебная экспертология, вероятнее всего, не будет адаптировать «сильный ИИ» под свои нужды, а сама трансформируется под влиянием этих изменений.

### **3.2.2. Вопросы защиты персональных данных**

Не менее важным с правовой точки зрения является и вопрос сохранности персональных данных лиц, чьи образцы используются в процессе исследования и обучения нейронных сетей. На сегодняшний день правовой статус рукописного почерка точно не определен. Например, в утратившем силу разъяснении Федеральной службы по надзору в сфере связи, информационных технологий и массовых коммуникаций от 30 августа 2013 г. указано следующее: «Также не является биометрическими персональными данными ... подпись лица, наличие которой в различных договорных отношениях является обязательным требованием, и почерк, в том числе анализируемый уполномоченными органами в рамках почерковедческой экспертизы. Все они не могут рассматриваться как биометрические персональные данные, поскольку действия с использованием указанных данных направлены на подтверждение их принадлежности конкретному физическому лицу, чья личность уже определена и чьи персональные данные уже имеются в распоряжении оператора»<sup>1</sup>. Нельзя не заметить и то, что какие-либо дополнительные разъяснения в виде официальных НПА по этому вопросу от Роскомнадзора на сегодняшний момент отсутствуют.

При этом, учитывая положения п. 1 ст. 3 Федерального закона от 27 июля 2006 года № 152-ФЗ «О персональных данных», в соответствии с которым

---

<sup>1</sup> Аналогичная информация указана и в ответе на сделанное автором обращение в Федеральную службу по надзору в сфере связи, информационных технологий и массовых коммуникаций Российской Федерации (Роскомнадзор) от 02.07.2025 № 08–312104 (см. приложение №31)

персональными данными признается любая информация, относящаяся к прямо или косвенно определенному или определяемому физическому лицу (субъекту персональных данных), можно заключить, что почерк человека де-факто может быть признан персональными данными или, по крайней мере, иметь с ними тесную связь. В связи с этим некоторые специалисты обоснованно выражают озабоченность по поводу обеспечения сохранности указанной информации.

Данный вопрос можно рассмотреть с двух сторон. Первая – это ситуация, когда нейронная сеть обучается «локально», на представленных образцах для сравнения. В этом случае проблемы, связанные с защитой персональных данных, не возникают, поскольку они регулируются действующим законодательством. Во-первых, процедура получения и использования образцов почерка регламентируется Федеральным законом от 31 мая 2001 года № 73-ФЗ «О государственной судебно-экспертной деятельности в Российской Федерации». В частности, это регулируется абз. 3 ст. 19 указанного закона, а также процессуальным законодательством, включая статьи 202 УПК РФ, 81 ГПК РФ и 26.5 КоАП РФ.

Во-вторых, в соответствии с положениями упомянутого закона и процессуального законодательства, эксперт не имеет права разглашать информацию, полученную в ходе проведения судебной экспертизы. Это означает, что он не может раскрывать третьим лицам, чьи подписи были исследованы, личность их автора или особенности почерка.

Проводя аналогию, можно утверждать, что создаваемая в рамках конкретной судебной экспертизы нейросетевая модель уже подпадает под действие вышеупомянутых положений. Во-первых, ИНС, как мы определили ранее, представляет собой метод исследования, который применяется для анализа предоставленных объектов с целью получения доказательственной информации. Во-вторых, обучение модели осуществляется исключительно на основе этих образцов и может проводиться на рабочем компьютере эксперта.

Последнее в настоящее время технически выполнимо, особенно если учесть, что обработке подлежит сильно ограниченная выборка данных.

Таким образом, по нашему мнению, использование нейросетей в данном контексте уже регулируется законодательством. Более того, модель, обученная в рамках исследования, может быть приобщена к заключению судебного эксперта в качестве дополнительного материала, на который распространяются все соответствующие законодательные требования.

Сложнее обстоят дела при рассмотрении второй стороны вопроса, которая предполагает обучение модели решать в целом какую-то задачу. Как неоднократно подчеркивалось, в рамках «глобального» подхода к обучению нейронных сетей требуется использование большого объема данных. В связи с этим возникает вопрос о способах и источниках их получения.

В настоящее время существует значительное количество открытых баз данных<sup>1</sup>, содержащих разнообразные образцы почерка, включая рукописные тексты, подписи и синтетические образцы<sup>2</sup>. Однако, как справедливо отмечает Е.Р. Россинская: «Если модель была обучена год назад, то факты, которые имели место за последний год, ей недоступны для оперирования»<sup>3</sup>. Это означает, что подобные базы данных необходимо постоянно обновлять. К сожалению, в настоящее время это обычно не осуществляется. Вместо этого появляются новые, часто плохо систематизированные наборы данных.

В связи с этим представляется более эффективным и простым способом обучение ИНС на «реальных» материалах различных судебно-почерковедческих экспертиз. Систематизация данных, полученных в

---

<sup>1</sup> Подробнее см., например, Фазылов Ш.Х., Мирзаев Н.М., Раджабов С.С., Дадаханов М.Х., Асраев М.А. Методы и алгоритмы идентификации личности на основе анализа изображений рукописного текста // Проблемы вычислительной и прикладной математики. – 2020. – №5(29). – С. 5–26.

<sup>2</sup> Синтетические образцы представляют собой имитации подписей, кратких записей или других рукописей, созданные с использованием компьютерных программ. Эти образцы могут воспроизводить почерк конкретного индивида или генерировать его «с нуля».

<sup>3</sup> Россинская Е. Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы // Вестник Университета имени О.Е. Кутафина (МГЮА). – 2024. – № 3(115). – С. 31.

результате исследования такого рода информации, может способствовать разработке более эффективных моделей, поскольку «реальные» объекты исследования, как правило, характеризуются значительно большей сложностью по сравнению с их искусственными аналогами, создаваемыми в рамках экспериментальных исследований.

Однако в этом случае мы сталкиваемся с правовыми аспектами защиты персональных данных, поскольку использование подобных «реальных» объектов фактически выходит за рамки отдельно взятого судебно-экспертного исследования. В связи с этим применение правовых положений, регулирующих каждую конкретную экспертизу, к подобным процедурам становится затруднительным.

На фоне этого целесообразным видится рассмотреть вопрос о внесении дополнительных законодательных уточнений, касающихся использования «реальных» материалов судебных экспертиз для проведения соответствующих научных исследований. Внедрение подобной регламентации позволит расширить и систематизировать статистические данные о распространенности общих, частных и диагностических признаков почерка в текущий момент времени.

В то же время, для обеспечения сохранности персональных данных можно предусмотреть процедуру их обезличивания – действия, в результате которых становится невозможным без использования дополнительной информации определить принадлежность персональных данных конкретному субъекту персональных данных<sup>1</sup>. Подобные методы уже активно применяются в медицинской сфере, а процедура их использования регулируется такими актами как ГОСТ Р 59525–2021 и ГОСТ Р 59921.7–2022<sup>2</sup>.

---

<sup>1</sup> П. 9, ст. 3 Федерального закона от 27.07.2006 №152-ФЗ «О персональных данных».

<sup>2</sup> Также наглядным примером являются открытые базы данных рентгеновских снимков, предоставляемые ГБУЗ «Научно-практическим клиническим центром диагностики и телемедицинских технологий Департамента здравоохранения города Москвы» (Компьютерное зрение в лучевой диагностике: первый этап Московского эксперимента: Монография. 2-е издание, переработанное и дополненное / Ю. А. Васильев [и д. р.]. – [б. м.]: Издательские решения, 2023.).

Благодаря процедуре обезличивания можно оставить только наиболее абстрактную информацию об авторе в виде половой принадлежности, возраста (указанный в виде диапазона) и профессиональную принадлежность в обобщенной форме. Например, можно указать, что субъект связан с делопроизводством или относится к творческой профессии, без конкретизации. Подобные меры гипотетически позволят избежать возможные утечки персональных данных.

Следует также обратить внимание на потенциальную проблему, связанную с генерацией почерка от вымышленного лица. Она представляется несущественной, поскольку уже сегодня в открытом доступе имеется значительное количество образцов подписей, кратких записей и других видов рукописей. Таким образом, создание еще одного банка данных с обезличенными образцами подписей не окажет значительного негативного воздействия. В то же время, благодаря постоянной актуализации данных, банк образцов подписей может способствовать развитию теоретических и практических аспектов почерковедения, обеспечивая надежную основу для научных исследований и практического применения в данной области.

### **3.2.3. Организационная сторона вопроса интеграции ИИ и нейронных сетей**

Последнее, что хотелось бы рассмотреть в этом разделе, это организация процесса экспертного исследования, в котором планируется применение ИНС. Первоначально отметим, что разработка и обучение нейронных сетей по-прежнему представляют собой сложный и многоэтапный процесс, который в настоящее время никак не связан с производством судебно-почерковедческой экспертизы. В силу этого сегодня у эксперта-почерковеда отсутствуют необходимые компетенции в сфере искусственного интеллекта и иных информационных технологий.

В связи с этим ряд исследователей предлагает привлекать специалистов из смежных научных областей, обладающих соответствующими знаниями и навыками в области ИИ и информационных технологий. Данная практика уже

получила широкое распространение и находит свое отражение в проведении комплексных экспертных исследований. Примером такого подхода является привлечение лингвистов для анализа почерков, выполненных на иностранных языках<sup>1</sup>. Однако если мы говорим о ИИ и нейросетях, то тут с привлечением специалистов определенного профиля могут возникнуть некоторые трудности.

Первая сложность возникает в том, какого конкретного специалиста нужно привлекать в помощь судебному эксперту? Как мы уже неоднократно указывали, ИИ-алгоритмов в настоящее время существует большое количество, в связи с чем очень сложно найти специалиста, который бы мог разбираться во всех этих системах. Данный факт актуален и для нейронных сетей. Буквально за 10 лет нейронные сети эволюционировали от достаточно простых моделей до больших языковых моделей и ИИ-агентов.

Несмотря на то, что в России стали вводить образовательные программы, по которым осуществляется академическая подготовка специалистов в области разработки нейронных сетей и ИИ-систем, важно понимать, что постоянно возникают новые, более эффективные подходы в проектировании подобных программных комплексов, которые зачастую не учитываются в действующих учебных планах. В связи с этим на передний план выходит, во-первых, выбор конкретных алгоритмов, которые будут использоваться в процессе экспертного исследования, и во-вторых, компетенция специалиста, которого планируется прилечь в помощь судебному эксперту для проведения соответствующего исследования, а именно его умение работать с выбранными алгоритмами.

Вторая сложность связана с определением фактической роли специалиста по машинному обучению и анализу данных. Так, Е.Р. Россинская выражает по этому вопросу неоднозначное мнение. С одной стороны, отмечается, что развитие новых технологий требует появления новых

---

<sup>1</sup> См., например, Бобовкин С.М., Четверкин П.А. Методические основы судебно-почерковедческой идентификационной экспертизы китайских иероглифических рукописей: возможности реализации комплексного подхода. Вестник Московского университета МВД России. 2020(6):197–203.



экспертных компетенций, что будет рассмотрено ниже. С другой стороны, внедрение искусственных нейронных сетей обуславливает необходимость появления в судебно-экспертной деятельности специалистов следующих направлений<sup>1</sup>:

- Аналитик данных, который осуществляет описание данных, выявление в них закономерностей и анализ результатов выявления взаимосвязей между различными признаками;

- Инженер экспертных данных, чья задача заключается в структурировании данных, полученных аналитиком, а также обеспечении их целостности и качества;

- Инженер машинного обучения, выполняющий обучение нейросетевой модели, оценивающий её качество и проверяющий эффективность.

В контексте вышеуказанного возникает ряд вопросов. Первый из них касается объёма задач, которые будут возлагаться на эксперта-почерковеда. Ранее было отмечено, что в рамках «локального» подхода эксперт может проводить обучение ИНС для получения необходимых результатов. Однако, исходя из наших предположений, это обучение осуществляется только в рамках ограниченной выборки, то есть анализу подвергаются исключительно те материалы, которые непосредственно связаны с конкретной судебной экспертизой. Более того, этот процесс обучения происходит только по заранее подготовленным и валидированным методическим схемам.

Мы согласны с мнением многих авторов о том, что судебная экспертиза представляет собой творческий исследовательский процесс. Однако в современных условиях, когда процессы стандартизации и максимальной формализации экспертных методик становятся всё более распространёнными, любое отклонение от валидированных схем решения типовых задач уже воспринимается многими юристами как основание для оспаривания результатов экспертного исследования.

---

<sup>1</sup> Россинская Е.Р. Система теории цифровизации судебно-экспертной деятельности // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 20–32.

Возвращаясь к вопросу компетенций, следует отметить, что в рассматриваемом предложении также, по всей видимости, подразумевается обучение ИНС в рамках «глобального» подхода, что, на наш взгляд, сильно увеличивает нагрузку на судебного эксперта.

Второй вопрос касается ситуации, когда предполагается привлечение специалистов в области аналитики данных. В этом контексте возникает неясность относительно функций судебного эксперта в процессе исследования, поскольку основная работа, в том числе по выявлению, анализу и оценке признаков, выполняется программистом. В частности, роль аналитика данных прямо предполагает выявление каких-либо закономерностей в исследуемых объектах. Из-за этого возникает вопрос о возможном дублировании компетенций между экспертом и аналитиком данных.

Кроме того, появляется необходимость определения методов и методик, которые будут применяться в подобных исследованиях. Как отмечает Ш.Н. Хазиев, в последние годы значительно развились системы биометрической идентификации, которые могут быть использованы в судебно-экспертных исследованиях<sup>1</sup>. В связи с этим логично, что привлеченный специалист по компьютерной технике будет стремиться использовать в экспертизе известные ему подходы, так как в настоящее время в рамках судебной экспертологии глобально такие методики еще не разработаны. Однако, как указывает упомянутый автор, эти «биометрические» подходы не всегда применимы на практике, поскольку они более подвержены различным ошибкам и не адаптированы под специфические нужды судебной экспертизы<sup>2</sup>.

---

<sup>1</sup> Хазиев Ш.Н. Криминалистические и судебно-экспертные основы современных биометрических технологий // Теория и практика судебной экспертизы. 2023. Т. 18. № 1. С. 16–21

<sup>2</sup> Подробнее эту проблему мы рассматривали это в одной из своих публикаций (Мищук В.А. Использование искусственных нейронных сетей для решения задач судебно-почерковедческой экспертизы: анализ зарубежного опыта // Теория и практика судебной экспертизы. 2025. Т. 20. № 1. С. 44–65.).

В связи с изложенным, представляется более целесообразным предложить следующую модель организации применения ИИ-технологий, в частности нейронных сетей, в экспертной практике:

1) Разработка типовых методик экспертного исследования, включающих в себя использование нейросетевых или иных схожих алгоритмов. Эти методики должны соответствовать установленным требованиям, включая интерпретируемость результатов, научную обоснованность и другие критерии;

2) На основе разработанных методик создание программного обеспечения, используемого для их реализации. Обслуживание и поддержка функционирования программного комплекса должны быть возложены на специалистов в области анализа данных и машинного обучения;

3) Обучение судебных экспертов работе с программным комплексом и методиками, основанными на ИИ.

Данный подход предполагает расширение компетенций экспертов, о чем ранее упоминала Е.Р. Россинская. Фактически, программисты будут выполнять роль специалистов по научно-методическому обеспечению, что имеет ряд преимуществ. Во-первых, это позволяет избежать дополнительных вопросов о процессуальном статусе программистов. Во-вторых, это способствует оперативному обновлению методик и программного обеспечения в сотрудничестве с экспертами.

Последние, в свою очередь, обладающие необходимыми компетенциями в области применения ИИ-алгоритмов, смогут эффективно решать поставленные задачи. С одной стороны, они имеют базовую подготовку по конкретной экспертной специальности, а с другой – дополнительные знания, позволяющие им понимать базовые особенности работы программного обеспечения и эффективно использовать его. Причем современные средства компьютерной техники позволяют создавать программы и веб-приложения, в которых пользователи могут интерактивно разрабатывать и обучать нейронные сети или другие алгоритмы машинного обучения. При этом пользователю не обязательно обладать глубокими профессиональными

знаниями для эффективной работы с такими системами. Достаточно владеть основами, тогда как основная часть вычислений и настройка алгоритмов осуществляются внутри системы. Подобный подход может быть применен и в рамках методик экспертного исследования, предусматривающих использование нейронных сетей или других алгоритмов машинного обучения.

Следует отметить, что практика применения подобных организационного-тактических схем уже существует. Например, судебные эксперты судебно-экспертных учреждений системы Минюста России после соответствующего обучения используют программу «ОКО-1» для исследования малоинформативных кратких записей и подписей. А с недавнего времени эксперты-криминалисты системы МВД РФ начали применять автоматизированную дактилоскопическую идентификационную систему (АДИС) «Папилон-9», в которой нейронная сеть используется для автоматического кодирования отсканированных изображений следов рук и их последующего поиска и сравнения с другими следами, хранящимися в базе данных<sup>1</sup>.

### **§ 3.3. Возможные направления по дальнейшей интеграции искусственных нейронных сетей в судебно-почерковедческую экспертизу**

#### **3.3.1. Объединение «динамического» и «статического» подходов**

Несмотря на достигнутые с использованием описанной ранее методики криминалистической идентификации определенные положительные результаты, следует отметить, что она обладает рядом существенных недостатков. Как отмечалось ранее, ключевым фактором, обуславливающим указанные недостатки, является использование в качестве исходной

---

<sup>1</sup> В 9-ю версию АДИС (AFIS) Папилон внедрена нейросеть // Системы Папилон: – URL: <https://www.papillon.ru/about/blog/v-9-iju-versiju-adis-afis-papilon-vnedrena-nejroset/> (дата обращения: 24.04.2025).

информации графических изображений рукописей. Данный тип данных не предоставляет явной информации о ряде ключевых характеристик почерка, таких как последовательность выполнения графических элементов письменных знаков, направления движений при их начертании и т. д.

В то же время, несмотря на указанные ограничения, многие исследователи продолжают активно работать над разработкой эффективных методов анализа рукописей, выполненных «традиционным» способом. Это обусловлено высокой востребованностью бумажного документооборота в различных сферах деятельности. В связи с этим специалисты вынуждены применять современные алгоритмы машинного обучения, включая сверточные нейронные сети и, в последнее время, нейронные сети с архитектурой Transformer, для извлечения релевантных характеристик из рукописных документов.

В противовес этому, для анализа «цифровых» рукописей, созданных с использованием стилуса, графического планшета или, с недавнего времени, на экране мобильного устройства<sup>1</sup>, применяются RNN, LSTM и Transformer<sup>2</sup>. Практическое исследование показывает, что данный подход обладает рядом преимуществ:

1) Точность: алгоритмы анализируют не только структурно-геометрические параметры почерка, но и последовательность выполнения штрихов. Это обусловлено тем, что в цифровой подписи данные признаки выражены более явно по сравнению со «статичными» изображениями подписей или аналогичных объектов;

---

<sup>1</sup> В контексте выполнения рукописей на экране мобильных устройств речь прежде всего идет о рукописных паролях в виде отдельных символов. Подробнее об исследовании таких объектов при помощи искусственных нейронных сетей см., например, в Chen Z. et al. Level online writer identification // International Journal of Computer Vision. – 2021. – Т. 129. – №. 5. – С. 1394–1409.

<sup>2</sup> Как можно заметить, архитектура Transformer применяется в различных направлениях. Однако нельзя игнорировать то, что при работе с последовательностями данный тип нейронной сети демонстрирует более высокую эффективность благодаря своей изначальной разработке для решения задач обработки последовательных данных. Для анализа изображений требуется адаптация данной архитектуры, что приводит к увеличению потребления вычислительных ресурсов.

2) Интерпретируемость: в «цифровых» рукописях фиксируются только штрихи, что исключает наличие фона и, следовательно, снижает уровень шумов, вызванных этим фоном. Кроме того, наличие явно выраженных признаков также способствует улучшению интерпретируемости<sup>1</sup>;

3) Вычислительная эффективность: анализ «цифровых» рукописей требует меньших вычислительных ресурсов, поскольку в них отсутствует ненужная информация, такая как фон. Это позволяет значительно сократить затраты на обработку данных.

В силу этих причин ближайшим перспективным направлением является «объединение» «статического» и «динамического» подходов в исследовании рукописей. Представляется, что достигнуть этого можно при помощи процедуры кодирования сфотографированных или отсканированных изображений рукописей. В подобной версии можно при помощи ИНС можно было бы сразу отмечать такие характеристики, как точки начала, окончания, пересечения и соединения движений, и уже на их основе выстраивать дальнейшую последовательность выполнения движений в виде координат точек, образующих отдельный сегмент рукописи.

В связи с вышеизложенным, наиболее перспективным направлением дальнейших исследований представляется интеграция «статического» и «динамического» подходов в анализе объектов судебно-почерковедческой экспертизы. Предполагается, что данная интеграция может быть достигнута посредством применения методов кодирования изображений рукописей, полученных в результате фотографирования или сканирования. В частности, в рамках предлагаемой методологии можно использовать нейронные сети для автоматического обнаружения таких ключевых характеристик как точки начала, окончания, пересечения и соединения движений. На основе этих данных будет возможно построение последовательности выполнения

---

<sup>1</sup> В качестве примера см. Zhang X. Y. et al. End-to-end online writer identification with recurrent neural network // IEEE transactions on human-machine systems. – 2016. – Т. 47. – №. 2. – С. 285–292.

движений в виде координат точек, образующих отдельные сегменты рукописи<sup>1</sup>.

Следует отметить, что методы, аналогичные предложенному, уже находят широкое применение в биометрических системах распознавания лиц и анализа следов пальцев рук. В связи с этим, предложенный подход обладает рядом существенных преимуществ:

1) Полученные данные характеризуются высокой информативностью, минимальным уровнем «шумов» и значительно ускоренной обработкой системой;

2) Метод обладает более высокой степенью интерпретируемости;

3) Он открывает возможности для более эффективной реализации «глобального» подхода к обучению нейронных сетей для анализа рукописей. В частности, данный метод может быть использован для кодирования объектов судебно-почерковедческой экспертизы. Такой подход представляется перспективным, поскольку он не требует учета уникальных особенностей каждой рукописи и не предполагает прогнозирования, а направлен исключительно на извлечение признаков;

4) Кодирование рукописных текстов с использованием специализированной системы позволяет эксперту осуществлять более тщательный контроль над процессом. В случае обнаружения ошибок в кодировке эксперт может оперативно их корректировать. Следует отметить, что подобная практика уже активно применяется в системе экспертно-криминалистических подразделений МВД РФ, в частности, при работе с АДИС «Папилон»;

5) Применение данного метода способствует более эффективной систематизации и анализу признаков почерка, выявлению общих тенденций и определению распространенности тех или иных признаков в конкретный

---

<sup>1</sup> В качестве примера см. Rahman A. U., Halim Z. A graph-based solution for writer identification from handwritten text // Knowledge and Information Systems. – 2022. – Т. 64. – №. 6. – С. 1501–1523.

момент времени. Это, в свою очередь, позволяет оценить информативность каждого признака в рамках конкретной экспертизы.

### **3.3.2. Возможности решения диагностических задач при помощи нейронных сетей**

В настоящей работе мы делали основной акцент на решении идентификационных задач судебно-почерковедческой экспертизы. Однако в рамках данного рода криминалистической экспертизы могут решаться и некоторые диагностические задачи. Хотя в основном они рассматриваются больше, как промежуточные стадии в процессе исследования, однако по-прежнему играют важную роль в комплексной оценке рукописного материала. Напомним, что диагностические задачи направлены в основном на установление различных обстоятельств, сопровождающих акт письма. Решение этих задач позволяет сделать выводы о личности пишущего, его психофизиологическом состоянии, а также условиях, в которых создавалась рукопись.

В частности, диагностическое исследование может включать выявление признаков необычных условий письма, которые могут свидетельствовать о возможной неподлинности изучаемой подписи. Либо напротив, человек, которых является автором этой подписи, находился в необычном психоэмоциональном состоянии: утомление, волнение, состояние аффекта<sup>1</sup>. Имеют место быть и физические ограничения, как например, тремор, вызванный заболеванием, иные полученные травмы<sup>2</sup>. Особым случаем является автоподлог, когда человек старается намеренно исказить свой почерк с целью затруднения его дальнейшей идентификации.

Интеграция нейросетевых методов в решение диагностических задач открывает новые горизонты для анализа. Мы не раз отмечали, что почерк

---

<sup>1</sup> См., например, Kedar S. V., Rokade S. Recognition of emotional state based on handwriting analysis and psychological assessment //Int. J. Eng. Adv. Technol. – 2019. – Т. 8. – №. 6. – С. 4395–4402.

<sup>2</sup> См., например, Zhao A., Li J. A significantly enhanced neural network for handwriting assessment in Parkinson's disease detection //Multimedia Tools and Applications. – 2023. – Т. 82. – №. 25. – С. 38297-38317.



можно рассматривать с позиции большого набора разнообразных данных. В силу этого имеется потенциальная возможность применения указанных методов анализа для выявления закономерностей, которые будут свидетельствовать о том или ином необычном факторе письма.

Так, наиболее очевидным является обучение нейросетей на больших массивах рукописей с заранее размеченными внешними и внутренними сбивающими факторам (например, письма в состоянии утомления или с признаками имитации). Поскольку у нас есть заранее определенный перечень потенциальных классов, подобный подход позволит создать нейросетевой диагностический классификатор, который будет:

- автоматически выделять нестабильные участки почерка, допустим, при помощи механизма внимания;
- ранжировать степень вероятности того или иного сбивающего фактора, как, например, состояние пишущего и т. д.

Причем обучить такой классификатор можно и целесообразнее обучить в рамках «глобального» обучения ИНС, поскольку это позволит модели максимально обобщить факторы, обуславливающие, например, половую принадлежность пишущего<sup>1</sup>. Представляется, что это в значительной степени позволит снизить субъективность экспертных экспертного исследования. Кроме этого, благодаря нейросетевым методам можно будет выявить новые диагностические признаки и в целом провести их дополнительную стандартизацию.

Таким образом, интеграция нейронных сетей для решения диагностических задач в судебно-почерковедческой экспертизе позволит:

- повысить объективность выводов;
- автоматизировать рутинные аналитические операции;
- выявлять скрытые закономерности, не всегда доступные визуальному восприятию;

---

<sup>1</sup> См., например, Xue G. et al. ATP-DenseNet: a hybrid deep learning-based gender identification of handwriting // Neural Computing and Applications. – 2021. – Т. 33. – С. 4611–4622.

– в перспективе, создать единую цифровую платформы для комплексной оценки и систематизации диагностических признаков.

Всё это формирует основу для взаимной интеграции качественно-описательной и количественной методик исследования.

### **3.3.3. Интеграция больших языковых моделей**

Последнее, на что хотелось бы обратить особое внимание, – это перспективы использования больших языковых моделей в процессе производства судебно-почерковедческой экспертизы. В настоящей работе основное внимание уделяется применению нейронных сетей для анализа рукописных объектов, включая как статические изображения, так и цифровые рукописи, фиксирующие динамику письма. Однако современные возможности LLM значительно шире и выходят далеко за рамки чисто аналитических функций.

Одним из ключевых направлений, представляющих интерес для криминалистической практики, является использование языковых моделей для автоматизации процесса подготовки экспертного заключения. Как известно, заключение эксперта, особенно в рамках судебно-почерковедческого исследования, в большинстве случаев имеет структурированную, типовую форму, включающую вводную часть, описание исследуемых объектов, методы исследования, результаты и выводы. Это делает процесс подготовки заключения потенциально пригодным для частичной или полной автоматизации с использованием LLM.

В частности, языковая модель может быть использована для:

- автоматического формирования текста заключения на основе введённых или выделенных экспертом признаков;
- редактирования черновика, подготовленного экспертом вручную;
- генерации пояснительных описаний выявленных признаков почерка с соблюдением научного стиля и терминологии, применяемого в почерковедении;

– структурирования выводов, соответствующих логике и стандартам судебной экспертологии.

Эксперт может использовать заранее подготовленные шаблоны для заключений, где зафиксированы основные разделы и формулировки, характерные для данного вида исследования. После анализа рукописи – вручную или с применением нейросетевых алгоритмов – эксперт-почерковед может либо самостоятельно внести описания выявленных признаков, либо задать языковой модели задание сформулировать соответствующие текстовые блоки на основе типовой лексики. Таким образом, LLM может взять на себя функцию «речевого конструктора», ускоряя рутинную часть оформления экспертных документов без потери точности и нормативного соответствия.

Дополнительным преимуществом такого подхода является возможность повышения качества и единообразия текстов заключений, минимизация стилистических и грамматических ошибок, а также обеспечение внутренней логической согласованности документа. Кроме того, при должной настройке такие модели могут выполнять роль «второго мнения» – автоматически проверяя завершённый текст заключения на наличие внутренних противоречий, неполных формулировок или логических пробелов.

Наконец, применение LLM может быть особенно полезным при необходимости составления черновиков заключений для учебных или тренировочных целей, а также при повышении квалификации экспертов. В таких случаях модель может генерировать примеры заключений, содержащие как корректные, так и ошибочные выводы, что даёт возможность использовать их в учебном процессе для анализа и обсуждения.

Подводя итог, можно утверждать, что интеграция больших языковых моделей в практику судебно-почерковедческой экспертизы открывает новые направления для повышения эффективности, стандартизации и качества экспертной деятельности, при этом оставляя за специалистом решающую роль в интерпретации и утверждении результатов исследования.

## ЗАКЛЮЧЕНИЕ

Настоящее диссертационное исследование представляет собой комплексный анализ теоретических и практических аспектов применения искусственных нейронных сетей (ИНС) в судебно-почерковедческой экспертизе. Прделанная работа позволила всесторонне обосновать и подтвердить высокую перспективность интеграции данных технологий для повышения ключевых показателей экспертной деятельности: эффективности, объективности и скорости проведения исследований. На основе системного анализа актуальной научной литературы, действующей нормативно-правовой базы и результатов проведенных эмпирических экспериментов были сформулированы ключевые выводы и разработаны практические рекомендации, учитывающие специфику и сложность внедрения ИНС в повседневную экспертную практику.

В частности, применительно к задаче определения потенциала и границ использования современных архитектур ИНС для исследования традиционных объектов судебно-почерковедческой экспертизы, автором были получены следующие основные результаты и сформулированы выводы:

1. Теоретическое обоснование целесообразности применения ИНС. Проведенный глубокий анализ последних достижений в области искусственного интеллекта (ИИ), машинного обучения и нейронных сетей создает прочную теоретическую базу для их применения в рамках судебно-экспертной деятельности. Установлено, что ИНС, являясь на сегодняшний день одним из наиболее мощных и гибких инструментов в арсенале ИИ-технологий, обладают значительным, но пока не до конца реализованным потенциалом в сфере судебно-почерковедческой экспертизы. Вместе с тем их практическое использование в доказывании по уголовным, гражданским и арбитражным делам требует неукоснительного соблюдения строгих требований к научной обоснованности, валидности, воспроизводимости и, что особенно важно, интерпретируемости получаемых результатов. Последнее

приобретает критическое значение, поскольку от этого напрямую зависит допустимость и доказательственная сила заключения эксперта. Следует подчеркнуть, что ИНС должны рассматриваться не как самостоятельная методика, а как специальные методы и инструменты в структуре комплексных экспертных методик. Эти методы, обеспечиваемые современными машинными средствами (включая автокодировщики, алгоритмы кластеризации, свёрточные нейронные сети (SNN), байесовские сети и продвинутые механизмы внимания, такие как CBAM, Self-Attention, Cross-Attention), не заменяют общенаучные методы познания (сравнение, описание, анализ, синтез), а органично дополняют и многократно усиливают их, автоматизируя трудоемкие процессы обработки и анализа больших массивов графических данных.

2. Историко-научный контекст автоматизации почерковедческих исследований. Проведенный историко-научный экскурс в область применения вычислительных методов и ранних прототипов ИНС для анализа почерка убедительно демонстрирует, что данная проблематика имеет глубокие корни и давно находится в фокусе внимания исследователей. Были систематизированы и выделены ключевые этапы развития данного направления как в отечественной, так и в зарубежной криминалистической науке. При этом установлено, что, несмотря на ранние теоретические разработки и высокий научный интерес к автоматизации почерковедческих исследований, их практическое внедрение в экспертную деятельность в прошлом было существенно ограничено недостаточным уровнем развития вычислительной техники и нерешенными проблемами интерпретируемости («проблема черного ящика»). Важно отметить, что если первая проблема сегодня в значительной степени преодолена, то вторая остается актуальной и требует поиска новых методологических решений.

3. Методологические подходы и экспериментальная апробация. Несмотря на обозначенные сложности, накопленный научный задел и современные исследования позволили сформулировать и обосновать ряд

эффективных методологических подходов к применению ИНС для решения типовых задач судебно-почерковедческой экспертизы. Результаты многочисленных исследований, а также итоги экспериментов, проведенных автором на специально собранном наборе данных (включающем около 100 экспериментальных образцов от каждого предполагаемого исполнителя и порядка 100 тестовых образцов), подтверждают, что ИНС могут успешно применяться для криминалистической идентификации исполнителя спорной подписи. В частности, разработанные автором архитектуры сиамских нейронных сетей, усиленные интегрированными механизмами внимания (CBAM, Self-Attention, Cross-Attention), в наиболее успешных конфигурациях продемонстрировали высокую классификационную точность (ACC) в диапазоне 83–97%. В то же время, полносвязные сети, реализованные по гибридной схеме, показали более скромные, но все же значимые результаты с точностью 65–82%.

В ходе исследования был сделан важный вывод о малой эффективности методов, основанных на непосредственном анализе изображения рукописи, когда нейросеть автоматически и неконтролируемо извлекает признаки. Как показали результаты интерпретации моделей, нейросеть действительно способна в процессе обучения выявлять и использовать отдельные значимые признаки почерка, однако этот процесс носит несистемный и стохастический характер, сильно зависящий от архитектуры, процедуры обучения, настройки гиперпараметров и состава обучающей выборки. Это приводит к нестабильности и непредсказуемости результатов в части их интерпретации (хотя отдельные повторяющиеся паттерны выявляемых признаков все же присутствует). В связи с этим, предлагается сосредоточить усилия на разработках, предполагающих двухэтапный подход: на первом этапе осуществляется предварительное кодирование и векторизация исследуемых рукописей, а на втором — целенаправленное извлечение, анализ и сопоставление формализованных признаков.

Таким образом, все полученные результаты свидетельствуют, что

максимальная эффективность использования нейронных сетей в анализе почерка достигается при корректной постановке экспертной задачи и выборе специализированной архитектуры модели. На основе этого автором была обоснована необходимость применения так называемого «локального» подхода. Его суть заключается в обучении или дообучении нейросети на конкретных данных, полученных в рамках каждого отдельного экспертного исследования (рукопись и сравнительные образцы конкретного лица). Такая процедура, по мнению автора, позволяет обеспечить значительно более высокую точность, адаптивность и надежность результатов.

4. Разработка методических рекомендаций по интеграции ИНС. На базе полученных теоретических и эмпирических результатов были разработаны детальные методические рекомендации по органичной интеграции ИНС в структуру частных и общих методик судебно-почерковедческой экспертизы. Предлагается следующая многоуровневая схема:

1) На уровне общих идентификационной и диагностической методик судебно-почерковедческой экспертизы: ИНС применяются на стадиях предварительного исследования (для кодирования рукописей и предварительного извлечения признаков почерка), аналитического изучения представленных рукописей и образцов для сравнения (для выявления общих, частных и диагностических признаков), сравнительного исследования (для сопоставления выявленных признаков) и оценки результатов (для расчета вероятностных метрик совпадения). Такая многоуровневая система позволяет контролировать эксперту-почерковеду каждый из отдельных этапов исследования, вносить необходимые корректировки, а также использовать разные нейросетевые модели, заточенные на выполнение определенного спектра задач, что обеспечивает гибкость в выборе алгоритмов и их возможной замене при появлении более совершенных вычислительных средств.

2) В частные (типовые) методики: ИНС используются для решения конкретных, четко формализованных задач определенной стадии экспертного

исследования. К ним можно отнести:

- кластеризация и предварительный отбор наиболее качественных и сопоставимых образцов для сравнительного анализа на стадии предварительного исследования;
- автоматизированное выявление диагностических признаков, свидетельствующих о необычных условиях выполнения подписи (например, состояние стресса, алкогольного опьянения, намеренное искажение<sup>1</sup>);
- прецизионное выделение, извлечение и анализ совокупности общих и частных признаков в исследуемой рукописи и сравнительных образцах;
- непосредственная идентификация исполнителя подписи путем количественного сравнения векторизованных признаков с последующей оценкой вероятности совпадения.

Повторимся, что предложенная модульная структура применения нейросетевых алгоритмов на каждом этапе исследования – от «цифровой фиксации» до формирования выводов – обеспечивает гибкость методики и сохраняет полный контроль со стороны эксперта на всех стадиях работы.

5. Проблемы валидации нейросетевых алгоритмов. Отдельное внимание уделено необходимости строгой валидации применяемых алгоритмов. Применение ИНС требует обязательной валидации в двух аспектах для обеспечения научной обоснованности, воспроизводимости и соответствия требованиям законодательства:

- для «глобальных» моделей (обученных на больших массивах обезличенных данных) должно проводиться создание верифицированных наборов данных и тестирование по схеме Е.Р. Россинской, с валидацией алгоритмов обучения и принятия решений с обязательной возможностью визуальной интерпретацией получаемых результатов. Иными словами, должна проводиться валидация самой нейросетевой модели.
- для «локальных» моделей (обученных на ограниченной выборке в

---

<sup>1</sup> Все перечисленное требует проведение дополнительных исследований.



рамках конкретной экспертизы) по мнению автора должна проводиться процедурная валидация по правилам апробации экспертных методик, включая оценку корректности, эффективности и верификацию на независимых данных. Иными словами, необходимо сфокусироваться в большей степени не столько на самом алгоритме, сколько на самой процедуре его использования и обучения для получения точных результатов.

6. Правовые и организационно-тактические аспекты. Проведен глубокий анализ правовых и организационных вопросов, неизбежно возникающих при использовании ИНС. Обосновано, что на современном этапе развития технологии нейросетевые алгоритмы должны рассматриваться в процессуальном поле как высокотехнологичные технические средства, применяемые экспертом в рамках утвержденного экспертного метода. В связи с этим их регулирование должно осуществляться в первую очередь через систему нормативно-технических документов (в частности, ГОСТов), по аналогии с другими программно-аппаратными комплексами. Кроме того, были детально рассмотрены вопросы защиты персональных данных при формировании обучающих выборок (в частности, предлагается обязательной процедуры обезличивания данных для обучения нейросетевых моделей), предложены пути правового и технического решения проблемы обезличивания данных как для «локального», так и для «глобального» подходов.

7. Предложения по организации применения ИНС. На основе проведенного анализа предложен комплекс организационных мер, направленных на эффективное и безопасное внедрение ИНС в экспертную практику. К ним относятся: необходимость централизованного создания программных комплексов с верифицированными и сертифицированными методиками, разработка программ повышения квалификации для экспертов, а также формирование междисциплинарных рабочих групп с привлечением специалистов по машинному обучению на этапах методической и программной разработки.

8. Перспективные направления дальнейших исследований. Определены наиболее перспективные векторы для будущих научных изысканий в данной области:

- создание гибридных моделей, объединяющих анализ «статических» (изображение) и «динамических» (биометрические данные процесса письма) характеристик рукописей для достижения максимальной точности;
- развитие нейросетевых алгоритмов для решения сложных диагностических задач, связанных с определением психофизиологического состояния пишущего лица;
- интеграция больших языковых моделей (LLM) для автоматизации рутинных процессов подготовки, структурирования и семантического анализа текста экспертных заключений, что позволит повысить их качество, единообразие и скорость оформления.

Таким образом, выполненное диссертационное исследование не только подтвердило научную обоснованность и практическую целесообразность применения искусственных нейронных сетей в судебно-почерковедческой экспертизе, но и заложило методологический фундамент для их дальнейшего внедрения. Разработанные подходы и рекомендации создают основу для развития нейросетевых технологий в экспертной практике, способствуя значительному повышению достоверности, объективности и эффективности судебной экспертизы.

Важно подчеркнуть, что очерченные выводы и рекомендации сфокусированы на исследовании рукописных объектов, выполненных традиционным способом. Анализ цифровых рукописных объектов (созданных с помощью стилуса, на графическом планшете) представляет собой отдельную, комплексную научную задачу, тесно связанную с исследованием «цифровых следов» и требующую самостоятельного изучения, тогда как настоящее исследование в большей степени направлено на создание опорной точки в вопросе интеграции искусственных нейронных сетей в область судебно-почерковедческой экспертизы.

## СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

ИИ – Искусственный интеллект

ИНС – Искусственные нейронные сети

МО – Машинное обучение

РФЦСЭ – Российский федеральный центр судебной экспертизы имени профессора А. Р. Шляхова при Министерстве юстиции Российской Федерации; также встречаются аббревиатуры ЦНИИСЭ и ВНИИСЭ – Центральный/Всесоюзный/Всероссийский научно-исследовательский институт судебных экспертиз Министерства юстиции СССР/РФ

СПЭ – Судебно-почерковедческая экспертизы

СЭД – Судебно-экспертная деятельность

ЭВМ – Электронно-вычислительная машина

АСС – Общая точность системы, которая рассчитывается как отношение количества верных прогнозов к их общему числу (Accuracy)

Attention – Механизм внимания в искусственных нейронных сетях

Attention map – Карта внимания

CBAM – Модуль сверточного внимания (Convolutional Block Attention Module)

CNN – Сверточные нейронные сети (Convolutional Neural Networks)

CPU – Центральный процессор (Central Processing Unit)

Cross-Attention – Механизм перекрёстного внимания в искусственных нейронных сетях

Dataset – Набор данных

Decoder – Декодирующая часть искусственной нейронной сети

Encoder – Кодированная часть искусственной нейронной сети

ERR – Показатель эффективности системы, при котором обе ошибки (FRR и FAR) эквивалентны (Equal Error Rate)

FAR – Коэффициент ложного доступа, который показывает, как часто система ошибочно идентифицирует посторонний образец как одного из зарегистрированных пользователей (ошибка 2-го рода) (False Acceptance Rate)

FC – Полносвязные нейронные сети (слои нейронных сетей) (Fully Connected Layer)

FRR – Коэффициент ложного отказа, который показывает, как часто система не признает подлинность зарегистрированного в ней пользователя (ошибка 1-го рода) (False Rejection Rate)

GAN – Генеративные нейронные сети (Generative Adversarial Network)

GOFAL – Старый добрый искусственный интеллект (англ. «Good old fashioned artificial intelligence»). Термин был введен Дж. Хоугеландом в 1985 г.

GPU – Графический процессор (Graphics Processing Unit)

GradCAM – Метод отображения активации класса с взвешенным градиентом (Gradient-weighted Class Activation Mapping)

GRU – Управляемые рекуррентные блоки (Gated Recurrent Units)

KAN – Искусственная нейронная сеть Колмогорова-Арнольда (Kolmogorov-Arnold Networks)

KNN – Алгоритм К-ближайших соседей (K-Nearest Neighbors)

LLM – Большая языковая модель (Large Language Model)

LOSS – Значение функции потерь; показывает, насколько хорошо прогнозы модели соответствуют целевым меткам

LSTM – Сеть с долгой краткосрочной памятью (Long short-term memory)

NAS – Национальная академия наук США (National Academy of Sciences)

NIST – Национальный институт стандартов и технологий США (National Institute of Standards and Technology)

Pooling – Субдискретизация; техника, которая уменьшает пространственные размеры входных карт признаков

Residual block – Остаточный блок

RNN – Рекуррентные нейронные сети (Recurrent neural network)

Self-Attention – Механизм самовнимания в искусственных нейронных сетях

SGD – Стохастический градиентный спуск

SNN – Сиамская нейронная сеть

SVM – Метод опорных векторов (Support Vector Machine); также встречается аббревиатура ON-SVM – одноклассовый метод опорных векторов

Transformer – Специальная архитектура искусственной нейронной сети, построенной на применении самовнимания

## СПИСОК ИСТОЧНИКОВ И ЛИТЕРАТУРЫ

### 1. Нормативные правовые акты, официальные документы РФ

1. Конституция Российской Федерации: принята всенародным голосованием 12 декабря 1993 г. изменениями, одобренными в ходе общероссийского голосования 01 июля 2020 г. (с учётом поправок, внесенных Законами РФ о поправках к Конституции РФ от 30 декабря 2008 г. № 6-ФКЗ, от 30 декабря 2008 г. № 7-ФКЗ, от 5 февраля 2014 г. № 2-ФКЗ, от 21 июля 2014 г. № 11-ФКЗ, от 14 марта 2020 г. № 1-ФКЗ, от 4 октября 2022 г. № 5-ФКЗ, от 4 октября 2022 г. № 6-ФКЗ, от 4 октября 2022 г. № 7-ФКЗ, от 4 октября 2022 г. № 8-ФКЗ) // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

2. Гражданский процессуальный кодекс Российской Федерации от 14.11.2002 № 138-ФЗ: в ред. от 01.04.2025 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

3. Уголовный кодекс Российской Федерации от 13.06.1996 № 63-ФЗ: в ред. от 21.04.2025 с изм. и доп., вступ. в силу с 02.05.2025 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

4. Уголовно-процессуальный кодекс Российской Федерации от 18.12.2001 № 174-ФЗ: в ред. от 21.04.2025 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

5. Кодекс Российской Федерации об административных правонарушениях от 30.12.2001 № 195-ФЗ: в ред. от 23.05.2025 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

6. О государственной судебно-экспертной деятельности в Российской Федерации: Федеральный закон от 31.05.2001 № 73-ФЗ в ред. от 22.07.2024 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

7. Об осуществлении идентификации и (или) аутентификации физических лиц с использованием биометрических персональных данных, о внесении изменений в отдельные законодательные акты Российской Федерации и признании утратившими силу отдельных положений законодательных актов Российской Федерации: Федеральный закон от 29.12.2022 № 572-ФЗ в ред. от 28.12.2024 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

8. О персональных данных: Федеральный закон от 27.07.2006 № 152-ФЗ в ред. от 08.08.2024 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

9. О развитии искусственного интеллекта в Российской Федерации (вместе с «Национальной стратегией развития искусственного интеллекта на период до 2030 года»): Указ Президента РФ от 10.10.2019 № 490 в ред. от 15.02.2024 // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

10. Вопросы организации производства судебных экспертиз в экспертно-криминалистических подразделениях органов внутренних дел Российской Федерации: Приказ МВД России от 29.06.2005 № 511 в ред. от 12.11.2024 (Зарегистрировано в Минюсте России 23.08.2005 № 6931) // Официальный сайт МВД РФ <https://мвд.рф>, 30.05.2025 г.

11. Об организации использования экспертно-криминалистических учетов органов внутренних дел Российской Федерации: Приказ МВД России от 10.02.2006 № 70 в ред. от 11.09.2018 // Официальный сайт МВД РФ <https://мвд.рф>, 30.05.2025 г.

12. Об утверждении Перечня родов (видов) судебных экспертиз, выполняемых в федеральных бюджетных судебно-экспертных учреждениях Минюста России, и Перечня экспертных специальностей, по которым предоставляется право самостоятельного производства судебных экспертиз в федеральных бюджетных судебно-экспертных учреждениях Минюста России:

Приказ Минюста России от 20.04.2023 № 72 в ред. от 31.01.2024 // Официальный сайт Минюста России <https://minjust.gov.ru/ru>, 30.05.2025 г.

13. Об утверждении критериев определения принадлежности проектов к проектам в сфере искусственного интеллекта: Приказ Минэкономразвития России от 29.06.2021 № 392 (Зарегистрировано в Минюсте России 28.07.2021 № 64430) // Официальный интернет-портал правовой информации <http://www.pravo.gov.ru>, 30.05.2025 г.

## **2. Стандарты**

14. ГОСТ Р 52633.5–2011 «Защита информации. Техника защиты информации. Автоматическое обучение нейросетевых преобразователей биометрия-код доступа». М.: Стандартинформ, 2018. – 15 с.

15. ГОСТ ISO/IEC 24713-1-2013 «Информационные технологии. Биометрические профили для взаимодействия и обмена данными. Часть 1. Общая архитектура биометрической системы и биометрические профили». М.: Стандартинформ, 2018. – 17 с.

16. ГОСТ Р 54412–2019 (ISO/IEC TR 24741:2018) «Информационные технологии. Биометрия. Общие положения и примеры применения». М.: Стандартинформ, 2019. – 37 с.

17. ГОСТ Р 59508–2021 «Судебно-почерковедческая экспертиза. Термины и определения». М.: Стандартинформ, 2021. – 11 с.

18. ГОСТ Р 59525–2021 «Информатизация здоровья. Интеллектуальные методы обработки медицинских данных. Основные положения». М.: Стандартинформ, 2021. – 9 с.

19. ГОСТ Р 59921.7–2022 «Системы искусственного интеллекта в клинической медицине. Алгоритмы анализа медицинских изображений. Методы испытаний. Общие требования». М.: Стандартинформ, 2021. – 30 с.



### 3. Монографии, учебники, учебные пособия

20. Амосов Н.М. Энциклопедия кибернетики / Н. М. Амосов, И. А. Артеменко/Отв. ред. ВМ Глушков // Киев: Укр. сов. энцикл, 1974. – 606 с.
21. Аристотель. Сочинения: В 4-х т. Т. 4 / Пер. с древнегреч.; Общ. ред. А.И. Доватура. М.: Мысль, 1983. – 830 с.
22. Баланов А.Н. Биометрия. Разработка и внедрение систем идентификации: учебное пособие для вузов / А. Н. Баланов. – Санкт-Петербург: Лань, 2024. – 228 с.
23. Белкин Р.С. Криминалистическая энциклопедия. – М.: Мегатрон XXI, 2000. 2-е изд. доп. – С. 224.
24. Боровская Е.В., Давыдова Н.А. Основы искусственного интеллекта: учебное пособие. 4-е изд., электрон. М.: Лаборатория знаний, 2020. – 130 с.
25. Брюхомицкий Ю.А. Биометрические технологии идентификации личности: учебное пособие / Ю. А. Брюхомицкий: Южный федеральный университет. Ростов-на-Дону; Таганрог: Издательство Южного федерального университета, 2017. – 263 с.
26. Бушов Ю.В., Светлик М.В., Нейрофизиология: учеб. пособие. – Томск: Издательство Томского государственного университета, 2021. – 124 с.
27. Дутова Н.В. и др. Дифференциация подлинных подписей и подписей, выполненных с подражанием после предварительной тренировки // Методическое письмо. М.: ВНИИСЭ, 1984. – 98 с.
28. Задоркин В.И. Организация учебного процесса: Учебное пособие. М.: РГСУ, 2013. – 107 с.
29. Комплексная методика установления подлинности (неподлинности) кратких и простых подписей. Методическое пособие для экспертов. – М.: ВНИИСЭ, 1987.
30. Ковалев С. А. Основы компьютерного моделирования при расследовании преступлений в сфере компьютерной информации монография / Ковалев С. А., Вехов В. Б. – М.: Буки-Веди, 2015. – 167 с.

31. Компьютерное зрение в лучевой диагностике: первый этап Московского эксперимента: Монография. 2-е издание, переработанное и дополненное / Ю. А. Васильев [и д. р.]: Издательские решения, 2023. – 376 с.

32. Коршиков, А.П. Общая методика проведения идентификационных почерковедческих исследований для установления исполнителей рукописных записей и подписей. Часть 1.: Методические рекомендации по определению технологических параметров выполнения рукописных записей. / А.П. Коршиков. М.: Центр специальной техники Института криминалистики ФСБ России, 2005. – 124 с.

33. Криминалистика: учебник / Т. В. Аверьянова, Р. С. Белкин, Ю. Г. Корухов, Е. Р. Россинская. 4-е изд., перераб. и доп. М.: Норма: ИНФРА-М, 2023. – 928 с.

34. Кулагин П.Г., Колонутова А.И. Экспертная методика дифференциации рукописей на мужские и женские. – Изд-во Всесоюзного НИИ МВД СССР, 1970. – 56 с.

35. Ланцман, Р.М. Кибернетика и криминалистическая экспертиза почерка / Р.М. Ланцман. М.: Наука, 1968. – 95 с.

36. Левашов О.В. Искусственное зрение. Искусственный интеллект. Нейронные модели живых сенсорных систем / О. В. Левашов. М.: URSS, 2022. – 248 с.

37. Мультимодальное издание «Судебная экспертиза: перезагрузка». Часть II. Энциклопедический словарь теории судебной экспертизы. М.: ЭКОМ, 2012. – 456 с.

38. Нейронные сети: история развития теории: учеб. пособие для вузов / общ. ред. Галушкин А. И., Цыпкин Я. З. Стереотипное изд., перепеч. с изд. 2001 г. М.: Альянс, 2015. – 839 с.

39. Никоненко С. И., Кадуринов А. А., Архангельская Е. В. Глубокое обучение. Погружение в мир нейронных сетей // СПб.: Питер, 2018 – 480 с.

40. Орлова В.Ф. и др. Судебно-почерковедческая экспертиза: общая часть // Теоретические и методические основы (Под науч. ред. ВФ Орловой, 2-е изд., РФЦСЭ при Минюсте РФ. М.: Наука, 2006. – 543 с.

41. Основы судебной экспертологии: учебно-методическое пособие – М.: ФБУ РФЦСЭ при Минюсте России, 2023 – 384 с.

42. Почерковедение и почерковедческая экспертиза / под ред. В. В. Серегина: учебник – Волгоград: ВА МВД России, 2014. – 349 с.

43. Применение методов исследования, основанных на вероятностном моделировании, в судебно-почерковедческой экспертизе: (Метод. пособие) / М-во юстиции СССР. Всесоюз. науч.-исслед. ин-т судебных экспертиз. М., 1976. – 358 с.

44. Проблемы правовой кибернетики / Науч. совет по комплексной проблеме «Кибернетика» АН СССР. Секция «Кибернетика и право». Центр науч.-исслед. ин-т судебных экспертиз Юрид. комис. при Совете Министров РСФСР. Ин-т государства и права АН СССР...; Под общ. ред. В. Н. Кудрявцева и А. Р. Шляхова, М., 1968. – 268 с.

45. Правовая кибернетика / Ред. коллегия: В. Н. Кудрявцев (отв. ред.) и др. М.: Наука, 1970. – 334 с.

46. Применение математических методов и вычислительной техники в праве, криминалистике и судебной экспертизе / Под общ. ред. В. Н. Кудрявцева и А. Р. Шляхова; Науч. совет по комплексной проблеме «Кибернетика» АН СССР. Всесоюз. науч.-исслед. ин-т судебных экспертиз М-ва юстиции СССР. Всесоюз. ин-т по изучению причин и разработке мер предупреждения преступности Прокуратуры СССР. М., 1970. – 187 с.

47. Редько В.Г. Эволюция, нейронные сети, интеллект: модели и концепции эволюционной кибернетики / В. Г. Редько; предисл. Г. И. Малинецкого. – Изд. 6-е. М.: URSS., 2009. – 220 с.

48. Романов П.С. Системы искусственного интеллекта. Моделирование нейронных сетей в системе MATLAB. Лабораторный практикум / П. С. Романов, И. П. Романова. 2-е изд., стер. Санкт-Петербург: Лань, 2022. – 140 с.

49. Россинская Е.Р. Теория судебной экспертизы (Судебная экспертология): учебник / Е.Р. Россинская, Е.И. Галяшина, А.М. Зинин; под ред. Е.Р. Россинской. 2-е изд., перераб и доп. М.: Норма: ИНФРА-М, 2025. – 368 с.

50. Ростовцев В.С. Искусственные нейронные сети: учебник для вузов / В. С. Ростовцев. 2-е изд., стер. Санкт-Петербург: Лань, 2021. – 216 с.

51. Самороковский В.М. Криминалистическая экспертиза почерка с применением математической модели вариационности признаков / М-во юстиции СССР. ВНИИ судебных экспертиз; Отв. ред. докт. юрид. наук Г.Л. Грановский. М., 1977. – 71 с.

52. Судебно-почерковедческая экспертиза документов: учеб.-практ. пособие / М. В. Жижина; под ред. Е. П. Ищенко. М.: Юрлитинформ, 2006 – 170 с.

53. Судебно-почерковедческая экспертиза малообъемных почерковых объектов. Вып. 3. Методика исследования подписей. Методическое пособие для экспертов / Под ред. В. Ф. Орловой. М.: РФЦСЭ. 1997.

54. Судебно-почерковедческая экспертиза: особенная часть: исследование малообъемных почерковых объектов / М-во юстиции Российской Федерации, Гос. учреждение Российский федеральный центр судебной экспертизы при М-ве юстиции Российской Федерации / под науч. ред. В. Ф. Орловой. – Изд. 2-е, перераб. и доп. – М.: Гос. учреждение Российский федеральный центр судебной экспертизы при М-ве юстиции РФ, 2011. – 538 с.

55. Теория информационно-компьютерного обеспечения криминалистической деятельности: монография / Е.Р. Россинская, А.И. Семикаленова, И.А. Рядовский; ред. Е.Р. Россинская; Моск. гос. юрид. ун-т им. О.Е. Кутафина (МГЮА). М.: Проспект, 2022. – 254 с.

56. Теория и практика криминалистической экспертизы: Сборник / Отв. ред. А. Р. Шляхов; М-во юстиции СССР. Отд. криминалист. учреждений. Центр. криминалист. лаборатория Всесоюз. ин-та юрид. наук. М.: Госюриздат, 1962 – 446 с.

57. Типовые экспертные методики исследования вещественных доказательств. Ч. I / Под ред. канд. техн. наук Ю.М. Дильдина. Общая редакция канд. техн. наук В. В. Мартынова. М.: ЭКЦ МВД России, 2010. – 568 с.

58. Шахматы: энциклопедический словарь / гл. ред. А.Е. Карпов. М.: Советская энциклопедия, 1990. – 621 с.

59. Шульговский В.В. Основы нейрофизиологии // М.: Аспект пресс. 2000. – 277 с.

60. Хрусталев В.Н. Теория судебной экспертизы: учебное пособие / В. Н. Хрусталев. М.: КноРус, 2020. – 241 с.

61. Цифровая криминалистика: учебник для вузов / под редакцией В. Б. Вехова, С. В. Зуева. 2-е изд., перераб. и доп. М.: Издательство Юрайт, 2025. – 490 с.

62. Энциклопедия судебной экспертизы / Под ред. Т.В. Аверьяновой, Е.Р. Россинской. М.: Юристъ, 1999. – 551 с.

#### **4. Авторефераты и диссертации**

63. Бахтеев Д.В. Концептуальные основы теории криминалистического мышления и использования систем искусственного интеллекта в расследовании преступлений: диссертация ... доктора юридических наук: 5.1.4. / Бахтеев Дмитрий Валерьевич – Екатеринбург, 2022. – 504 с.

64. Вехов В.Б. Криминалистическое учение о компьютерной информации и средствах ее обработки: диссертация ... доктора юридических наук: 12.00.09 / Вехов Виталий Борисович – Волгоград, 2008. – 561 с.

65. Иванов А.И. Нейросетевые технологии биометрической аутентификации пользователей открытых систем: диссертация ... доктора технических наук: 05.13.01. – Пенза, 2002. – 393 с.

66. Купин А.Ф. Криминалистическое исследование рукописей, выполненных с подражанием почерку другого лица: диссертация ... кандидата юридических наук: 12.00.09 / Купин Алексей Фёдорович – М., 2012. – 234 с.

67. Никонец Д.А. Методы и средства повышения эффективности работы экспертов-почерковедов в криминалистике: диссертация ... кандидата технических наук: 05.13.01 / Никонец Денис Артурович – Москва, 2012. – 200 с.

68. Охлупина А.Н. Теоретические, методические и организационно-тактические основы применения интеллектуальных систем в судебно-почерковедческом исследовании подписей: диссертация ... кандидата юридических наук: 12.00.12 / Охлупина Анастасия Николаевна – Москва, 2019. – 192 с.

69. Чеснокова Е.В. Концептуальные основы стандартизации в судебно-экспертной деятельности: диссертация ... доктора юридических наук: 12.00.12 / Чеснокова Елена Владимировна – Москва, 2022. – 573 с.

70. Шаталов А.А. Модели и методы выявления закономерностей в информационном потоке на примере рукописного текста с целью установления его авторства: диссертация ... кандидата технических наук: 05.25.05 / Шаталов Андрей Александрович – Старый Оскол, 2015. – 170 с.

## **5. Статьи**

71. Андреева О.И., Иванов В.В., Нестеров А.Ю., Трубникова Т.В. Технологии распознавания лиц в уголовном судопроизводстве: проблема оснований правового регулирования использования искусственного интеллекта // Вестник Томского государственного университета. 2019. № 449. С. 201–212.

72. Ароцкер Л.Е., Компаниец А.М., Сироджа И.Б. Об использовании электронно-вычислительных машин для графической идентификации // Проблемы правовой кибернетики. М., 1968.

73. Ахунджанов У.Ю., Старовойтов В.В. Off-line верификация рукописной подписи с применением сверточной нейронной сети // Системный анализ и прикладная информатика. – 2022. – № 1. – С. 12–18.

74. Бахтеев Д.В. Искусственный интеллект в криминалистике: состояние и перспективы использования / Д. В. Бахтеев // Российское право: образование, практика, наука. – 2018. – № 2(104). – С. 43–49.

75. Бахтеев, Д. В. Особенности распознавания подлога подписи человеком как первичные критерии для разработки системы искусственного интеллекта / Д. В. Бахтеев // Сибирское юридическое обозрение. – 2020. – Т. 17, № 4. – С. 514–522.

76. Бахтеев Д.В. Предэкспертная верификация подложных подписей: человеческий и машинный подходы // Российское право: образование, практика, наука. 2023. № 4. С. 4–10.

77. Бахтеев Д.В., Судариков Р. NSP Dataset и оффлайн-верификация подписи // Качество информационных и коммуникационных технологий: 13-я Международная конференция, QUATIC 2020, Фару, Португалия, 9–11 сентября 2020 г.: Труды. – Springer International Publishing, 2020. – С. 41–49.

78. Баянов Б.И. Методы обработки биометрических данных рукописного почерка // Инженерный вестник Дона. – 2022. – № 12(96). – С. 314–324.

79. Бобовкин М.В., Диденко О.А., Нестеров А.Е. Компьютерное моделирование раздельного и сравнительного исследования частных признаков почерка на основе программного комплекса «Фрося» // Судебная экспертиза – 2021–№3 (67). – С. 62–71.

80. Бобовкин С.М., Климова Я.А., Полунин В.П. Использование возможностей цифровой криминалистики (на примере судебно-почерковедческой экспертизы) // Вестник Волгоградской Академии МВД России. 2022. № 3 (62). С. 109–117.

81. Бобовкин С.М. Особенности формирования компетентности судебного эксперта при производстве почерковедческих экспертиз изображений рукописей // Криминологический журнал. 2024. № 1. С. 19–23.

82. Бобовкин С.М., Четверкин П.А. Методические основы судебно-почерковедческой идентификационной экспертизы китайских

иероглифических рукописей: возможности реализации комплексного подхода. Вестник Московского университета МВД России. 2020(6):197–203.

83. Вапник В.Н., Лернер А.Я., Червоненкис А.Я. Системы обучения распознаванию образов при помощи обобщенных портретов. Известия АН СССР, Техническая кибернетика, № 1, 1965.

84. Вехов В.Б., Пастухов П.С. Искусственный интеллект в решении криминалистических задач // Государственное и муниципальное управление в России: состояние, проблемы и перспективы: Материалы Всероссийской научно-практической конференции, Пермь, 12 ноября 2020 года. – Пермь: Российская академия народного хозяйства и государственной службы при Президенте Российской Федерации, 2020. – С. 8–16.

85. Вехов В.Б. «Электронная криминалистика»: понятие и система // Криминалистика: актуальные вопросы теории и практики: Сборник трудов участников Международной научно-практической конференции, Ростов-на-Дону, 25 мая 2017 года. – Ростов-на-Дону: Ростовский юридический институт Министерства внутренних дел Российской Федерации, 2017. – С. 40–46.

86. Еременко Ю.И., Шаталов А.А. Иммунный алгоритм мультиклональной селекции в решении задачи идентификации почерка // Научные ведомости Белгородского государственного университета. Серия: Экономика. Информатика. – 2013. – № 22(165). – С. 218–224.

87. Ермоленко А.В. Аспекты идентификации автора почерка с помощью нечёткой логики и нейросетей // Актуальные вопросы судебной психологической экспертизы комплексной экспертизы с участием психолога. Перспективы научного и прикладного исследования почерка: Сборник материалов III международной научно-практической конференции, Калуга, 16–19 мая 2019 года / Под редакцией В.Ф. Енгальчева, Е.В. Леоновой. – Калуга: ФБГОУ ВПО «Калужский государственный университет им. К.Э.Циолковского», 2019. – С. 48–55.



88. Журавель А.А., Трошко Н.В., Эджубов Л.Г. Использование алгоритма обобщенного портрета для опознавания образов в судебном почерковедении // Правовая кибернетика. – М.: Наука. – 1970. – С. 212–227.

89. Здоровцова Е.А. Использование сиамских нейронных сетей в задаче определения схожести изображений // Современные информационные технологии. – 2023. – № 5.

90. Иванов А.И., Газин А.И., Качайкин Е.И., Андреев Д.Ю. Автоматизация почерковедческой экспертизы, построенная на обучении больших искусственных нейронных сетей // Модели, системы, сети в экономике, технике, природе и обществе. – 2016. – № 1(17). – С. 249–257.

91. Камалова Г.Г. Цифровые технологии в судебной экспертизе: проблемы правового регулирования и организации применения // Вестник Удмуртского университета. Серия Экономика и право. – 2019. – Т. 29, № 2. – С. 180–186.

92. Качайкин Е.И., Куликов С.В. Получение биометрических параметров высокого качества из статического изображения рукописной подписи // Инфокоммуникационные технологии. – 2015. – Т. 13, № 4. – С. 446–450.

93. Ковалев С.А., Решняк О.А., Вехов В.Б. Генезис компьютерного моделирования в криминалистике // Расследование преступлений: проблемы и пути их решения. – 2017. – № 4(18). – С. 156–160.

94. Козинец Б.Н., Ланцман Р.М., Якубович В.А. Об одном кибернетическом методе исследования в криминалистической экспертизе почерка // Кибернетика и судебная экспертиза. – Вильнюс: НИИСЭ. – 1966. – №. 2. – С.55–84.

95. Кокин А.В. Судебная экспертиза в эпоху четвертой индустриальной революции (Индустрии 4.0) // Теория и практика судебной экспертизы. 2021. Т. 16. № 2. С. 29–36.

96. Кокин А.В., Денисов Ю. Д. Искусственный интеллект в криминалистике и судебной экспертизе: вопросы правосубъектности и

алгоритмической предвзятости // Теория и практика судебной экспертизы. 2023. Т. 18. № 2. С. 30–37.

97. Коляда А.А. О проблеме автоматизации почерковедческих исследований // Вопросы криминологии, криминалистики и судебной экспертизы. – 2019. – № 2(46). – С. 160–167.

98. Кошманов М.П., Кошманов П.М. Этапы и основные направления внедрения компьютерных технологий в судебное почерковедение и почерковедческую экспертизу // Эксперт-криминалист – 2008 – №3. – С. 35–40.

99. Кулик С.Д., Никонец Д.А. Автоматизация классификационно-диагностических почерковедческих исследований с помощью нейронных сетей // Информационные технологии. – 2012. – № 1. – С. 70–75.

100. Кулик С.Д., Никонец Д.А. Использование существующих почерковедческих методик для идентификационного поиска исполнителя рукописи // Нейрокомпьютеры: разработка, применение. – 2016. – № 9. – С. 64–70.

101. Купин А.Ф., Коваленко А.С. К вопросу о возможностях применения систем искусственного интеллекта при криминалистическом исследовании документов и их реквизитов // Теория и практика судебной экспертизы. 2023. Т. 18. № 4. С. 28–35.

102. Купин А.Ф. Применение пакета прикладных программ MATLAB при производстве судебных почерковедческих экспертиз // Цифровые технологии современной криминалистики, использование специальных знаний: Материалы конференции, проведенной в рамках XXVII Международной выставки средств обеспечения безопасности государства «Интерполитех-2023», Москва, 18 октября 2023 года. – М.: Московская академия Следственного комитета Российской Федерации, 2024. – С. 179–185.

103. Ланцман Р.М. Кибернетизация почерковедческой экспертизы // Правоведение. Л.: Изд-во Ленингр. ун-та, 1966, № 4. – С. 128–132.

104. Ланцмана Р.М. Проблема наглядности в процессе использования ЭВМ в почерковедческой экспертизе // Проблемы правовой кибернетики. М., 1968. – С. 117–118.

105. Мищук В.А. Соотношение понятий «искусственный интеллект» и «искусственная нейронная сеть» в судебной экспертологии // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 33–46.

106. Мищук В.А. Использование искусственных нейронных сетей для решения задач судебно-почерковедческой экспертизы: анализ зарубежного опыта // Теория и практика судебной экспертизы. 2025. Т. 20. № 1. С. 44–65.

107. Мищук В.А. Использование модуля сверточного внимания для интерпретации результатов работы сиамской нейронной сети при идентификации рукописных подписей // Теория и практика судебной экспертизы. 2025. Т. 20. № 2. С. 65–81.

108. Мищук В.А. Использование искусственных нейронных сетей для выявления диагностических признаков почерка, свидетельствующих о возможной фальсификации подписи // Материалы X Международной научно-практической конференции, посвященной двадцатилетию Института судебных экспертиз Московского государственного юридического университета имени О. Е. Кутафина (МГЮА), г. Москва, 30–31 января 2025 года. – Москва: Издательский центр Университета имени О.Е. Кутафина (МГЮА), 2025. – С. 205–209.

109. Охлупина, А. Н. Теоретические и организационно-тактические основы использования интеллектуальных систем в судебном почерковедении // Право и политика. – 2019. – № 6. – С. 50–55.

110. Охлупина А.Н. К вопросу о современных возможностях исследования объектов судебно-почерковедческой экспертизы. Вестник Московского университета МВД России. 2020(6):212-4.

111. Полякова А.В., Мартынова Я.А. Генезис разработки и внедрения компьютерных технологий в судебно-почерковедческой экспертизе // Законность и правопорядок. – 2022. – № 3(35). – С. 50–54.

112. Пьянков О.В. Звягин Д.С. Моделирование процесса производства судебной почерковедческой экспертизы при помощи сетей Петри // Вестник Воронежского института МВД России. – 2020. – № 1. – С. 57–64.

113. Россинская Е.Р. Теория информационно-компьютерного обеспечения судебно-экспертной деятельности как новая частная теория судебной экспертологии // Вестник Университета имени О.Е. Кутафина. – 2022. – №. 2 (90). – С. 27–40.

114. Россинская Е.Р. Нейросети в судебной экспертологии и экспертной практике: проблемы и перспективы // Вестник Университета имени О.Е. Кутафина (МГЮА). 2024. № 3(115). С. 21–33.

115. Россинская Е.Р. Система теории цифровизации судебно-экспертной деятельности // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 20–32.

116. Смирнов А.В. Программа «ОКО-1» для исследования кратких и простых почерковых объектов // Теория и практика судебной экспертизы. 2006. № 1 (1). С. 121–124.

117. Собко Г.М. Некоторые возможности математической формализации идентификационного судебно-почерковедческого исследования // Применение математических методов и вычислительной техники в праве, криминалистике и судебной экспертизе: материалы симпозиума. – 1970. – С. 109–112.

118. Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник ЮУрГУ. Серия: Вычислительная математика и информатика. 2017. Т. 6, № 3. С. 28–59.

119. Усов А.И., Омелянюк Г.Г., Лапина И.А., Карпухина Е.С., Кузнецов В.О. Роль цифровой трансформации в развитии судебной экспертологии // Теория и практика судебной экспертизы. 2024. Т. 19. № 3. С. 47–57.

120. Усов А. И., Омелянюк Г.Г., Бебешко Г.И., Любецкая И.П., Афанасьев И.Б. Методологические особенности валидации судебно-экспертных методик // Теория и практика судебной экспертизы. 2023. Т. 18. № 1. С. 76–96.

121. Устинов В.В. О возможности объективизации почерковедческого исследования рукописных реквизитов // Вопросы экспертной практики. – 2019. – № S1. – С. 663–668

122. Фазылов Ш.Х., Мирзаев Н.М., Раджабов С.С., Дадаханов М.Х., Асраев М.А. Методы и алгоритмы идентификации личности на основе анализа изображений рукописного текста // Проблемы вычислительной и прикладной математики. – 2020. – №5(29). – С. 5–26.

123. Хазиев Ш.Н. Криминалистические и судебно-экспертные основы современных биометрических технологий // Теория и практика судебной экспертизы. 2023. Т. 18. № 1. С. 16–21.

124. Хазиев Ш.Н., Штохов А.Н. Судебные экспертизы по делам об ошибочной биометрической идентификации. 2024. Т. 19. № 3. С. 88–102.

125. Хмыз А.И. Использование возможностей искусственного интеллекта в судебной экспертизе // Вестник экономической безопасности. 2022. № 5. С. 224–227.

126. Хмыз А.И. Экспертная ситуация и искусственный интеллект // Вестник Московского университета МВД России. 2022. № 3. С. 286–290.

127. Чеснокова Е.В., Усов А.И., Омелянюк Г.Г., Никулина М.В. Искусственный интеллект в судебной экспертологии. // Теория и практика судебной экспертизы. 2023. Т. 18. № 3. С. 60–77.

128. Шевская Н.В. Объяснимый искусственный интеллект и методы интерпретации результатов // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, № 2(33).

129. Эджубов Л.Г. Кибернетика и некоторые вопросы судебного почерковедения. – В сб. «Вопросы кибернетики и право». Изд-во «Наука», 1967.

## **6. Иностранные издания**

130. Alzubaidi L. et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions // Journal of big Data. – 2021. – T. 8. – C. 1–74.
131. Aliakbarzadeh M., Razzazi F. Online Persian/Arabic writer identification using gated recurrent unit neural networks // Majlesi Journal of Electrical Engineering. – 2020. – T. 14. – №. 3. – C. 73–79.
132. Ammar M., Yoshida Y., Fukumura T. A new effective approach for off-line verification of signatures by using pressure features // Proceedings of the 8th International Conference on Pattern Recognition. – 1986. – C. 566–569.
133. Bahdanau D., Cho K., Bengio Y. Neural machine translation by jointly learning to align and translate // arXiv preprint arXiv:1409.0473. – 2014. Bengio Y., Simard P., Frasconi P. Learning long-term dependencies with gradient descent is difficult // IEEE transactions on neural networks. – 1994. – T. 5. – №. 2. – C. 157–166.
134. Baker B. et al. Monitoring reasoning models for misbehavior and the risks of promoting obfuscation // arXiv preprint arXiv:2503.11926. – 2025.
135. Bokhan D., Mastiukova A.S., Boev A.S., Trubnikov D.N., Fedorov A.K. Multiclass classification using quantum convolutional neural networks with hybrid quantum-classical learning // Frontiers in Physics. – 2022. – T. 10. – C. 1069985.
136. Braitenberg V. Vehicles: Experiments in Synthetic Psychology. The MIT Press, 1986. – 168 c.
137. Bromley J. et al. Signature verification using a «Siamese» time delay neural network // Advances in neural information processing systems. – 1993. – T. 6.
138. Bulacu M., Schomaker L. GRAWIS: Groningen Automatic Writer Identification System // BNAIC. – 2005. – C. 413–414.
139. Cai H. et al. Brain Organoid Reservoir Computing for Artificial Intelligence // Nature Electronics. 2023. Vol. 6. No. 12. C. 1032–1039.
140. Caligiuri M. P., Mohammed L. A. The neuroscience of handwriting: Applications for forensic document examination. – CRC Press, 2012.

141. Castro D. Rethinking Concerns About AI's Energy Use // Center for Data Innovation. – 2024.
142. Cardot H. et al. Des reseaux neuronaux pour l'authentification de signatures manuscrites // Proc. CNED'92: Colloque National sur VEcrit et le Document, Nancy. – 1992. – C. 250–255.
143. Cardot H. et al. L'authentification des signatures manuscrites: une approche globale par réseaux de neurones // 6th Int. Conf. on Handwriting and Drawing. – 1993. – C. 225–227.
144. Chahi A. et al. WriterINet: a multi-path deep CNN for offline text-independent writer identification // International Journal on Document Analysis and Recognition (IJDAR). – 2023. – T. 26. – №. 2. – C. 89–107.
145. Chahi A. Automatic off-line text-independent writer identification from handwriting: дис. – Université Bourgogne Franche-Comté; Université Ibn Tofail. Faculté des sciences de Kénitra, 2021.
146. Chang H. D., Wang J. F., Suen H. M. Dynamic handwritten Chinese signature verification // Proceedings of 2nd International Conference on Document Analysis and Recognition (ICDAR'93). – IEEE, 1993. – C. 258–261.
147. Chen Z. et al. Letter-level online writer identification // International Journal of Computer Vision. – 2021. – T. 129. – №. 5. – C. 1394–1409.
148. Chollet F. Deep learning with Python. – Simon and Schuster, 2021. – 478 c.
149. Das A. et al. Human attention in visual question answering: Do humans and deep networks look at the same regions? // Computer Vision and Image Understanding. – 2017. – T. 163. – C. 90–100.
150. Dey S. et al. Signet: Convolutional siamese network for writer independent offline signature verification // arXiv preprint arXiv:1707.02131. – 2017.
151. Deviterne-Lapeyre M., Ibrahim S. Interpol questioned documents review 2019–2022 // Forensic Science International: Synergy. – 2023. – T. 6. – C. 100300.

152. Dhieb T. et al. Towards a novel biometric system for forensic document examination // *Computers & Security*. – 2020. – T. 97. – C. 101973.
153. Droby A. et al. Digital Hebrew Paleography: Script Types and Modes // *Journal of Imaging*. – 2022. – T. 8. – №. 5. – C. 143.
154. Dullink H. Automated signature identification and verification: дис. – Faculty of Science and Engineering, 1996.
155. Ertel W. Introduction to Artificial Intelligence. London: Springer, 2018. – 356 с.
156. Fenner M. Machine learning with Python for everyone. – Addison-Wesley Professional, 2019. – 592 с.
157. Franke K., Köppen M. A computer-based system to support forensic studies on handwritten documents // *International Journal on Document Analysis and Recognition*. – 2001. – T. 3. – C. 218–231.
158. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position // *Biological cybernetics*. – 1980. – T. 36. – №. 4. – C. 193–202.
159. Garrett B. L., Rudin C. Interpretable algorithmic forensics // *Proceedings of the National Academy of Sciences*. – 2023. – T. 120. – №. 41. – C. e2301842120.
160. Gentric P., Minot J. Authentification dynamique de signatures par reseaux de neurones // *Revue annuelle-LEP*. – 1990. – C. 34–36.
161. Goldstein A. et al. A unified acoustic-to-speech-to-language embedding space captures the neural basis of natural language processing in everyday conversations // *Nature Human Behaviour*. – 2025. – C. 1–15.
162. Goodfellow I. et al. Generative adversarial nets // *Advances in neural information processing systems*. – 2014. – T. 27.
163. Hameed M. M. et al. Machine learning-based offline signature verification systems: A systematic review // *Signal Processing: Image Communication*. – 2021. – T. 93. – C. 116139.
164. Harralson H.H., Miller L.S. Huber and Headrick's Handwriting Identification: Facts and Fundamentals. – Crc Press, 2017. – 442 с.



165. Haykin S. Neural networks: a comprehensive foundation. – Prentice Hall PTR, 1994.
166. Haykin S. Neural networks and learning machines, 3/E. – Pearson Education India, 2009.
167. Hebb D. O. The organization of behavior: A neuropsychological theory. – Psychology press, 2005. – 279 c.
168. He K. et al. Deep residual learning for image recognition // Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – C. 770–778.
169. He S., Schomaker L. GR-RNN: Global-context residual recurrent neural networks for writer identification // Pattern Recognition. – 2021. – T. 117. – C. 107975.
170. Herbst N.M., Liu C.N. Automatic signature verification based on accelerometry // IBM Journal of Research and Development. – 1977. – T. 21. – №. 3. – C. 245–253.
171. Hicklin R. A. et al. Accuracy and reliability of forensic handwriting comparisons // Proceedings of the National Academy of Sciences. – 2022. – T. 119. – №. 32. – C. e2119944119.
172. Higashino J. Signature verification system on neuro-computer // Proceedings., 11th IAPR International Conference on Pattern Recognition. Vol. III. Conference C: Image, Speech and Signal Analysis. – IEEE, 1992. – C. 517–521.
173. Hochreiter S., Schmidhuber J. Long short-term memory // Neural computation. – 1997. – T. 9. – №. 8. – C. 1735–1780.
174. Hopfield J.J. Neural networks and physical systems with emergent collective computational abilities // Proceedings of the national academy of sciences. – 1982. – T. 79. – №. 8. – C. 2554–2558.
175. Huber R.A., Headrick A.M. Handwriting identification: facts and fundamentals. – CRC press, 1999. – 456 c.
176. Haugeland J. Artificial Intelligence: The Very Idea. MIT Press, Cambridge, MA – 1985. – 287 c.

177. J. McCarthy, M.L. Minsky, N. Rochester, C.E. Shannon A proposal for the Dartmouth summer research project on artificial intelligence. USA: Dartmouth. 1955. – 13 c.
178. Karpathy A. What I learned from competing against a ConvNet on ImageNet // Andrej Karpathy Blog. – 2014. – T. 5. – C. 1–15.
179. Kao H. H., Wen C. Y. An offline signature verification and forgery detection method based on a single known sample and an explainable deep learning approach // Applied Sciences. – 2020. – T. 10. – №. 11. – C. 3716.
180. Kedar S. V., Rokade S. Recognition of emotional state based on handwriting analysis and psychological assessment //Int. J. Eng. Adv. Technol. – 2019. – T. 8. – №. 6. – C. 4395–4402.
181. Kim J., Park S., Carriquiry A. A deep learning approach for the comparison of handwritten documents using latent feature vectors // Statistical Analysis and Data Mining: The ASA Data Science Journal. – 2024. – T. 17. – №. 1. – C. e11660.
182. Khosroshahi S.N.M. et al. Deep neural networks-based offline writer identification using heterogeneous handwriting data: an evaluation via a novel standard dataset // Journal of Ambient Intelligence and Humanized Computing. – 2022. – C. 1–20.
183. Krizhevsky A., Sutskever I., Hinton G. E. Imagenet classification with deep convolutional neural networks // Advances in neural information processing systems. – 2012. – T. 25.
184. Kumar P., Sharma A. Segmentation-free writer identification based on convolutional neural network // Computers & Electrical Engineering. – 2020. – T. 85. – C. 106707.
185. Kumar V., Sundaram S. Siamese based Neural Network for Offline Writer Identification on word level data // arXiv preprint arXiv:2211.14443. – 2022.
186. Kumar V., Sundaram S. Attention based End to end network for Offline Writer Identification on Word level data // arXiv preprint arXiv:2404.07602. – 2024.

187. LeCun Y. et al. Backpropagation applied to handwritten zip code recognition // *Neural computation*. – 1989. – T. 1. – №. 4. – C. 541–551.
188. Le Cun Y. Quand la machine apprend: la révolution des neurones artificiels et de l'apprentissage profond. – Odile Jacob, 2019. – 321 c.
189. Leclerc F., Plamondon R. Automatic signature verification: The state of the art—1989–1993 // *International journal of pattern recognition and artificial intelligence*. – 1994. – T. 8. – №. 03. – C. 643–660.
190. Leedham S. S. G., Srihari S. A survey of computer methods in forensic handwritten document examination // *Proceeding the Eleventh International Graphonomics Society Conference, Scottsdale Arizona*. – 2003. – C. 278-281.
191. Li B., Li N. Handwriting expertise reliability: a review // *Journal of Forensic Science and Medicine*. – 2019. – T. 5. – №. 4. – C. 181–186.
192. Marcus G. Deep learning: A critical appraisal // *arXiv preprint arXiv:1801.00631*. – 2018.
193. Marcinowski M. Top interpretable neural network for handwriting identification // *Journal of Forensic Sciences*. – 2022. – T. 67. – №. 3. – C. 1140–1148.
194. Maslej N. et al. Artificial Intelligence Index Report 2024 // *arXiv preprint arXiv:2405.19522*. – 2024.
195. Masís S. *Interpretable Machine Learning with Python: Learn to build interpretable high-performance models with hands-on real-world examples*. – Packt Publishing Ltd, 2021.
196. McCorduck P., Cfe C. *Machines who think: A personal inquiry into the history and prospects of artificial intelligence*. – AK Peters/CRC Press, 2004.
197. McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // *The bulletin of mathematical biophysics*. – 1943. – T. 5. – C. 115–133.
198. Mitchell T.M. *Machine learning*. – New York: McGraw-hill, 1997. – T. 1. – №. 9. – 414 c.

199. Minsky M. A neural-analogue calculator based upon a probability model of reinforcement // Harvard University Psychological Laboratories, Cambridge, Massachusetts. – 1952. – C. 7.
200. Minsky M., Papert S. A. Perceptrons, reissue of the 1988 expanded edition with a new foreword by Léon Bottou: an introduction to computational geometry. – MIT press, 2017. – 316 c.
201. Minot J., Gentric P. Authentification dynamique de signatures par reseaux de neurones // TS. Traitement du signal. – 1991. – T. 8. – №. 6. – C. 423–430.
202. Moor J. The Dartmouth College artificial intelligence conference: The next fifty years // AI magazine. – 2006. – T. 27. – №. 4. – C. 87–91.
203. Molnar C. Interpretable machine learning. – Lulu. com, 2020.
204. Morris R. N. Forensic handwriting identification: fundamental concepts and principles. – 2020.
205. Mohammed L. A. Forensic examination of signatures. – Academic Press, 2019.
206. Nagel R. N., Rosenfeld A. Computer detection of freehand forgeries // IEEE Transactions on Computers. – 1977. – T. 100. – №. 9. – C. 895–905.
207. National Research Council et al. Strengthening forensic science in the United States: a path forward. – National Academies Press – 2009.
208. Nguyen H. T. et al. Text-independent writer identification using convolutional neural network // Pattern Recognition Letters. – 2019. – T. 121. – C. 104–112.
209. Parodi M. Automatic Handwritten Signature Verification: doctoral dissertation. – Universidad Nacional de Rosario, 2015.
210. Plamondon R., Lorette G. Automatic signature verification and writer identification – the state of the art // Pattern recognition. – 1989. – T. 22. – №. 2. – C. 107–131.

211. Rahman A. U., Halim Z. A graph-based solution for writer identification from handwritten text // Knowledge and Information Systems. – 2022. – T. 64. – №. 6. – C. 1501–1523.
212. Rich E. Artificial Intelligence. New York: McGraw-Hill. 1991. – 621 c.
213. Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain // Psychological review. – 1958. – T. 65. – №. 6. – C. 386–408.
214. Rothman D. Transformers for Natural Language Processing and Computer Vision: Explore Generative AI and Large Language Models with Hugging Face, ChatGPT, GPT-4V, and DALL-E 3. – Packt Publishing Ltd, 2024.
215. Rumelhart D.E., Hinton G.E., Williams R.J. Learning representations by back-propagating errors // Nature. – 1986. – T. 323. – №. 6088. – C. 533–536.
216. Ruiz V. et al. Off-line handwritten signature verification using compositional synthetic generation of signatures and Siamese Neural Networks // Neurocomputing. – 2020. – T. 374. – C. 30–41.
217. Sabourin R., Plamondon R. Preprocessing of handwritten signatures from image gradient analysis. In Proc. 8th Int. Conf. Pattern Recognition, 1986. – C. 576–579.
218. Sabourin R., Drouhard J.P. Off-line Signature Verification Using Directional PDF and Neural Networks // Proceedings of the 11th ICPR, The Hague. – 1992. – T. 321. – C. 321–325.
219. Schmidhuber J. Deep learning in neural networks: An overview // Neural network. – 2015. – T. 61. – C. 85–117.
220. Searle J. R. Minds, brains, and programs // Behavioral and brain sciences. – 1980. – T. 3. – №. 3. – C. 417–424.
221. See N. G., Seng O. H. A neural network approach for off-line signature verification // Proceedings of TENCON'93. IEEE Region 10 International Conference on Computers, Communications and Automation. – IEEE, 1993. – T. 2. – C. 770–773.

222. Selvaraju R.R. et al. Grad-cam: Visual explanations from deep networks via gradient-based localization // Proceedings of the IEEE international conference on computer vision. – 2017. – C. 618–626.

223. Shaikh M. A. et al. Attention based writer independent verification // 2020 17th International Conference on Frontiers in Handwriting Recognition (ICFHR). – IEEE, 2020. – C. 373–379.

224. Sharma P., Singh M., Jasuja O. P. Forensic examination of electronic signatures: A comparative study // Nowa Kodyfikacja Prawa Karnego. – 2021. – T. 59. – C. 149–184.

225. Suteddy W. et al. End-to-end evaluation of deep learning architectures for off-line handwriting writer identification: a comparative study // JOIV: International Journal on Informatics Visualization. – 2023. – T. 7. – №. 1. – C. 178–185.

226. Simonyan K. Deep inside convolutional networks: Visualising image classification models and saliency maps // arXiv preprint arXiv:1312.6034. – 2013.

227. Team C. Chameleon: Mixed-modal early-fusion foundation models // arXiv preprint arXiv:2405.09818. – 2024.

228. The Expert Working Group for Human Factors in Handwriting Examination, Forensic Handwriting Examination and Human Factors: Improving the Practice Through a Systems Approach, U.S. Department of Commerce, National Institute of Standards and Technology – 2021.

229. Tolosana R. et al. Biometric signature verification using recurrent neural networks // 2017 14th IAPR international conference on document analysis and recognition (ICDAR). – IEEE, 2017. – T. 1. – C. 652–657.

230. Turing A.M. Computing machinery and intelligence. – Springer Netherlands, 2009. – C. 23–65.

231. Xu K. et al. Show, attend and tell: Neural image caption generation with visual attention // International conference on machine learning. – PMLR, 2015. – C. 2048–2057.

232. Xue G. et al. ATP-DenseNet: a hybrid deep learning-based gender identification of handwriting // Neural Computing and Applications. – 2021. – T. 33. – C. 4611–4622.
233. Vaswani A. et al. Attention is all you need // Advances in neural information processing systems. – 2017. – T. 30.
234. Van Erp M. et al. The WANDA measurement tool for forensic document examination // Journal of Forensic Document Examination. – 2018. – T. 28. – C. 5–14.
235. Van Melle W. MYCIN: a knowledge-based consultation program for infectious disease diagnosis // International journal of man-machine studies. – 1978. – T. 10. – №. 3. – C. 313–322.
236. Wang S., Jia S. Signature handwriting identification based on generative adversarial networks // Journal of Physics: Conference Series. – IOP Publishing, 2019. – T. 1187. – №. 4. – C. 042047.
237. Wei P., Li H., Hu P. Inverse discriminative networks for handwritten signature verification // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. – 2019. – C. 5764–5772.
238. Widrow B., Lehr M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation // Proceedings of the IEEE. – 2002. – T. 78. – №. 9. – C. 1415–1442.
239. Wilkinson T., Mighell D., Goodman J. Backpropagation and its application to handwritten signature verification // Advances in Neural Information Processing Systems. – 1988. – T. 1.
240. Woo S. et al. CBAM: Convolutional block attention module // Proceedings of the European conference on computer vision (ECCV). – 2018. – C. 3–19.
241. Yang W., Jin L., Liu M. Deepwriterid: An end-to-end online text-independent writer identification system // IEEE Intelligent Systems. – 2016. – T. 31. – №. 2. – C. 45–53.

242. Yu M. et al. The super weight in large language models // arXiv preprint arXiv:2411.07191. – 2024.

243. Yildirim S., Asgari-Chenaghlu M. Mastering Transformers: Build state-of-the-art models from scratch with advanced natural language processing techniques. – Packt Publishing Ltd, 2021.

244. Zeiler M. D., Fergus R. Visualizing and understanding convolutional networks // Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part I 13. – Springer International Publishing, 2014. – С. 818-833.

245. Zhang H. et al. Self-attention generative adversarial networks // International conference on machine learning. – PMLR, 2019. – С. 7354–7363.

246. Zhang X. Y. et al. End-to-end online writer identification with recurrent neural network // IEEE transactions on human-machine systems. – 2016. – Т. 47. – №. 2. – С. 285–292.

247. Zhang Y. et al. A survey on neural network interpretability // IEEE Transactions on Emerging Topics in Computational Intelligence. – 2021. – Т. 5. – №. 5. – С. 726–742.

248. Zhao A., Li J. A significantly enhanced neural network for handwriting assessment in Parkinson's disease detection //Multimedia Tools and Applications. – 2023. – Т. 82. – №. 25. – С. 38297-38317.

## **7. Интернет-ресурсы**

249. АДИС ПАПИЛОН-9. Руководство пользователя / [Электронный ресурс] // ООО «ИТ-Папилон» [сайт]. – URL: <http://ftp.папилон.рф/products/adis-9/adis-9-u.pdf> (дата обращения: 13.04.2025).

250. Аналитическая система АСПИАД / [Электронный ресурс] // Т-информ: [сайт]. – URL: <https://tinform.ru/solutions/aspiad/> (дата обращения: 01.08.2024).

251. В 9-ю версию АДИС (AFIS) Папилон внедрена нейросеть / [Электронный ресурс] // Системы Папилон: [сайт]. – URL:



<https://www.papillon.ru/about/blog/v-9-uju-versiju-adis-afis-papilon-vnedrenaj-roset/> (дата обращения: 23.04.2025).

252. Голем / [Электронный ресурс] // Научно-образовательный портал «Большая российская энциклопедия»: [сайт]. – URL: <https://bigenc.ru/c/golem-93e841> (дата обращения: 03.01.2025).

253. Интерпретация / [Электронный ресурс] // Научно-образовательный портал «Большая российская энциклопедия»: [сайт]. – URL: <https://bigenc.ru/c/interpretatsiia-bd27d1> (дата обращения: 11.03.2025).

254. Охлупина А. Н. Вопросы применения интеллектуальных систем в целях криминалистического исследования подписей // Энциклопедия Судебной Экспертизы: Научно-практический журнал. – 2016. – № 1 (8). [Электронный ресурс]. URL: [https://proexpertizu.ru/theory\\_and\\_practice/pocherk/682/?ysclid=mbvzihnjkf925370900](https://proexpertizu.ru/theory_and_practice/pocherk/682/?ysclid=mbvzihnjkf925370900) (дата обращения: 12.01.2025).

255. Синицин Ф. Решающие деревья / Синицин Ф. [Электронный ресурс] // Яндекс. Образование: [сайт]. – URL: <https://education.yandex.ru/handbook/ml/article/reshayushchiye-derevya> (дата обращения: 04.01.2025).

256. Chopra P. Making Your Neural Network Say «I Don't Know» – Bayesian NNs using Pyro and PyTorch // Medium: [сайт]. URL: <https://towardsdatascience.com/making-your-neural-network-say-i-dont-know-bayesian-nns-using-pyro-and-pytorch-b1c24e6ab8cd> (дата обращения: 03.08.2024).

**ПРИЛОЖЕНИЯ***Приложение №1****Акт о внедрении результатов диссертационного исследования*****УТВЕРЖДАЮ**

Первый заместитель директора  
ФБУ РФЦСЭ имени профессора  
А.Р. Шляхова при Минюсте России

А.И. Усов

« 16 »

2025 года

**АКТ**

о внедрении результатов диссертационного исследования  
Мищук Всеволода Александровича на тему «Теоретические и практические  
аспекты применения нейронных сетей в судебно-почерковедческой  
экспертизе», по специальности 5.1.4 – Уголовно-правовые науки  
в практику работы федерального бюджетного учреждения Российский  
федеральный центр судебной экспертизы имен профессора А.Р. Шляхова  
при Министерстве юстиции Российской Федерации

Настоящий акт составлен комиссией в составе: председателя – Ученого секретаря ФБУ РФЦСЭ имени профессора А.Р. Шляхова при Минюсте России, доктора юридических наук, профессора Омелянюка Георгия Георгиевича, членов комиссии: главного научного сотрудника отдела научно-методического обеспечения и аспирантуры (ОНМО) ФБУ РФЦСЭ имени профессора А.Р. Шляхова при Минюсте России, кандидата юридических наук Михалевой Натальи Валерьевны, ведущего научного сотрудника отдела инноваций судебно-экспертной деятельности (ОИСЭД) ФБУ РФЦСЭ имени профессора А.Р. Шляхова при Минюсте России, кандидата юридических наук Савенко Антона Сергеевича о том, что основные положения, выводы и рекомендации диссертационного исследования Мищук Всеволода Александровича внедрены в деятельность ОИСЭД ФБУ РФЦСЭ имени профессора А.Р. Шляхова при Минюсте России.

Комиссия рассмотрела результаты практического использования диссертационного исследования Мищук В.А. и установила следующее: сформулированные и обоснованные в диссертационном исследовании положения развивают основы применения нейронных сетей в судебной почерковедческой экспертизе, а также представляют собой комплекс организационных и технологических решений по использованию нейронных сетей в качестве инновационного инструмента по вопросу об установлении лица, выполнившего подпись или рукописную запись.



Выводы диссертационного исследования могут быть использованы в научно-исследовательской работе, при производстве судебной почерковедческой экспертизе после проведения комплекса валидационных испытаний.

Председатель комиссии



Г.Г. Омелянюк

Члены комиссии:

Н.В. Михалева

А.С. Савенко

### Общая классификация постановок задач машинного обучения



**1) Обучение без учителя** – подход, когда алгоритму предлагается самостоятельно выявить какие-либо закономерности в данных на основе каких-либо критериев. Подвиды:

- Оценка плотности – задача, когда нужно оценить плотность распределения элементов в массиве данных;

- Снижение размерности – задача, в которой необходимо входные данные большой размерности (например, большой текст) представить в виде данных меньшей размерности, которого будет достаточно для полного отражения исходных данных;

- Кластеризация – задача, в которой алгоритму необходимо разбить набор данных на N-количество классов по некоторой мере схожести.

**2) Обучение с частичным привлечением учителя** – подход, когда алгоритму дается небольшое количество размеченных данных и большой массив неразмеченных данных, которые необходимо разметить в процессе обучения.

**3) Обучение с учителем** – подход, в котором алгоритм обучается на основе тренировочного (обучающего) набора данных (сами анализируемые данные и прогнозы, которые алгоритм должен давать на основе анализа этих данных). Подвиды:

- Классификация – задача, в которой алгоритму необходимо «научиться» относить анализируемый объект к конкретному классу;


- Регрессия – задача, где алгоритму на основе входных данных нужно предсказать значение некоей функции, у которой обычно может быть бесконечно много разных значений (например, на основе роста человека спрогнозировать его вес и т. п.);

- Обучение ранжированию – задача, в которой по имеющимся данным необходимо отсортировать имеющиеся объекты некоторого массива в порядке убывания целевой функции. При этом, в отличие от регрессии, значение имеют только результаты сравнения этой функции на разных объектах.


**4) Обучение с подкреплением** – подход, в котором алгоритм, находясь в некоторой «среде» и выполняя какую-то задачу, получает «поощрение» или «наказание» за совершение определенных действий.

**Формальное описание  
единичного нейрона по  
У. МакКалоку и У. Питтсу**

Тормозящий синапс



**Простая нейронная сеть в  
обозначениях У. МакКалока и У.  
Питтса и ее таблица истинности.  
Состояние каждого нейрона  
обозначается  $N_i$**



**Нейронная сеть по У. МакКалоку и У. Питтсу состоит из следующих основных элементов:**

- сам нейрон, который имеет определенный порог возбуждения, характеризующийся необходимым количеством входных сигналов;
- возбуждающий синапс (+1), который пропускает любую информацию;
- тормозящий синапс (–1), который может выполнять относительное либо абсолютное торможение.


**Процесс логической обработки информации в нейронной сети проходит следующим образом:**

- 1) Каждый нейрон может иметь любое количество подключенных к нему синапсов любого вида;
- 2) Когда по возбуждающему синапсу проходит сигнал, он подает на нейрон значение +1 (рисунок справа, связи нейронов 1–out и 2–out);
- 3) Обратная ситуация происходит с тормозящим синапсом – когда через него проходит сигнал, то на нейрон подается значение –1. При этом, в зависимости от особенностей строения сети, тормозной синапс при прохождении через него сигнала может полностью «блокировать» нейрон, к которому он подключен. Это означает, что последний никак не может быть активирован при любом количестве полученных сигналов (рисунок справа, строка 9 таблицы);
- 4) Если возбуждающий синапс имеет «ветвление», т. е. разделяется на два синапса, то каждый из них дает значение +1. Таким образом итоговое значение, которое получит нейрон, будет +2 (рисунок справа, связи нейронов 3–out);
- 5) Так как каждому нейрону нужно определенное количество сигналов для возбуждения, он накапливает в себе все полученные сигналы от синапсов. Если число сходных сигналов в сумме превышает порог возбуждения нейрона, то он активируется (состояние 1) и посылает сигнал по синапсу на следующий нейрон (рисунок справа, строки 4–8 таблицы). В противном случае нейрон не будет активироваться (состояние 0; рисунок справа, строки 1–3 таблицы).

## Устройство перцептрона Розенблатта

### Общая схема

### Устройство элемента R (сумматор)



#### Перцептрон Розенблатта состоит из следующих основных элементов:

- S-элементы – регистрирующий слой, состоящий из фотосенсоров либо иного другого вида регистрирующих устройств, выполняющий функции сетчатки глаза. Элементы могут быть либо в возбужденном состоянии, либо в невозбужденном;
- A-элементы – ассоциативный слой нейронов, к каждому из которых подключено некоторое количество S-элементов. Эти элементы имеют определенный порог возбуждения;
- R-элемент – один или несколько сумматоров, к которым подключены все A-элементы;
- Пороговая функция активации – преобразует выходное значение сумматора в 0 или 1;
- Коэффициенты весов синапсов – числовые значения, показывающие уровень «связи» между соединенными элементами перцептрона. Выделяют веса S–A связей, которые могут иметь только значения  $-1$ ,  $0$  и  $+1$  ( $0$  обозначает отсутствие связи), а также веса A–R связей, которые могут быть любыми.


#### Принцип работы:

- 1) Когда на элемент фотосенсора попадает свет либо иной «раздражитель», элемент возбуждается, что можно определить состоянием 1, т. е. наличие сигнала;
- 2) В случае возбуждения S-элемента он отправляет сигнал нейронам A слоя, с которыми имеет синаптические связи;
- 3) Если синаптическая S–A связь имеет значение  $-1$ , значит сигнал, который получит A-элемент также будет иметь значение  $-1$ . Для S–A связи со значением  $+1$  полученный сигнал также будет иметь значение  $+1$ ;
- 4) Все полученные с S-элементов значения суммируются A-элементом. Если полученный результат больше порога возбуждения, нейрон выдает сигнал  $+1$ , в противном случае  $-0$ ;
- 5) Полученные значения умножаются на соответствующий весовой коэффициент A–R связи, после чего суммируются между собой на R-элементе. Итоговое значение подается на пороговую функцию активации, которые выдает результат  $-1$  или  $1$ , условные «Да» и «Нет».


**Примечание:** Обучение элементарного перцептрона состоит в изменении весовых коэффициентов связей A–R. Веса связей S–A и значения порогов A-элементов выбираются случайным образом в самом начале обучения и затем не изменяются.



**Многослойный перцептрон по Д. Румельхарту. Обучается при помощи метода обратного распространения ошибки.**



**Устройство и схема обучения единичного современного нейрона в полносвязной нейронной сети**




**Примечание:** в настоящее время в качестве функций активации используются нелинейные либо кусочно-линейный функции. Конкретно на данном изображении представлена сигмоидальная функция активации.

Наиболее полный список

## искусственных нейронных сетей


© 2019 (Федор ван Вин) Fjodor van Veen & Стефан Лейнен (Stefan Leijen) asimovinstitute.org  
Переведено на русский - [aisimple.ru](http://aisimple.ru)



**Примечание:** на данном изображении представлены не все передовые архитектуры искусственных нейронных сетей



**Основные математические элементы,  
с которыми работают нейронные сети**



– **Скалярное значение** – величина, которая характеризуется только одним числовым значением, т. е. одним, как правило действительным, числом;


– **Вектор** – величина, которая характеризуется N-количеством числовых значений (скаляров) и направлением. Также вектор можно характеризовать как матрицу с только одним столбцом или одной строкой;

– **Матрица** – массив данных, который записывается в виде прямоугольной таблицы, элементами которой являются скаляры.


– **Тензор** – многомерный массив данных, элементы которого организованным определенным образом (например изображение, которое можно представить в виде 3-мерного тензора: в 1-измерении записывается число цветовых каналов изображение, 2 и 3 измерение в совокупности можно характеризовать как матрицу – одно измерение для ширины и одно для длины изображения).

**Примечание:** при работе с нейросетями в целом любое значение обычно представляют в виде тензора определенной размерности. Например, скалярное значение будет тензором с размерностью 0, вектор – тензор с размерностью 1 и т. д. (см. изображение).

**Общая схема сверточной нейронной сети  
с полносвязным классификатором**




## Общее устройство нейросети Transformer




## Устройство блока внимания

Scaled Dot-Product Attention



*Механизм внимания на основе масштабированного скалярного произведения*

Multi-Head Attention



*«Многопоточное» («многоголовое») внимание, которое состоит из нескольких слоёв внимания, работающих параллельно*

**Некоторые типы механизма внимания**


| Название                                                  | Функция внимания                                                                                                | Источник                     |
|-----------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------|------------------------------|
| Контентное внимание<br>(content-based attention)          | $\text{score}(\mathbf{s}_i, \mathbf{h}_i) = \cos[\mathbf{s}_i, \mathbf{h}_i]$                                   | Грейвс<br>(Graves, 2004)     |
| Аддитивное<br>(additive)                                  | $\text{score}(\mathbf{s}_i, \mathbf{h}_i) = \mathbf{v}_a^\top \tanh(\mathbf{W}_a [\mathbf{s}_i; \mathbf{h}_i])$ | Богданов<br>(Bahdanau, 2015) |
| Позиционное<br>(location-based)                           | $\alpha_{t,i} = \text{softmax}(\mathbf{W}_a \mathbf{s}_t)$                                                      | Луонг<br>(Luong, 2015)       |
| Общее<br>(general)                                        | $\text{score}(\mathbf{s}_i, \mathbf{h}_i) = \mathbf{s}_t^\top \mathbf{W}_a \mathbf{h}_i$                        | Луонг<br>(Luong, 2015)       |
| Скалярное произведение<br>(dot-product)                   | $\text{score}(\mathbf{s}_i, \mathbf{h}_i) = \mathbf{s}_t^\top \mathbf{h}_i$                                     | Луонг<br>(Luong, 2015)       |
| Взвешенное скалярное произведение<br>(scaled dot product) | $\text{score}(\mathbf{s}_i, \mathbf{h}_i) = \frac{\mathbf{s}_t^\top \mathbf{h}_i}{\sqrt{n}}$                    | Васвани<br>(Vaswani, 2017)   |

**Основные подходы исследования почерка  
при помощи компьютерных технологий**

| <b>Основание для классификации</b> | <b>Наименование подхода и его суть</b>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                             |
|------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| По типу исследуемых данных         | Online-исследование почерка – базируется на анализе рукописей, выполненных с помощью электронных устройств (стилус, графический планшет и т. п.). Этот подход иногда называют «динамическим исследованием почерка», так как в его рамках алгоритм преимущественно анализирует динамические признаки почерка, зафиксированные устройством в процессе выполнения рукописи. К ним относятся время выполнения отдельных элементов, сила и дифференциация нажима и т. п. В настоящее время данный подход признается исследовательским сообществом наиболее эффективным. | Offline-исследование почерка – в рамках этого направления алгоритмы анализируют оцифрованное изображение рукописного текста или подписи, хранящееся в памяти компьютера. Считается менее эффективным по сравнению с online-исследованием почерка, так как программа работает только со статическими характеристиками, такими как геометрические особенности элементов, соотношение их длин и т. д. Однако, несмотря на это, offline-исследование почерка вызывает наибольший интерес у исследователей, поскольку даже в эпоху массовой цифровизации документооборота рукописи на бумажном носителе по-прежнему остаются весьма популярными. |
| По типу решаемых задач             | Идентификация (классификация) – алгоритмы этого направления основаны на предположении, что в базе данных имеются образцы почерка истинного автора исследуемой рукописи. Таким образом цель программы состоит в том, чтобы правильно отнести исследуемую рукопись к                                                                                                                                                                                                                                                                                                 | Верификация – алгоритмы в рамках данного подхода производят сравнение, осуществляемое по принципу «один к одному». Иными словами, система сравнивает между собой исследуемую рукопись, автор которой неизвестен, с каким-нибудь контрольным образцом почерка предполагаемого исполнителя. Результатом                                                                                                                                                                                                                                                                                                                                       |

|                     |                                                                                                                                                                                                                                                                                                                                                                                |                                                                                                                                                                                                                                                                                                                                                                                                                                              |
|---------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                     | <p>конкретному автору из этой базы данных, т. е. произвести сравнение по принципу «один ко многим». В качестве прогноза подобная система может предоставить, например, ранжированный список авторов, начиная с наиболее вероятного исполнителя и заканчивая наименее вероятным.</p>                                                                                            | <p>такого сравнения является прогноз о том, насколько схожи или различны два сравниваемых объекта.</p>                                                                                                                                                                                                                                                                                                                                       |
| По типу сегментации | <p>Текстозависимый (Text-Dependent) – подход, который предполагает изучение рукописей в целом, без их сегментации. Такой способ анализа считается более точным и требует меньшего количества образцов почерка для эффективной работы. Однако, такой подход обладает меньшей гибкостью, поскольку содержание текстов и/или записей во всех образцах должно быть идентичным.</p> | <p>Текстнезависимый (Text-Independent) – в отличие от текстозависимого подхода является менее точным, однако обладает большей гибкостью в использовании. Достигается это за счет использования сегментации исходной рукописи на отдельные символы, группы символов и их элементы. Это позволяет алгоритму обобщить информацию о почерке, что позволяет использовать его для анализа любых образцов почерка, независимо от их содержания.</p> |

**Примеры некоторых экспериментальных материалов, на которых проводилось обучение нейронных сетей (набор данных №1)**



**Примечание:**




1) На изображениях представлены следующие образцы (слева на право): образец подлинной подписи, образец неподлинной подписи (исполнитель входит в обучающую выборку), образец неподлинной подписи (исполнитель не входит в обучающую выборку);

2) Поскольку все используемые изображения переводились в режим «градации серого», тон красящего вещества материала письма не влиял на итоговый результат;


3) Подробный иллюстративный материал в части выявляемых признаков почерка нейронными сетями и их сравнение на разных наборах данных представлен в приложениях №26–28.

**Некоторые экспериментальные образы из открытого набора данных CEDAR**


Подлинные образцы



Поддельные образцы




## Методы сравнительного анализа и принятия решения








**Схема и структурные элементы нейросетевой модели без механизма внимания (модель основана на ИНС ResNet)**




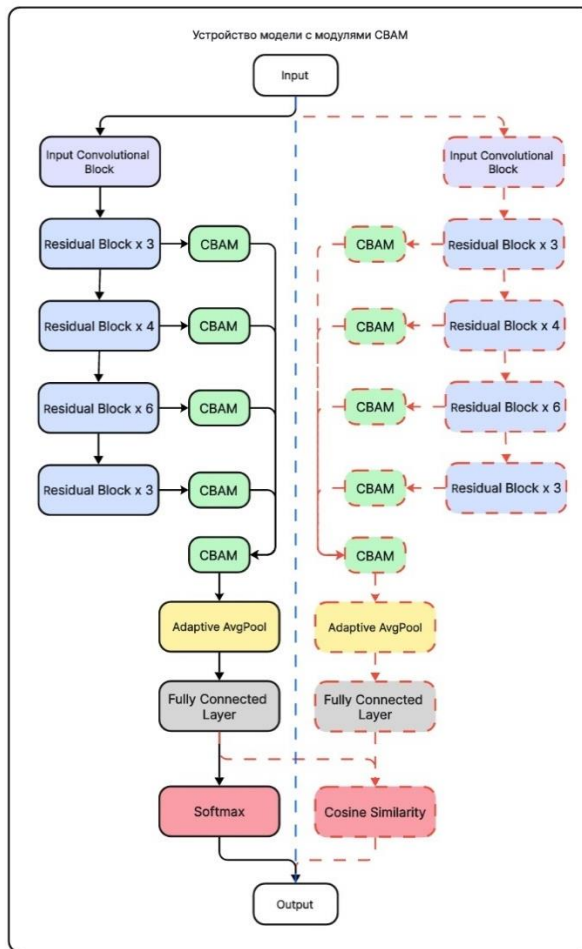
**Примечание:** Красными пунктирными линиями показан путь движения данных в варианте SNN-модели

### Схема и структурные элементы нейросетевой модели с Self-Attention






**Примечание:** Красными пунктирными линиями показан путь движения данных в варианте SNN-модели

### Схема и структурные элементы нейросетевой модели с СВМ



**Примечание:** Красными пунктирными линиями показан путь движения данных в варианте SNN-модели

# **Схема и структурные элементы нейросетевой модели с Cross-Attention**




**Результаты обучения моделей**

| Механизм внимания      | Номер модели | Показатели FC-модели |         |                | Показатели SNN-модели |         |                  |
|------------------------|--------------|----------------------|---------|----------------|-----------------------|---------|------------------|
|                        |              | ACC                  | LOSS    | Время обучения | ACC                   | LOSS    | Время дообучения |
| <b>Без Attention</b>   | <b>№1</b>    | 0.976<br>(41/42)     | 0.08764 | 23.29<br>мин.  | 0.952<br>(40/42)      | 0.08579 | 26.13 мин.       |
|                        | <b>№2.1</b>  | 0.9200<br>(46/50)    | 0.16341 | 38.60<br>мин.  | 0.900<br>(45/50)      | 0.09765 | 55.85 мин.       |
|                        | <b>№2.2</b>  | 0.975<br>(39/40)     | 0.05985 | 27.71<br>мин.  | 0.950<br>(38/40)      | 0.08248 | 39.75 мин.       |
|                        | <b>№3</b>    | 0.916<br>(11/12)     | 0.29421 | 11.91<br>мин.  | 1.000<br>(12/12)      | 0.02205 | 15.47 мин.       |
| <b>CBAM</b>            | <b>№1</b>    | 1.000<br>(42/42)     | 0.04390 | 44.26<br>мин.  | 0.976<br>(41/42)      | 0.02377 | 64.31 мин.       |
|                        | <b>№2.1</b>  | 0.980<br>(49/50)     | 0.03515 | 55.57<br>мин.  | 0.980<br>(49/50)      | 0.02184 | 81.69 мин.       |
|                        | <b>№2.2</b>  | 0.950<br>(38/40)     | 0.21041 | 43.62<br>мин.  | 0.975<br>(39/40)      | 0.01472 | 64.21 мин.       |
|                        | <b>№3</b>    | 0.916<br>(11/12)     | 0.17083 | 13.16<br>мин.  | 1.000<br>(12/12)      | 0.00920 | 19.32 мин.       |
| <b>Self-Attention</b>  | <b>№1</b>    | 1.000<br>(42/42)     | 0.00180 | 119.39<br>мин. | 0.976<br>(41/42)      | 0.00748 | 61.76 мин.       |
|                        | <b>№2.1</b>  | 0.980<br>(49/50)     | 0.06025 | 170.92<br>мин. | 1.000<br>(50/50)      | 0.00920 | 80.65 мин.       |
|                        | <b>№2.2</b>  | 1.000<br>(40/40)     | 0.00134 | 142.37<br>мин. | 1.000<br>(40/40)      | 0.00369 | 63.57 мин.       |
|                        | <b>№3</b>    | 1.000<br>(12/12)     | 0.06957 | 36.72<br>мин.  | 1.000<br>(12/12)      | 0.01182 | 18.27 мин.       |
| <b>Cross-Attention</b> | <b>№1</b>    | _____                | _____   | _____          | 0.952<br>(40/42)      | 0.05988 | 24.07 мин.       |
|                        | <b>№2.1</b>  | _____                | _____   | _____          | 0.880<br>(44/50)      | 0.11586 | 31.11 мин.       |
|                        | <b>№2.2</b>  | _____                | _____   | _____          | 0.900<br>(36/40)      | 0.09424 | 36.88 мин.       |
|                        | <b>№3</b>    | _____                | _____   | _____          | 0.750<br>(9/12)       | 0.27596 | 9.83 мин.        |

## Графики обучения моделей

### Модели без механизма внимания (обычный вариант):


Модель,  
обученная на  
dataset №1




Модель,  
обученная на  
dataset №2.1



Модель,  
обученная на  
dataset №2.2




Модель,  
обученная на  
dataset №3




### Модели без механизма внимания (вариант SNN):


Модель,  
обученная на  
dataset №1




Модель,  
обученная на  
dataset №2.1



Модель,  
обученная на  
dataset №2.2




Модель,  
обученная на  
dataset №3




### Модели с Self-Attention (обычный вариант):

Модель,  
обученная на  
dataset №1




Модель,  
обученная на  
dataset №2.1






Модель,  
обученная на  
dataset №2.2




Модель,  
обученная на  
dataset №3




### Модели с Self-Attention (вариант SNN):


Модель,  
обученная на  
dataset №1



Модель,  
обученная на  
dataset №2.1




Модель,  
обученная на  
dataset №2.2






Модель,  
обученная на  
dataset №3




### Модели с СВМ (обычный вариант):


Модель,  
обученная на  
dataset №1




Модель,  
обученная на  
dataset №2.1



Модель,  
обученная на  
dataset №2.2




Модель,  
обученная на  
dataset №3




## Модели с CBAM (вариант SNN):


Модель,  
обученная на  
dataset №1




Модель,  
обученная на  
dataset №2.1



Модель,  
обученная на  
dataset №2.2




Модель,  
обученная на  
dataset №3




## Модели с Cross-Attention

Модель,  
обученная на  
dataset №1




Модель,  
обученная на  
dataset №2.1



Модель,  
обученная на  
dataset №2.2



Модель,  
обученная на  
dataset №3



**Результаты тестирования моделей с экспериментальным нахождением порога и вычислением EER (тестирование №1)**

**Модели без механизма внимания**

| Номер модели | Вид модели | ACC             | FAR   | FRR   | ERR   | Порог   | ACC+            | ACC-            |                                                                         |
|--------------|------------|-----------------|-------|-------|-------|---------|-----------------|-----------------|-------------------------------------------------------------------------|
| №1           | FC         | 0.762 (61/80)   | 0.238 | 0.237 | 0.230 | 0.98352 | 0.750 (45/60)   | 0.800 (16/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
|              | SNN        | 0.725 (58/80)   | 0.300 | 0.266 | 0.272 | 0.99770 | 0.733 (44/60)   | 0.700 (14/20)   |                                                                         |
| №2.1         | FC         | 0.825 (330/400) | 0.175 | 0.175 | 0.175 | 0.96442 | 0.825 (165/200) | 0.825 (165/200) |                                                                         |
|              | SNN        | 0.842 (337/400) | 0.160 | 0.155 | 0.156 | 0.98824 | 0.845 (169/200) | 0.840 (168/200) |                                                                         |
| №2.2         | FC         | 0.830 (415/500) | 0.169 | 0.170 | 0.170 | 0.96903 | 0.825 (165/200) | 0.833 (250/300) |                                                                         |
|              | SNN        | 0.844 (422/500) | 0.156 | 0.155 | 0.155 | 0.99322 | 0.845 (169/200) | 0.843 (253/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.99988 | _____           | 1.000 (100/100) | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.99829 | _____           | 1.000 (100/100) |                                                                         |
| №1           | FC         | 0.625 (50/80)   | 0.100 | 0.466 | 0.341 | 1       | 0.533 (32/60)   | 0.900 (18/20)   |                                                                         |
|              | SNN        | 0.850 (68/80)   | 0.350 | 0.083 | 0.276 | 1       | 0.916 (55/60)   | 0.650 (13/20)   |                                                                         |
| №2.1         | FC         | 0.707 (283/400) | 0.190 | 0.395 | 0.327 | 2       | 0.605 (121/200) | 0.810 (162/200) |                                                                         |
|              | SNN        | 0.737 (295/400) | 0.340 | 0.185 | 0.226 | 3       | 0.815 (163/200) | 0.660 (132/200) |                                                                         |
| №2.2         | FC         | 0.754 (377/500) | 0.096 | 0.474 | 0.344 | 1       | 0.520 (104/200) | 0.910 (273/300) |                                                                         |
|              | SNN        | 0.816 (408/500) | 0.206 | 0.150 | 0.195 | 1       | 0.850 (170/200) | 0.793 (238/300) |                                                                         |
| №3           | FC         | 0.530 (53/100)  | 0.470 | _____ | _____ | 1       | _____           | 0.530 (53/100)  |                                                                         |
|              | SNN        | 0.870 (87/100)  | 0.130 | _____ | _____ | 1       | _____           | 0.870 (87/100)  |                                                                         |
| №1           | FC         | 0.787 (63/80)   | 0.200 | 0.216 | 0.216 | 0.10389 | 0.783 (47/60)   | 0.800 (16/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.675 (54/80)   | 0.350 | 0.316 | 0.323 | 0.30069 | 0.683 (41/60)   | 0.650 (13/20)   |                                                                         |
| №2.1         | FC         | 0.752 (301/400) | 0.090 | 0.405 | 0.299 | 0.00399 | 0.595 (119/200) | 0.910 (182/200) |                                                                         |
|              | SNN        | 0.870 (348/400) | 0.130 | 0.130 | 0.129 | 0.07592 | 0.870 (174/200) | 0.870 (174/200) |                                                                         |
| №2.2         | FC         | 0.756 (378/500) | 0.184 | 0.335 | 0.286 | 0.02197 | 0.655 (131/200) | 0.823 (247/300) |                                                                         |
|              | SNN        | 0.778 (389/500) | 0.220 | 0.225 | 0.217 | 0.12387 | 0.775 (155/200) | 0.780 (234/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.73726 | _____           | 1.000 (100/100) | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.92507 | _____           | 1.000 (100/100) |                                                                         |
| №1           | FC         | 0.800 (64/80)   | 0.200 | 0.200 | 0.183 | 0.10489 | 0.800 (48/60)   | 0.800 (16/20)   |                                                                         |
|              | SNN        | 0.787 (63/80)   | 0.200 | 0.216 | 0.212 | 0.09990 | 0.783 (47/60)   | 0.800 (16/20)   |                                                                         |
| №2.1         | FC         | 0.882 (353/400) | 0.120 | 0.115 | 0.116 | 0.05694 | 0.885 (177/200) | 0.880 (176/200) |                                                                         |
|              | SNN        | 0.895 (358/400) | 0.105 | 0.105 | 0.104 | 0.23076 | 0.895 (179/200) | 0.895 (179/200) |                                                                         |
| №2.2         | FC         | 0.830 (415/500) | 0.165 | 0.177 | 0.175 | 0.08391 | 0.810 (162/200) | 0.843 (253/300) |                                                                         |
|              | SNN        | 0.870 (435/500) | 0.130 | 0.130 | 0.130 | 0.53046 | 0.870 (174/200) | 0.870 (261/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.41758 | _____           | 1.000 (100/100) |                                                                         |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.40459 | _____           | 1.000 (100/100) |                                                                         |

### Модели с СВМ

| Номер модели | Вид модели | ACC             | FAR   | FRR   | ERR   | Порог   | ACC+            | ACC-            |                                                                         |
|--------------|------------|-----------------|-------|-------|-------|---------|-----------------|-----------------|-------------------------------------------------------------------------|
| №1           | FC         | 0.750 (60/80)   | 0.238 | 0.254 | 0.250 | 0.97478 | 0.733 (44/60)   | 0.800 (16/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
|              | SNN        | 0.762 (61/80)   | 0.250 | 0.233 | 0.235 | 0.99169 | 0.766 (46/60)   | 0.750 (15/20)   |                                                                         |
| №2.1         | FC         | 0.757 (303/400) | 0.160 | 0.325 | 0.278 | 0.95001 | 0.675 (135/200) | 0.839 (168/200) |                                                                         |
|              | SNN        | 0.819 (328/400) | 0.180 | 0.180 | 0.180 | 0.99866 | 0.819 (164/200) | 0.819 (164/200) |                                                                         |
| №2.2         | FC         | 0.759 (380/500) | 0.240 | 0.240 | 0.240 | 0.96846 | 0.759 (152/200) | 0.759 (228/300) |                                                                         |
|              | SNN        | 0.726 (363/500) | 0.273 | 0.275 | 0.273 | 0.99954 | 0.725 (145/200) | 0.726 (218/300) |                                                                         |
| №3           | FC         | 0.879 (88/100)  | 0.120 | _____ | _____ | 0.99895 | _____           | 0.879 (88/100)  | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.99994 | _____           | 1.000 (100/100) |                                                                         |
| №1           | FC         | 0.662 (53/80)   | 0.100 | 0.416 | 0.316 | 1       | 0.583 (35/60)   | 0.899 (18/20)   |                                                                         |
|              | SNN        | 0.824 (66/80)   | 0.350 | 0.116 | 0.283 | 1       | 0.883 (53/60)   | 0.649 (13/20)   |                                                                         |
| №2.1         | FC         | 0.542 (217/400) | 0.421 | 0.505 | 0.466 | 3       | 0.425 (85/200)  | 0.660 (132/200) |                                                                         |
|              | SNN        | 0.737 (295/400) | 0.190 | 0.342 | 0.297 | 2       | 0.625 (125/200) | 0.850 (170/200) |                                                                         |
| №2.2         | FC         | 0.648 (324/500) | 0.459 | 0.178 | 0.295 | 2       | 0.785 (157/200) | 0.556 (167/300) | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.804 (402/500) | 0.250 | 0.115 | 0.220 | 1       | 0.884 (177/200) | 0.750 (225/300) |                                                                         |
| №3           | FC         | 0.759 (76/100)  | 0.240 | _____ | _____ | 2       | _____           | 0.759 (76/100)  |                                                                         |
|              | SNN        | 0.920 (92/100)  | 0.080 | _____ | _____ | 1       | _____           | 0.920 (92/100)  |                                                                         |
| №1           | FC         | 0.650 (52/80)   | 0.350 | 0.350 | 0.350 | 0.12287 | 0.650 (39/60)   | 0.650 (13/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.787 (63/80)   | 0.200 | 0.216 | 0.210 | 0.18381 | 0.783 (47/60)   | 0.800 (16/20)   |                                                                         |
| №2.1         | FC         | 0.620 (248/400) | 0.000 | 0.760 | 0.431 | 0.01498 | 0.240 (48/200)  | 1.000 (200/200) |                                                                         |
|              | SNN        | 0.905 (362/400) | 0.090 | 0.100 | 0.096 | 0.02697 | 0.900 (180/200) | 0.910 (182/200) |                                                                         |
| №2.2         | FC         | 0.786 (393/500) | 0.040 | 0.475 | 0.331 | 0.00299 | 0.525 (105/200) | 0.960 (288/300) |                                                                         |
|              | SNN        | 0.796 (398/500) | 0.206 | 0.200 | 0.204 | 0.16783 | 0.800 (160/200) | 0.793 (238/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.92507 | _____           | 1.000 (100/100) | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.90009 | _____           | 1.000 (100/100) |                                                                         |
| №1           | FC         | 0.675 (54/80)   | 0.333 | 0.300 | 0.308 | 0.24575 | 0.666 (40/60)   | 0.700 (14/20)   |                                                                         |
|              | SNN        | 0.837 (67/80)   | 0.200 | 0.150 | 0.178 | 0.40559 | 0.850 (51/60)   | 0.800 (16/20)   |                                                                         |
| №2.1         | FC         | 0.797 (319/400) | 0.228 | 0.175 | 0.192 | 0.01198 | 0.800 (160/200) | 0.795 (159/200) |                                                                         |
|              | SNN        | 0.930 (372/400) | 0.065 | 0.075 | 0.072 | 0.27372 | 0.925 (185/200) | 0.935 (187/200) |                                                                         |
| №2.2         | FC         | 0.828 (414/500) | 0.166 | 0.180 | 0.174 | 0.11088 | 0.820 (164/200) | 0.833 (250/300) | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 0.914 (457/500) | 0.083 | 0.090 | 0.085 | 0.37162 | 0.910 (182/200) | 0.916 (275/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.87412 | _____           | 1.000 (100/100) |                                                                         |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.05294 | _____           | 1.000 (100/100) |                                                                         |

### Модели с Self-Attention

| Номер модели | Вид модели | ACC             | FAR   | FRR   | ERR   | Порог   | ACC+            | ACC-            |                                                                         |
|--------------|------------|-----------------|-------|-------|-------|---------|-----------------|-----------------|-------------------------------------------------------------------------|
| №1           | FC         | 0.875 (70/80)   | 0.100 | 0.133 | 0.129 | 0.95001 | 0.866 (52/60)   | 0.899 (18/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
|              | SNN        | 0.850 (68/80)   | 0.150 | 0.150 | 0.150 | 0.99785 | 0.850 (51/60)   | 0.850 (17/20)   |                                                                         |
| №2.1         | FC         | 0.827 (331/400) | 0.145 | 0.200 | 0.189 | 0.95001 | 0.800 (160/200) | 0.855 (171/200) |                                                                         |
|              | SNN        | 0.887 (355/400) | 0.110 | 0.115 | 0.111 | 0.99554 | 0.884 (177/200) | 0.889 (178/200) |                                                                         |
| №2.2         | FC         | 0.720 (360/500) | 0.280 | 0.280 | 0.279 | 0.97405 | 0.720 (144/200) | 0.720 (216/300) |                                                                         |
|              | SNN        | 0.800 (400/500) | 0.200 | 0.200 | 0.200 | 0.99894 | 0.800 (160/200) | 0.800 (240/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.99978 | _____           | 1.000 (100/100) | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.99977 | _____           | 1.000 (100/100) |                                                                         |
| №1           | FC         | 0.675 (54/80)   | 0.100 | 0.400 | 0.307 | 1       | 0.600 (36/60)   | 0.899 (18/20)   |                                                                         |
|              | SNN        | 0.925 (74/80)   | 0.150 | 0.050 | 0.136 | 1       | 0.949 (57/60)   | 0.850 (17/20)   |                                                                         |
| №2.1         | FC         | 0.714 (286/400) | 0.215 | 0.363 | 0.316 | 2       | 0.595 (119/200) | 0.834 (167/200) |                                                                         |
|              | SNN        | 0.720 (288/400) | 0.074 | 0.489 | 0.310 | 2       | 0.504 (101/200) | 0.935 (187/200) |                                                                         |
| №2.2         | FC         | 0.624 (312/500) | 0.367 | 0.389 | 0.381 | 2       | 0.595 (119/200) | 0.643 (193/300) | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.694 (347/500) | 0.269 | 0.361 | 0.299 | 2       | 0.634 (127/200) | 0.733 (220/300) |                                                                         |
| №3           | FC         | 0.939 (94/100)  | 0.060 | _____ | _____ | 1       | _____           | 0.939 (94/100)  |                                                                         |
|              | SNN        | 0.620 (62/100)  | 0.380 | _____ | _____ | 1       | _____           | 0.620 (62/100)  |                                                                         |
| №1           | FC         | 0.875 (70/80)   | 0.000 | 0.166 | 0.142 | 0.00299 | 0.833 (50/60)   | 1.000 (20/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.800 (64/80)   | 0.200 | 0.200 | 0.195 | 0.10089 | 0.800 (48/60)   | 0.800 (16/20)   |                                                                         |
| №2.1         | FC         | 0.712 (285/400) | 0.000 | 0.575 | 0.365 | 0.00199 | 0.425 (85/200)  | 1.000 (200/200) |                                                                         |
|              | SNN        | 0.865 (346/400) | 0.130 | 0.140 | 0.136 | 0.02197 | 0.860 (172/200) | 0.870 (174/200) |                                                                         |
| №2.2         | FC         | 0.666 (333/500) | 0.253 | 0.455 | 0.371 | 0.00299 | 0.545 (109/200) | 0.746 (224/300) |                                                                         |
|              | SNN        | 0.660 (330/500) | 0.340 | 0.340 | 0.337 | 0.15184 | 0.660 (132/200) | 0.660 (198/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.76623 | _____           | 1.000 (100/100) | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.86813 | _____           | 1.000 (100/100) |                                                                         |
| №1           | FC         | 0.912 (73/80)   | 0.100 | 0.083 | 0.083 | 0.04995 | 0.916 (55/60)   | 0.900 (18/20)   |                                                                         |
|              | SNN        | 0.850 (68/80)   | 0.150 | 0.150 | 0.150 | 0.40259 | 0.850 (51/60)   | 0.850 (17/20)   |                                                                         |
| №2.1         | FC         | 0.892 (357/400) | 0.120 | 0.095 | 0.097 | 0.02297 | 0.905 (181/200) | 0.880 (176/200) |                                                                         |
|              | SNN        | 0.940 (376/400) | 0.060 | 0.060 | 0.058 | 0.33566 | 0.940 (188/200) | 0.940 (188/200) |                                                                         |
| №2.2         | FC         | 0.724 (362/500) | 0.276 | 0.275 | 0.276 | 0.24775 | 0.725 (145/200) | 0.723 (217/300) | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 0.898 (449/500) | 0.100 | 0.105 | 0.099 | 0.42457 | 0.895 (179/200) | 0.900 (270/300) |                                                                         |
| №3           | FC         | 1.000 (100/100) | 0.000 | _____ | _____ | 0.65934 | _____           | 1.000 (100/100) |                                                                         |
|              | SNN        | 1.000 (100/100) | 0.000 | _____ | _____ | 0.05294 | _____           | 1.000 (100/100) |                                                                         |

### Модели с Cross-Attention



| Номер модели | ACC                | FAR   | FRR   | ERR   | Порог   | ACC+               | ACC-               |                                                                         |
|--------------|--------------------|-------|-------|-------|---------|--------------------|--------------------|-------------------------------------------------------------------------|
| №1           | 0.574<br>(46/80)   | 0.450 | 0.416 | 0.416 | 0.99726 | 0.583<br>(35/60)   | 0.550<br>(11/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
| №2.1         | 0.567<br>(227/400) | 0.434 | 0.430 | 0.432 | 0.99949 | 0.469<br>(94/200)  | 0.665<br>(133/200) |                                                                         |
| №2.2         | 0.546<br>(273/500) | 0.455 | 0.452 | 0.453 | 0.99961 | 0.545<br>(109/200) | 0.546<br>(164/300) |                                                                         |
| №3           | 0.100<br>(10/100)  | 0.900 | —     | —     | 0.99999 | —                  | 0.100<br>(10/100)  |                                                                         |
| №1           | 0.750<br>(60/80)   | 0.550 | 0.150 | 0.392 | 1       | 0.850<br>(51/60)   | 0.449<br>(9/20)    | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
| №2.1         | 0.387<br>(155/400) | 0.442 | 1.000 | 0.642 | 1       | 0.000<br>(0/200)   | 0.774<br>(155/200) |                                                                         |
| №2.2         | 0.639<br>(320/500) | 0.196 | 0.605 | 0.429 | 1       | 0.395<br>(79/200)  | 0.803<br>(241/300) |                                                                         |
| №3           | 0.860<br>(86/100)  | 0.140 | —     | —     | 2       | —                  | 0.860<br>(86/100)  |                                                                         |
| №1           | 0.787<br>(63/80)   | 0.200 | 0.216 | 0.212 | 0.14585 | 0.783<br>(47/60)   | 0.800<br>(16/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
| №2.1         | 0.560<br>(224/400) | 0.443 | 0.435 | 0.436 | 0.11788 | 0.460<br>(92/200)  | 0.660<br>(132/200) |                                                                         |
| №2.2         | 0.476<br>(238/500) | 0.524 | 0.523 | 0.524 | 0.43656 | 0.455<br>(91/200)  | 0.490<br>(147/300) |                                                                         |
| №3           | 1.000<br>(100/100) | 0.000 | —     | —     | 0.00199 | —                  | 1.000<br>(100/100) |                                                                         |
| №1           | 0.825<br>(66/80)   | 0.200 | 0.166 | 0.171 | 0.46353 | 0.833<br>(50/60)   | 0.800<br>(16/20)   | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
| №2.1         | 0.792<br>(317/400) | 0.205 | 0.210 | 0.207 | 0.28971 | 0.790<br>(158/200) | 0.795<br>(159/200) |                                                                         |
| №2.2         | 0.750<br>(375/500) | 0.256 | 0.240 | 0.251 | 0.67432 | 0.760<br>(152/200) | 0.743<br>(223/300) |                                                                         |
| №3           | 1.000<br>(100/100) | 0.000 | —     | —     | 0.05294 | —                  | 1.000<br>(100/100) |                                                                         |

#### Примечание:

- 1) Модели нумеруются по номерам dataset, на которых они были обучены;
- 2) Указатель FC в графе «Вид модели» показывает, что модель является модифицированным классификатором, тогда как SNN обозначает модель в архитектуре сиамской нейронной сети;
- 3) Из-за особенностей сравнения при помощи среднего значения и стандартного отклонения порог в соответствующих графах указан в целочисленных значениях;
- 4) В рамках данной работы ACC+ характеризует точность, с которой система распознает известных ей авторов и верно их идентифицирует, тогда как ACC- показывает эффективность выявления всех «чужих» образцов рукописей, авторов которых нейросеть не знает. Эти показатели, по сути, являются обратными FRR и FAR соответственно;
- 5) Поскольку тестирование моделей №3 проводилось только на «сторонних» образцах рукописей, для нее не определялись показатели FRR, ERR и ACC+. По этой же причине коэффициенты ACC и ACC- равны между собой.



## Графики ROC моделей

### Набор данных №1



### Сравнение при помощи косинусного сходства

### Сравнение при помощи среднего значения и стандартного отклонения




### Сравнение при помощи одноклассового классификатора SVM

### Сравнение при помощи одноклассового классификатора SGD SVM




## Набор данных №2.1




|                                                |
|------------------------------------------------|
| Not-Attention FC (ERR = 0.175; AUC = 0.890)    |
| Not-Attention SNN (ERR = 0.156; AUC = 0.906)   |
| CBAM FC (ERR = 0.279; AUC = 0.778)             |
| CBAM SNN (ERR = 0.180; AUC = 0.881)            |
| Cross-Attention SNN (ERR = 0.432; AUC = 0.594) |
| Self-Attention FC (ERR = 0.190; AUC = 0.871)   |
| Self-Attention SNN (ERR = 0.112; AUC = 0.953)  |

### Сравнение при помощи косинусного сходства




|                                                |
|------------------------------------------------|
| Not-Attention FC (ERR = 0.328; AUC = 0.737)    |
| Not-Attention SNN (ERR = 0.226; AUC = 0.830)   |
| CBAM FC (ERR = 0.466; AUC = 0.575)             |
| CBAM SNN (ERR = 0.297; AUC = 0.791)            |
| Cross-Attention SNN (ERR = 0.642; AUC = 0.279) |
| Self-Attention FC (ERR = 0.317; AUC = 0.747)   |
| Self-Attention SNN (ERR = 0.310; AUC = 0.772)  |

### Сравнение при помощи среднего значения и стандартного отклонения



|                                                |
|------------------------------------------------|
| Not-Attention FC (ERR = 0.300; AUC = 0.783)    |
| Not-Attention SNN (ERR = 0.130; AUC = 0.909)   |
| CBAM FC (ERR = 0.432; AUC = 0.620)             |
| CBAM SNN (ERR = 0.097; AUC = 0.943)            |
| Cross-Attention SNN (ERR = 0.437; AUC = 0.557) |
| Self-Attention FC (ERR = 0.365; AUC = 0.713)   |
| Self-Attention SNN (ERR = 0.137; AUC = 0.914)  |


### Сравнение при помощи одноклассового классификатора SVM




|                                                |
|------------------------------------------------|
| Not-Attention FC (ERR = 0.117; AUC = 0.948)    |
| Not-Attention SNN (ERR = 0.105; AUC = 0.965)   |
| CBAM FC (ERR = 0.193; AUC = 0.874)             |
| CBAM SNN (ERR = 0.073; AUC = 0.964)            |
| Cross-Attention SNN (ERR = 0.208; AUC = 0.849) |
| Self-Attention FC (ERR = 0.097; AUC = 0.954)   |
| Self-Attention SNN (ERR = 0.059; AUC = 0.978)  |

### Сравнение при помощи одноклассового классификатора SGD SVM


## Набор данных №2.2




Сравнение при помощи косинусного сходства



Сравнение при помощи среднего значения и стандартного отклонения



Сравнение при помощи одноклассового классификатора SVM




Сравнение при помощи одноклассового классификатора SGD SVM

### Примечание:

1) ROC – график, который используется для иллюстрации диагностической способности бинарной системы классификатора при изменении порога дискриминации;

2) Поскольку в тестовом наборе данных №3 у нас только «негативные» примеры данных, для него график ROC не строится.

**Усреднённые показатели точности моделей с экспериментальным нахождением порога и вычислением EER (тестирование №1)**



**Примечание:** Зелеными столбцами отмечены FC-модели, синими – SNN.

**Результаты тестирования моделей  
при подборе порога идентификации «вслепую» (тестирование №2)**

**Модели без механизма внимания**

| Номер модели | Вид модели | ACC             | FAR   | FRR   | ERR   | Порог   | ACC+            | ACC-            |                                                                         |
|--------------|------------|-----------------|-------|-------|-------|---------|-----------------|-----------------|-------------------------------------------------------------------------|
| <b>№1</b>    | <i>FC</i>  | 0.800 (64/80)   | 0.428 | 0.118 | 0.273 | 0.95001 | 0.866 (52/60)   | 0.600 (12/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
|              | <i>SNN</i> | 0.875 (70/80)   | 0.450 | 0.016 | 0.233 | 0.95001 | 0.983 (59/60)   | 0.550 (11/20)   |                                                                         |
| <b>№2.1</b>  | <i>FC</i>  | 0.820 (328/400) | 0.233 | 0.125 | 0.179 | 0.95001 | 0.870 (174/200) | 0.770 (154/200) |                                                                         |
|              | <i>SNN</i> | 0.845 (338/400) | 0.150 | 0.160 | 0.155 | 0.98914 | 0.840 (168/200) | 0.850 (170/200) |                                                                         |
| <b>№2.2</b>  | <i>FC</i>  | 0.818 (409/500) | 0.215 | 0.130 | 0.173 | 0.95710 | 0.865 (173/200) | 0.786 (236/300) |                                                                         |
|              | <i>SNN</i> | 0.824 (412/500) | 0.153 | 0.210 | 0.181 | 0.99423 | 0.790 (158/200) | 0.846 (254/300) |                                                                         |
| <b>№3</b>    | <i>FC</i>  | 0.450 (45/100)  | 0.550 | _____ | _____ | 0.95001 | _____           | 0.450 (45/100)  | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
|              | <i>SNN</i> | 0.800 (80/100)  | 0.200 | _____ | _____ | 0.95001 | _____           | 0.800 (80/100)  |                                                                         |
| <b>№1</b>    | <i>FC</i>  | 0.625 (50/80)   | 0.100 | 0.466 | 0.283 | 1       | 0.533 (32/60)   | 0.900 (18/20)   |                                                                         |
|              | <i>SNN</i> | 0.850 (68/80)   | 0.350 | 0.083 | 0.216 | 1       | 0.916 (55/60)   | 0.650 (13/20)   |                                                                         |
| <b>№2.1</b>  | <i>FC</i>  | 0.677 (271/400) | 0.020 | 0.625 | 0.322 | 1       | 0.375 (75/200)  | 0.980 (196/200) |                                                                         |
|              | <i>SNN</i> | 0.817 (327/400) | 0.090 | 0.275 | 0.182 | 2       | 0.725 (145/200) | 0.910 (182/200) |                                                                         |
| <b>№2.2</b>  | <i>FC</i>  | 0.338 (169/500) | 0.651 | 0.681 | 0.666 | 2       | 0.285 (56/200)  | 0.373 (112/300) |                                                                         |
|              | <i>SNN</i> | 0.816 (408/500) | 0.206 | 0.150 | 0.178 | 1       | 0.850 (170/200) | 0.793 (238/300) |                                                                         |
| <b>№3</b>    | <i>FC</i>  | 0.530 (53/100)  | 0.470 | _____ | _____ | 1       | _____           | 0.530 (53/100)  |                                                                         |
|              | <i>SNN</i> | 0.870 (87/100)  | 0.130 | _____ | _____ | 1       | _____           | 0.870 (87/100)  |                                                                         |
| <b>№1</b>    | <i>FC</i>  | 0.650 (52/80)   | 0.650 | 0.250 | 0.450 | 0.03096 | 0.750 (45/60)   | 0.350 (7/20)    | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | <i>SNN</i> | 0.750 (60/80)   | 0.900 | 0.033 | 0.466 | 0.00199 | 0.966 (58/60)   | 0.100 (2/20)    |                                                                         |
| <b>№2.1</b>  | <i>FC</i>  | 0.752 (301/400) | 0.090 | 0.405 | 0.247 | 0.04295 | 0.595 (119/200) | 0.910 (182/200) |                                                                         |
|              | <i>SNN</i> | 0.835 (334/400) | 0.075 | 0.255 | 0.165 | 0.20079 | 0.745 (149/200) | 0.925 (185/200) |                                                                         |
| <b>№2.2</b>  | <i>FC</i>  | 0.770 (385/500) | 0.026 | 0.535 | 0.280 | 0.28271 | 0.465 (93/200)  | 0.973 (292/300) |                                                                         |
|              | <i>SNN</i> | 0.710 (355/500) | 0.378 | 0.155 | 0.267 | 0.05994 | 0.840 (168/200) | 0.623 (187/300) |                                                                         |
| <b>№3</b>    | <i>FC</i>  | 0.560 (56/100)  | 0.440 | _____ | _____ | 0.03996 | _____           | 0.560 (56/100)  | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | <i>SNN</i> | 0.590 (59/100)  | 0.410 | _____ | _____ | 0.04995 | _____           | 0.590 (59/100)  |                                                                         |
| <b>№1</b>    | <i>FC</i>  | 0.700 (56/80)   | 1.000 | 0.066 | 0.533 | 0.01898 | 0.933 (56/60)   | 0.000 (0/20)    |                                                                         |
|              | <i>SNN</i> | 0.737 (59/80)   | 1.000 | 0.000 | 0.500 | 0.02897 | 0.983 (59/60)   | 0.000 (0/20)    |                                                                         |
| <b>№2.1</b>  | <i>FC</i>  | 0.747 (299/400) | 0.477 | 0.025 | 0.251 | 0.02097 | 0.970 (194/200) | 0.525 (105/200) |                                                                         |
|              | <i>SNN</i> | 0.865 (346/400) | 0.115 | 0.155 | 0.135 | 0.33966 | 0.845 (169/200) | 0.885 (177/200) |                                                                         |
| <b>№2.2</b>  | <i>FC</i>  | 0.814 (407/500) | 0.043 | 0.400 | 0.221 | 0.29670 | 0.600 (120/200) | 0.956 (287/300) |                                                                         |
|              | <i>SNN</i> | 0.588 (294/500) | 0.657 | 0.040 | 0.349 | 0.08591 | 0.955 (191/200) | 0.343 (103/300) |                                                                         |
| <b>№3</b>    | <i>FC</i>  | 0.300 (30/100)  | 0.700 | _____ | _____ | 0.06593 | _____           | 0.300 (30/100)  |                                                                         |
|              | <i>SNN</i> | 0.000 (0/100)   | 1.000 | _____ | _____ | 0.06993 | _____           | 0.000 (0/100)   |                                                                         |

### Модели с СВМ

| Номер модели | Вид модели | ACC             | FAR   | FRR   | ERR   | Порог   | ACC+            | ACC-            |                                                                         |
|--------------|------------|-----------------|-------|-------|-------|---------|-----------------|-----------------|-------------------------------------------------------------------------|
| №1           | FC         | 0.824 (66/80)   | 0.380 | 0.101 | 0.241 | 0.95001 | 0.883 (53/60)   | 0.649 (13/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
|              | SNN        | 0.837 (67/80)   | 0.550 | 0.033 | 0.291 | 0.95001 | 0.966 (58/60)   | 0.449 (9/20)    |                                                                         |
| №2.1         | FC         | 0.757 (303/400) | 0.160 | 0.325 | 0.242 | 0.95001 | 0.675 (135/200) | 0.839 (168/200) |                                                                         |
|              | SNN        | 0.682 (273/400) | 0.580 | 0.055 | 0.317 | 0.97948 | 0.944 (189/200) | 0.419 (84/200)  |                                                                         |
| №2.2         | FC         | 0.762 (381/500) | 0.316 | 0.120 | 0.218 | 0.95001 | 0.879 (176/200) | 0.683 (205/300) |                                                                         |
|              | SNN        | 0.551 (276/500) | 0.740 | 0.010 | 0.375 | 0.95001 | 0.990 (198/200) | 0.259 (78/300)  |                                                                         |
| №3           | FC         | 0.140 (14/100)  | 0.860 | _____ | _____ | 0.95001 | _____           | 0.140 (14/100)  | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
|              | SNN        | 0.620 (62/100)  | 0.380 | _____ | _____ | 0.95001 | _____           | 0.620 (62/100)  |                                                                         |
| №1           | FC         | 0.662 (53/80)   | 0.100 | 0.416 | 0.258 | 1       | 0.583 (35/60)   | 0.899 (18/20)   |                                                                         |
|              | SNN        | 0.824 (66/80)   | 0.350 | 0.116 | 0.233 | 1       | 0.883 (53/60)   | 0.649 (13/20)   |                                                                         |
| №2.1         | FC         | 0.615 (246/400) | 0.005 | 0.765 | 0.385 | 1       | 0.234 (47/200)  | 0.995 (199/200) |                                                                         |
|              | SNN        | 0.814 (326/400) | 0.010 | 0.360 | 0.185 | 1       | 0.639 (128/200) | 0.990 (198/200) |                                                                         |
| №2.2         | FC         | 0.782 (391/500) | 0.050 | 0.470 | 0.260 | 1       | 0.529 (105/200) | 0.949 (285/300) | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.804 (402/500) | 0.250 | 0.115 | 0.182 | 1       | 0.884 (177/200) | 0.750 (225/300) |                                                                         |
| №3           | FC         | 0.129 (13/100)  | 0.870 | _____ | _____ | 1       | _____           | 0.129 (13/100)  |                                                                         |
|              | SNN        | 0.920 (92/100)  | 0.080 | _____ | _____ | 1       | _____           | 0.920 (92/100)  |                                                                         |
| №1           | FC         | 0.637 (51/80)   | 0.400 | 0.350 | 0.375 | 0.12087 | 0.650 (39/60)   | 0.600 (12/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.800 (64/80)   | 0.250 | 0.183 | 0.216 | 0.16183 | 0.816 (49/60)   | 0.750 (15/20)   |                                                                         |
| №2.1         | FC         | 0.617 (247/400) | 0.000 | 0.765 | 0.382 | 0.06293 | 0.235 (47/200)  | 1.000 (200/200) |                                                                         |
|              | SNN        | 0.855 (342/400) | 0.170 | 0.120 | 0.145 | 0.02997 | 0.880 (176/200) | 0.830 (166/200) |                                                                         |
| №2.2         | FC         | 0.780 (390/500) | 0.040 | 0.490 | 0.265 | 0.05794 | 0.510 (102/200) | 0.960 (288/300) |                                                                         |
|              | SNN        | 0.646 (323/500) | 0.568 | 0.030 | 0.299 | 0.00599 | 0.965 (193/200) | 0.433 (130/300) |                                                                         |
| №3           | FC         | 0.440 (44/100)  | 0.560 | _____ | _____ | 0.38161 | _____           | 0.440 (44/100)  | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 0.800 (80/100)  | 0.200 | _____ | _____ | 0.04995 | _____           | 0.800 (80/100)  |                                                                         |
| №1           | FC         | 0.675 (54/80)   | 0.600 | 0.233 | 0.416 | 0.15584 | 0.766 (46/60)   | 0.400 (8/20)    |                                                                         |
|              | SNN        | 0.800 (64/80)   | 0.450 | 0.116 | 0.283 | 0.22077 | 0.883 (53/60)   | 0.550 (11/20)   |                                                                         |
| №2.1         | FC         | 0.745 (298/400) | 0.034 | 0.477 | 0.256 | 0.05494 | 0.520 (104/200) | 0.970 (194/200) |                                                                         |
|              | SNN        | 0.492 (197/400) | 0.975 | 0.025 | 0.500 | 0.02597 | 0.960 (192/200) | 0.025 (5/200)   |                                                                         |
| №2.2         | FC         | 0.822 (411/500) | 0.153 | 0.215 | 0.184 | 0.12587 | 0.785 (157/200) | 0.846 (254/300) | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 0.528 (264/500) | 0.778 | 0.005 | 0.391 | 0.03296 | 0.985 (197/200) | 0.223 (67/300)  |                                                                         |
| №3           | FC         | 0.190 (19/100)  | 0.810 | _____ | _____ | 0.05994 | _____           | 0.190 (19/100)  |                                                                         |
|              | SNN        | 0.000 (0/100)   | 1.000 | _____ | _____ | 0.01398 | _____           | 0.000 (0/100)   |                                                                         |

### Модели с Self-Attention

| Номер модели | Вид модели | ACC             | FAR   | FRR   | ERR   | Порог   | ACC+            | ACC-            |                                                                         |
|--------------|------------|-----------------|-------|-------|-------|---------|-----------------|-----------------|-------------------------------------------------------------------------|
| №1           | FC         | 0.875 (70/80)   | 0.100 | 0.133 | 0.116 | 0.95173 | 0.866 (52/60)   | 0.899 (18/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
|              | SNN        | 0.875 (70/80)   | 0.500 | 0.000 | 0.250 | 0.95001 | 1.000 (60/60)   | 0.500 (10/20)   |                                                                         |
| №2.1         | FC         | 0.827 (331/400) | 0.145 | 0.200 | 0.172 | 0.95001 | 0.800 (160/200) | 0.855 (171/200) |                                                                         |
|              | SNN        | 0.764 (306/400) | 0.442 | 0.025 | 0.233 | 0.95001 | 0.970 (194/200) | 0.560 (112/200) |                                                                         |
| №2.2         | FC         | 0.709 (355/500) | 0.420 | 0.095 | 0.257 | 0.95001 | 0.904 (181/200) | 0.579 (174/300) |                                                                         |
|              | SNN        | 0.578 (289/500) | 0.694 | 0.010 | 0.352 | 0.95001 | 0.985 (197/200) | 0.306 (92/300)  |                                                                         |
| №3           | FC         | 0.709 (71/100)  | 0.290 | _____ | _____ | 0.95001 | _____           | 0.709 (71/100)  | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
|              | SNN        | 0.460 (46/100)  | 0.540 | _____ | _____ | 0.95001 | _____           | 0.460 (46/100)  |                                                                         |
| №1           | FC         | 0.675 (54/80)   | 0.100 | 0.400 | 0.250 | 1       | 0.600 (36/60)   | 0.899 (18/20)   |                                                                         |
|              | SNN        | 0.925 (74/80)   | 0.150 | 0.050 | 0.100 | 1       | 0.949 (57/60)   | 0.850 (17/20)   |                                                                         |
| №2.1         | FC         | 0.675 (270/400) | 0.005 | 0.645 | 0.325 | 1       | 0.354 (71/200)  | 0.995 (199/200) |                                                                         |
|              | SNN        | 0.772 (309/400) | 0.010 | 0.445 | 0.227 | 1       | 0.555 (111/200) | 0.990 (198/200) |                                                                         |
| №2.2         | FC         | 0.705 (353/500) | 0.176 | 0.470 | 0.323 | 1       | 0.529 (105/200) | 0.823 (247/300) | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.717 (359/500) | 0.370 | 0.150 | 0.260 | 1       | 0.850 (170/200) | 0.629 (189/300) |                                                                         |
| №3           | FC         | 0.939 (94/100)  | 0.060 | _____ | _____ | 1       | _____           | 0.939 (94/100)  |                                                                         |
|              | SNN        | 0.620 (62/100)  | 0.380 | _____ | _____ | 1       | _____           | 0.620 (62/100)  |                                                                         |
| №1           | FC         | 0.837 (67/80)   | 0.000 | 0.216 | 0.108 | 0.03196 | 0.783 (47/60)   | 1.000 (20/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
|              | SNN        | 0.775 (62/80)   | 0.600 | 0.100 | 0.350 | 0.00299 | 0.900 (54/60)   | 0.400 (8/20)    |                                                                         |
| №2.1         | FC         | 0.712 (285/400) | 0.000 | 0.575 | 0.287 | 0.08191 | 0.425 (85/200)  | 1.000 (200/200) |                                                                         |
|              | SNN        | 0.850 (340/400) | 0.170 | 0.130 | 0.150 | 0.01998 | 0.870 (174/200) | 0.830 (166/200) |                                                                         |
| №2.2         | FC         | 0.532 (266/500) | 0.750 | 0.045 | 0.397 | 0.01098 | 0.955 (191/200) | 0.250 (75/300)  |                                                                         |
|              | SNN        | 0.672 (336/500) | 0.243 | 0.455 | 0.349 | 0.10189 | 0.545 (109/200) | 0.756 (227/300) |                                                                         |
| №3           | FC         | 0.820 (82/100)  | 0.180 | _____ | _____ | 0.07992 | _____           | 0.820 (82/100)  | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 0.210 (21/100)  | 0.790 | _____ | _____ | 0.04995 | _____           | 0.210 (21/100)  |                                                                         |
| №1           | FC         | 0.912 (73/80)   | 0.100 | 0.083 | 0.091 | 0.05494 | 0.916 (55/60)   | 0.900 (18/20)   |                                                                         |
|              | SNN        | 0.750 (60/80)   | 1.000 | 0.000 | 0.500 | 0.02497 | 1.000 (60/60)   | 0.000 (0/20)    |                                                                         |
| №2.1         | FC         | 0.897 (359/400) | 0.119 | 0.085 | 0.102 | 0.01998 | 0.910 (182/200) | 0.885 (177/200) |                                                                         |
|              | SNN        | 0.490 (196/400) | 1.000 | 0.000 | 0.500 | 0.00899 | 0.980 (196/200) | 0.000 (0/200)   |                                                                         |
| №2.2         | FC         | 0.546 (273/500) | 0.750 | 0.010 | 0.380 | 0.02897 | 0.990 (198/200) | 0.250 (75/300)  | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
|              | SNN        | 0.488 (244/500) | 0.847 | 0.005 | 0.426 | 0.03396 | 0.990 (198/200) | 0.153 (46/300)  |                                                                         |
| №3           | FC         | 0.010 (1/100)   | 0.990 | _____ | _____ | 0.01598 | _____           | 0.010 (1/100)   |                                                                         |
|              | SNN        | 0.000 (0/100)   | 1.000 | _____ | _____ | 0.01998 | _____           | 0.000 (0/100)   |                                                                         |




### Модели с Cross-Attention

| Номер модели | ACC                | FAR   | FRR   | ERR   | Порог   | ACC+               | ACC-               |                                                                         |
|--------------|--------------------|-------|-------|-------|---------|--------------------|--------------------|-------------------------------------------------------------------------|
| №1           | 0.537<br>(43/80)   | 0.400 | 0.483 | 0.441 | 0.99878 | 0.516<br>(31/60)   | 0.600<br>(12/20)   | <b>Сравнение при помощи косинусного сходства</b>                        |
| №2.1         | 0.574<br>(230/400) | 0.217 | 0.681 | 0.449 | 0.99990 | 0.284<br>(57/200)  | 0.865<br>(173/200) |                                                                         |
| №2.2         | 0.550<br>(275/500) | 0.468 | 0.422 | 0.445 | 0.99950 | 0.574<br>(115/200) | 0.533<br>(160/300) |                                                                         |
| №3           | 0.039<br>(4/100)   | 0.960 | —     | —     | 0.99997 | —                  | 0.039<br>(4/100)   |                                                                         |
| №1           | 0.750<br>(60/80)   | 0.550 | 0.150 | 0.350 | 1       | 0.850<br>(51/60)   | 0.449<br>(9/20)    | <b>Сравнение при помощи среднего значения и стандартного отклонения</b> |
| №2.1         | 0.372<br>(149/400) | 0.433 | 1.000 | 0.716 | 2       | 0.000<br>(0/200)   | 0.745<br>(149/200) |                                                                         |
| №2.2         | 0.639<br>(320/500) | 0.196 | 0.605 | 0.400 | 1       | 0.395<br>(79/200)  | 0.803<br>(241/300) |                                                                         |
| №3           | 0.860<br>(86/100)  | 0.140 | —     | —     | 1       | —                  | 0.860<br>(86/100)  |                                                                         |
| №1           | 0.475<br>(38/80)   | 0.000 | 0.700 | 0.350 | 0.74025 | 0.300<br>(18/60)   | 1.000<br>(20/20)   | <b>Сравнение при помощи одноклассового классификатора SVM</b>           |
| №2.1         | 0.515<br>(206/400) | 0.283 | 0.774 | 0.529 | 0.53046 | 0.185<br>(37/200)  | 0.845<br>(169/200) |                                                                         |
| №2.2         | 0.464<br>(232/500) | 0.473 | 0.634 | 0.553 | 0.48151 | 0.355<br>(71/200)  | 0.536<br>(161/300) |                                                                         |
| №3           | 1.000<br>(100/100) | 0.000 | —     | —     | 0.02197 | —                  | 1.000<br>(100/100) |                                                                         |
| №1           | 0.575<br>(46/80)   | 0.350 | 0.450 | 0.400 | 0.54145 | 0.550<br>(33/60)   | 0.650<br>(13/20)   | <b>Сравнение при помощи одноклассового классификатора SGD SVM</b>       |
| №2.1         | 0.462<br>(185/400) | 0.439 | 0.748 | 0.593 | 0.46453 | 0.160<br>(32/200)  | 0.765<br>(153/200) |                                                                         |
| №2.2         | 0.684<br>(342/500) | 0.146 | 0.570 | 0.358 | 0.40759 | 0.430<br>(86/200)  | 0.853<br>(256/300) |                                                                         |
| №3           | 1.000<br>(100/100) | 0.000 | —     | —     | 0.16083 | —                  | 1.000<br>(100/100) |                                                                         |

#### Примечание:

- 1) Модели нумеруются по номерам dataset, на которых они были обучены;
- 2) Указатель FC в графе «Вид модели» показывает, что модель является модифицированным классификатором, тогда как SNN обозначает модель в архитектуре сиамской нейронной сети;
- 3) Из-за особенностей сравнения при помощи среднего значения и стандартного отклонения порог в соответствующих графах указан в целочисленных значениях;
- 4) В рамках данной работы ACC+ характеризует точность, с которой система распознает известных ей авторов и верно их идентифицирует, тогда как ACC- показывает эффективность выявления всех «чужих» образцов рукописей, авторов которых нейросеть не знает. Эти показатели, по сути, являются обратными FRR и FAR соответственно;
- 5) Поскольку тестирование моделей №3 проводилось только на «сторонних» образцах рукописей, для нее не определялись показатели FRR, ERR и ACC+. По этой же причине коэффициенты ACC и ACC- равны между собой.




**Усреднённые показатели точности моделей при подборе порога идентификации «вслепую» (тестирование №2)**



**Примечание:** Зелеными столбцами отмечены FC-модели, синими – SNN.



**Разница средних показателей точности  
при тестировании №1 и тестировании №2**




**Примечание:**


- 1) Зелеными столбцами отмечены FC-модели, синими – SNN;
- 2) Расположение столбцов слева от 0 оси Y означает, что модель показала себя лучше при тестировании №2 (подбор порога «вслепую»), справа – при тестировании №1 (при экспериментальном вычислении порога с низким показателем EER)

**Примеры визуализации карт внимания у модели с СВМ****Результаты, полученные при анализе рукописи известной модели****автора:**


Набор данных №1



Набор данных №2.1




Набор данных №2.2




## Результаты, полученные при анализе рукописи неизвестного модели автора:


Набор данных №1




Набор данных №2.1



Набор данных №2.2




Набор данных №3




**Примечание:** изображения слева – исследуемая подпись, изображение справа – образец для сравнения.


**Примеры визуализации карт внимания у модели с Self-Attention**  
**Результаты, полученные при анализе рукописи известного модели**  
**автора:**  
**Набор данных №1**




**Набор данных №2.1**



## Набор данных №2.2




**Результаты, полученные при анализе рукописи неизвестного модели  
автора:**  
Набор данных №1







## Набор данных №2.1



## Набор данных №2.2




## Набор данных №3


**Примечание:**

- 1) Изображения слева — исследуемая подпись, изображение справа — образец для сравнения;
- 2) Приведены изображения только для нижних уровней моделей.

**Примеры визуализации карт внимания у модели с Cross-Attention**  
**Результаты, полученные при анализе рукописи известного модели**  
**автора:**  
Набор данных №1




Набор данных №2.1






## Набор данных №2.2




**Результаты, полученные при анализе рукописи неизвестного модели  
автора:**


## Набор данных №1




## Набор данных №2.1



## Набор данных №2.2



## Набор данных №3

**Примечание:**

- 1) Изображения слева — исследуемая подпись, изображение справа — образец для сравнения;
- 2) Приведены изображения только для нижних уровней моделей.

**Информация о персональном компьютере,  
использовавшегося для разработки искусственных нейронных сетей**

**ОТЧЕТ О СИСТЕМЕ WINDOWS**

**ОС:** Windows 10 Home Single Language 64-bit Версия 2009

**Имя устройства:** MSI

**Процессор:** Intel(R) Core(TM) i7-9750H CPU @ 2.60GHz

**Физических ядер:** 6

**Логических ядер:** 12

**Оперативная память (RAM):** 8,00 ГБ

**Диск С:** Всего: 459.23 ГБ

**GPU №1:** Intel(R) UHD Graphics 630

**GPU №2:** NVIDIA GeForce GTX 1650 with Max-Q Design,  
4096.0 MB, Driver 576.52

**ОТЧЕТ О СИСТЕМЕ WSL**

**Операционная система:** Linux 5.15.167.4-microsoft-standard-WSL2

**Имя устройства:** MSI

**Архитектура:** x86\_64

**Процессор:** x86\_64

**Физических ядер:** 6

**Логических ядер:** 12

**Оперативная память (WSL):** 3.75 ГБ (видимая в WSL)

**Информация о среде выполнения программного кода****Conda версия:** conda 25.3.1**Python версия:** 3.12.2**Список пакетов Conda:**

| Пакет              | Версия    | Пакет                    | Версия   |
|--------------------|-----------|--------------------------|----------|
| _libgcc_mutex      | 0.1       | matplotlib               | 3.10.0   |
| _openmp_mutex      | 4.5       | matplotlib-base          | 3.10.0   |
| absl-py            | 2.1.0     | matplotlib-inline        | 0.1.6    |
| asttokens          | 3.0.0     | mdurl                    | 0.1.2    |
| blas               | 1.0       | mkl                      | 2023.1.0 |
| bottleneck         | 1.4.2     | mkl-service              | 2.4.0    |
| brotli             | 1.1.0     | mkl_fft                  | 1.3.11   |
| brotli-bin         | 1.1.0     | mkl_random               | 1.2.8    |
| brotli-python      | 1.0.9     | ml-dtypes                | 0.5.1    |
| bzip2              | 1.0.8     | mpc                      | 1.3.1    |
| c-ares             | 1.34.4    | mpfr                     | 4.2.1    |
| ca-certificates    | 2025.2.25 | mpmath                   | 1.3.0    |
| captum             | 0.7.0     | msgpack                  | 1.1.0    |
| certifi            | 2025.4.26 | munkres                  | 1.1.4    |
| charset-normalizer | 3.3.2     | mysql                    | 8.4.0    |
| chex               | 0.1.88    | ncurses                  | 6.4      |
| colorama           | 0.4.6     | nest-asyncio             | 1.6.0    |
| comm               | 0.2.1     | nettle                   | 3.7.3    |
| contourpy          | 1.3.1     | networkx                 | 3.4.2    |
| cuda-cudart        | 12.4.127  | numexpr                  | 2.10.1   |
| cuda-cupti         | 12.4.127  | numpy                    | 1.26.4   |
| cuda-libraries     | 12.4.1    | numpy-base               | 1.26.4   |
| cuda-nvrtc         | 12.4.127  | nvidia-cublas-cul2       | 12.6.4.1 |
| cuda-nvtx          | 12.4.127  | nvidia-cuda-cupti-cul2   | 12.6.80  |
| cuda-openssl       | 12.4.127  | nvidia-cuda-nvcc-cul2    | 12.6.85  |
| cuda-runtime       | 12.4.1    | nvidia-cuda-runtime-cul2 | 12.6.77  |
| cuda-version       | 12.4      | nvidia-cudnn-cul2        | 9.6.0.74 |
| cycler             | 0.12.1    | nvidia-cufft-cul2        | 11.3.0.4 |
| cyrus-sasl         | 2.1.28    | nvidia-                  | 11.7.1.2 |

|                         |           |                       |          |
|-------------------------|-----------|-----------------------|----------|
|                         |           | cusolver-cu12         |          |
| debugpy                 | 1.8.11    | nvidia-cusparse-cu12  | 12.5.4.2 |
| decorator               | 5.1.1     | nvidia-nccl-cu12      | 2.24.3   |
| etils                   | 1.11.0    | nvidia-nvjitlink-cu12 | 12.6.85  |
| executing               | 0.8.3     | ocl-icd               | 2.3.2    |
| expat                   | 2.6.4     | onnx                  | 1.17.0   |
| ffmpeg                  | 4.3       | openh264              | 2.1.1    |
| filelock                | 3.17.0    | openjpeg              | 2.5.2    |
| flax                    | 0.10.2    | openldap              | 2.6.5    |
| fontconfig              | 2.14.2    | openssl               | 3.4.0    |
| fonttools               | 4.55.3    | opt-einsum            | 3.4.0    |
| freetype                | 2.13.3    | opt_einsum            | 3.3.0    |
| fsspec                  | 2024.12.0 | optax                 | 0.2.4    |
| giflib                  | 5.2.2     | orbax-checkpoint      | 0.11.0   |
| gmp                     | 6.3.0     | packaging             | 24.2     |
| gmpy2                   | 2.2.1     | pandas                | 2.2.3    |
| gnutls                  | 3.6.15    | parso                 | 0.8.4    |
| gputil                  | 1.4.0     | patsy                 | 1.0.1    |
| h5py                    | 3.12.1    | pcr2                  | 10.42    |
| hdf5                    | 1.14.5    | pexpect               | 4.8.0    |
| humanize                | 4.11.0    | pillow                | 11.1.0   |
| icu                     | 73.2      | pip                   | 25.1     |
| idna                    | 3.7       | platformdirs          | 4.3.7    |
| imageio                 | 2.37.0    | prompt-toolkit        | 3.0.43   |
| importlib-resources     | 6.5.2     | prompt_toolkit        | 3.0.43   |
| intel-openmp            | 2023.1.0  | protobuf              | 5.29.3   |
| ipykernel               | 6.29.5    | psutil                | 5.9.0    |
| ipython                 | 9.1.0     | pthread-stubs         | 0.4      |
| ipython_pygments_lexers | 1.1.1     | ptyprocess            | 0.7.0    |
| ipywidgets              | 8.1.5     | pure_eval             | 0.2.2    |
| jax                     | 0.4.38    | pygments              | 2.19.1   |
| jax-cuda12-pjrt         | 0.4.38    | pyparsing             | 3.2.1    |
| jax-cuda12-plugin       | 0.4.38    | pyqt                  | 6.7.1    |
| jaxlib                  | 0.4.38    | pyqt6-sip             | 13.9.1   |
| jedi                    | 0.19.2    | pyro-api              | 0.1.2    |
| jinja2                  | 3.1.6     | pyro-ppl              | 1.9.1    |
| joblib                  | 1.4.2     | pysocks               | 1.7.1    |
| jpeg                    | 9e        | python                | 3.12.2   |

|                    |              |                 |            |
|--------------------|--------------|-----------------|------------|
| jupyter_client     | 8.6.3        | python-dateutil | 2.9.0post0 |
| jupyter_core       | 5.7.2        | python-docx     | 1.1.2      |
| jupyterlab_widgets | 3.0.13       | python-tzdata   | 2025.2     |
| keyutils           | 1.6.1        | python_abi      | 3.12       |
| kiwisolver         | 1.4.8        | pytorch         | 2.5.1      |
| krb5               | 1.20.1       | pytorch-cuda    | 12.4       |
| lame               | 3.100        | pytorch-mutex   | 1.0        |
| lazy_loader        | 0.4          | pytz            | 2024.1     |
| lcms2              | 2.16         | pywavelets      | 1.8.0      |
| ld_impl_linux-64   | 2.40         | pyyaml          | 6.0.2      |
| lerc               | 4.0.0        | pyzmq           | 26.2.0     |
| libabseil          | 20250127.0   | qhull           | 2020.2     |
| libbrotlicommon    | 1.1.0        | qtbase          | 6.7.3      |
| libbrotlidec       | 1.1.0        | qtdeclarative   | 6.7.3      |
| libbrotlienc       | 1.1.0        | qtsvg           | 6.7.3      |
| libcublas          | 12.4.5.8     | qttools         | 6.7.3      |
| libcufft           | 11.2.1.3     | qtwebchannel    | 6.7.3      |
| libcufile          | 1.9.1.3      | qtwebsockets    | 6.7.3      |
| libcups            | 2.4.2        | readline        | 8.2        |
| libcurand          | 10.3.5.147   | requests        | 2.32.3     |
| libcurl            | 8.12.1       | rich            | 13.9.4     |
| libcusolver        | 11.6.1.9     | scikit-image    | 0.25.0     |
| libcuspars         | 12.3.1.170   | scikit-learn    | 1.6.1      |
| libdeflate         | 1.22         | scipy           | 1.15.2     |
| libedit            | 3.1.20230828 | seaborn         | 0.13.2     |
| libev              | 4.33         | seaborn-base    | 0.13.2     |
| libexpat           | 2.6.4        | setuptools      | 78.1.1     |
| libffi             | 3.4.4        | simplejson      | 3.19.3     |
| libgcc             | 14.2.0       | sip             | 6.10.0     |
| libgcc-ng          | 14.2.0       | six             | 1.17.0     |
| libgfortran-ng     | 11.2.0       | sqlite          | 3.45.3     |
| libgfortran5       | 11.2.0       | stack_data      | 0.2.0      |
| libglib            | 2.78.4       | statsmodels     | 0.14.4     |
| libgomp            | 14.2.0       | sympy           | 1.13.3     |
| libiconv           | 1.16         | tbb             | 2021.8.0   |
| libidn2            | 2.3.4        | tensorstore     | 0.1.71     |
| libjpeg-turbo      | 2.1.4        | threadpoolctl   | 3.5.0      |
| libnghttp2         | 1.58.0       | tifffile        | 2025.2.18  |

|                |                |                         |        |
|----------------|----------------|-------------------------|--------|
| libnpp         | 12.2.5.30      | tk                      | 8.6.14 |
| libnsl         | 2.0.1          | tomli                   | 2.2.1  |
| libntlm        | 1.8            | toolz                   | 1.0.0  |
| libnvfatbin    | 12.4.127       | torchaudio              | 2.5.1  |
| libnvjitlink   | 12.4.127       | torchinfo               | 1.8.0  |
| libnvjpeg      | 12.3.1.11<br>7 | torchtriton             | 3.1.0  |
| libpng         | 1.6.39         | torchvision             | 0.20.1 |
| libpq          | 17.4           | tornado                 | 6.4.2  |
| libprotobuf    | 5.29.3         | tqdm                    | 4.67.1 |
| libsodium      | 1.0.18         | traitlets               | 5.14.3 |
| libsqlite      | 3.46.0         | typing-<br>extensions   | 4.12.2 |
| libssh2        | 1.11.1         | typing_extensi<br>ons   | 4.12.2 |
| libstdcxx      | 14.2.0         | tzdata                  | 2025b  |
| libstdcxx-ng   | 14.2.0         | unicodedata2            | 16.0.0 |
| libtasn1       | 4.19.0         | urllib3                 | 2.3.0  |
| libtiff        | 4.7.0          | wcwidth                 | 0.2.5  |
| libunistring   | 0.9.10         | wheel                   | 0.45.1 |
| libuuid        | 2.38.1         | widgetsnbexten<br>sion  | 4.0.13 |
| libwebp        | 1.3.2          | xcb-util                | 0.4.1  |
| libwebp-base   | 1.3.2          | xcb-util-<br>cursor     | 0.1.5  |
| libxcb         | 1.17.0         | xcb-util-image          | 0.4.0  |
| libxcrypt      | 4.4.36         | xcb-util-<br>renderutil | 0.3.10 |
| libxkbcommon   | 1.9.1          | xkeyboard-<br>config    | 2.44   |
| libxml2        | 2.13.8         | xorg-libx11             | 1.8.12 |
| libxslt        | 1.1.41         | xorg-libxau             | 1.0.12 |
| libzlib        | 1.2.13         | xorg-libxdmcp           | 1.1.5  |
| lime           | 0.2.0.1        | xorg-xorgproto          | 2024.1 |
| llvm-openmp    | 14.0.6         | xz                      | 5.6.4  |
| lxml           | 5.3.0          | yaml                    | 0.2.5  |
| lz4-c          | 1.9.4          | zeromq                  | 4.3.5  |
| markdown-it-py | 3.0.0          | zipp                    | 3.21.0 |
| markupsafe     | 3.0.2          | zlib                    | 1.2.13 |
|                |                | zstd                    | 1.5.6  |



**Официальный ответ Федеральной службы по надзору в сфере связи, информационных технологий и массовых коммуникаций Российской Федерации (Роскомнадзор) на вопрос, относится ли рукописный почерк физического лица к персональным данным**



МИНИСТЕРСТВО ЦИФРОВОГО РАЗВИТИЯ,  
СВЯЗИ И МАССОВЫХ КОММУНИКАЦИЙ  
РОССИЙСКОЙ ФЕДЕРАЦИИ

Мищуку В.А.

seva.mi.112@yandex.ru

**ФЕДЕРАЛЬНАЯ СЛУЖБА  
ПО НАДЗОРУ В СФЕРЕ СВЯЗИ,  
ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ  
И МАССОВЫХ КОММУНИКАЦИЙ  
(РОСКОМНАДЗОР)**

Китайгородский проезд, д. 7, стр. 2, Москва, 109992  
тел.: (495) 198-65-01; факс: (495) 587-44-68; <https://rkn.gov.ru/>

02.07.2025 № 08-312104

На

О рассмотрении обращения Мищука В.А.

Роскомнадзор рассмотрел Ваше обращение от 16.06.2025 № 02-11-22648 и сообщает следующее.

К биометрическим персональным данным в соответствии с ч. 1 ст. 11 Федерального закона от 27.07.2006 № 152-ФЗ «О персональных данных» относятся сведения, которые характеризуют физиологические и биологические особенности человека, на основании которых можно установить его личность (биометрические персональные данные).

При отнесении тех или иных сведений к биометрическим персональным данным необходимо руководствоваться законодательными и иными нормативными правовыми актами Российской Федерации, позволяющими отнести такие сведения человека к биометрическим персональным данным.

В частности, в соответствии с положениями ч. 4 ст. 3 Федерального закона от 29.12.2022 № 572-ФЗ «Об осуществлении идентификации и (или) аутентификации физических лиц с использованием биометрических персональных данных, о внесении изменений в отдельные законодательные акты Российской Федерации и признании утратившими силу отдельных положений законодательных актов Российской Федерации» изображение лица человека, полученное с помощью фотовидеоустройств и запись голоса человека, полученная с помощью звукозаписывающих устройств обрабатываемое в единой биометрической системе относится к биометрическим персональным данным.

2

Принимая во внимание изложенное, рукописный почерк физического лица не будет являться биометрическими персональными данными.

Врио начальника Управления по защите  
прав субъектов персональных данных

Е.Д. Еловских

