

На правах рукописи



Ковальчук Андрей Викторович

**РАЗРАБОТКА НЕЙРОМОРФНЫХ АЛГОРИТМОВ ПРИНЯТИЯ РЕШЕНИЙ В
ЗАДАЧАХ РАСПОЗНАВАНИЯ ОБЪЕКТОВ НА ИЗОБРАЖЕНИИ**

5.12.4 - Когнитивное моделирование (физико-математические науки)

АВТОРЕФЕРАТ

диссертации на соискание ученой степени
кандидата физико-математических наук

Нижний Новгород – 2026

Работа выполнена в Федеральном государственном бюджетном научном учреждении «Федеральный исследовательский центр Институт прикладной физики им. А.В. Гапонова-Грехова Российской академии наук».

Научный доктор физико-математических наук, старший научный сотрудник
руководитель: **Яхно Владимир Григорьевич**

Официальные доктор физико-математических наук, доктор технических наук
оппоненты: **Макаренко Николай Григорьевич**

главный научный сотрудник, заведующий Сектором
Математического Моделирования нелинейных процессов в
гелио/геофизике Федерального государственного бюджетного
учреждения науки Главная (Пулковская) астрономическая
обсерватория Российской академии наук, г. Санкт-Петербург
доктор технических наук, доцент

Новикова Светлана Владимировна

профессор кафедры прикладной математики и информатики
ФГБОУ ВО Казанский национальный исследовательский
технический университет им. А.Н. Туполева–КАИ

Ведущая организация: Федеральное государственное автономное научное учреждение
“Центральный научно-исследовательский и опытно-
конструкторский институт робототехники и технической
кибернетики”, г. Санкт-Петербург

Защита диссертации состоится 21 мая 2026 г. В 15 ч. 00 мин. на заседании
диссертационного совета 24.2.340.15 при ФГАОУ ВО «Национальный исследовательский
Нижегородский государственный университет им. Н.И. Лобачевского» по адресу: 603022, г.
Нижний Новгород, пр. Гагарина, д. 23, корпус 2, Зал научных демонстраций.

С диссертацией можно ознакомиться в читальном зале библиотеки ФГАОУ ВО
«Национальный исследовательский Нижегородский государственный университет им. Н. И.
Лобачевского» и на сайте ННГУ: <https://diss.unn.ru/1626>

Автореферат разослан « ____ » _____ 2026 года

Ученый секретарь диссертационного совета

24.2.340.15,

д.с.н., доцент

Петрова Ирина Эдуардовна

Общая характеристика работы

Актуальность темы диссертации

Современные тенденции в области искусственного интеллекта и распознавания образов всё больше ориентируются на биоморфные методы. Актуальность используемого подхода обусловлена несколькими обстоятельствами.

Во-первых, традиционные алгоритмы распознавания достигают предела эффективности при работе с изменчивыми и зашумлёнными данными, при выходе данных за область обучающих распределений: глубокие модели резко теряют точность при сдвиге домена (Amodei и др., 2016; Taori и др., 2020) и крайне чувствительны к шумам и артефактам (Geirhos и др., 2023; Hendrycks & Dietterich, 2019). В условиях появления новых шумов, ранее невиданных классов или изменений сенсоров такие системы демонстрируют низкую гибкость. Нейроморфные алгоритмы, напротив, обладают адаптивностью и устойчивостью (Izhikevich, 2014), позволяя восстанавливать неполные данные, переносить знания на новые задачи и корректироваться в реальном времени (Han & Lee, 2021).

Во-вторых, они формируют основу интеллектуальных систем нового поколения, где жёстко детерминистские алгоритмы заменяются на самообучающиеся и саморегулирующиеся (Hadsell и др., 2020). Одновременно усиливается запрос на объяснимость моделей (Rudin, 2018; Samek & Müller, 2019). В отличие от традиционного глубокого обучения, требующего больших выборок и ресурсов, нейроморфные алгоритмы обеспечивают непрерывную адаптацию, пояснимость решений и автономное улучшение без внешнего вмешательства.

В-третьих, с инженерной точки зрения биоморфный подход открывает возможности оптимизации: использование параллельной обработки, событийного управления, избыточности и устойчивости к сбоям позволяет строить более экономичные и надёжные системы (Bengio и др., 2015; Gallego и др., 2020). Адаптивное управление на основе мотивационных сигналов сокращает избыточные вычисления, оставляя активными только необходимые модули. Такие модели позволяют экономить вычислительные ресурсы и повышают надёжность в задачах распознавания в реальном времени.

Таким образом, актуальность исследования определяется необходимостью создания гибких и надёжных нейроморфных систем, способных адаптироваться к непредсказуемым условиям реального мира, работать с неполными и изменчивыми сигналами и сохранять эффективность при появлении новых задач.

Степень разработанности проблемы

Исследование нейроподобных сред восходит к классическим моделям биоэлектрической активности Ходжкина и Хаксли (Hodgkin & Huxley, 1952), популяционным моделям Уилсона–Коуэна (Wilson & Cowan, 1972) и теориям латерального торможения Амари (Amari, 1977), объясняющим формирование устойчивых пространственных паттернов. Однако большинство работ ограничивалось либо теоретической динамикой, либо низкоуровневой фильтрацией. Возможности и роль динамических режимов, встроенных в контур классификации в комплексных системах, остается еще слабо изученной.

Традиционные метрики, такие как FAR/FRR фиксируют итоговую ошибку, но не дают оценки качества конкретных примеров. Для решения этих проблем были предложены циклы «кодирование–восстановление» с анализом невязки (Яхно и др., 2006), автоэнкодеры, разрежённое кодирование, байесовские схемы машины Гельмгольца и т.д. Однако формальные критерии выбора алгоритма предобработки в этих решениях отсутствуют.

Механизмы коллективного распознавания развивались в работах Растригина (Растригин & Эренштейн, 1981), Мазурова (Мазуров, 1990) и более поздних исследованиях (Ortega и др., 2001). Решение принималось через выбор классификатора по мере компетенции или по правилам агрегации, но для повышения устойчивости предложены тернарные классификаторы, допускающие ответ «не знаю».

Рост применения ИИ в критических областях обострил проблему непредсказуемых сбоев (Cucker & Smale, 2001). Полное переобучение дорого и рискованно, поэтому развиваются корректоры — модули, обучающиеся на единичных ошибках (Gorban и др., 2021). Согласно теоремам стохастического разделения, в сверхвысоких размерностях такие ошибки отделимы линейными границами, что делает возможной one/few-shot схему построения корректоров.

Обзор показывает, что существующие модели — от латерального торможения Амари до методов корректоров и стохастической разделимости — решают частные задачи, но не дают комплексного решения адаптивного выбора алгоритма, построения тернарных классификаторов и динамической коррекции ошибок. Поэтому требуется система, объединяющая динамические признаки, критерий невязки и коллективное принятие решений — именно такая система построена в данной диссертации.

Цель и задачи исследования

Цель работы — разработка и исследование элементов биоморфной системы, реализующих адаптивный выбор алгоритмов обработки и коррекцию решений на основе внутренней динамики и тернарного коллективного распознавания.

Для достижения поставленной цели решались следующие задачи:

1. Разработать для математических моделей нейронных сетей рекуррентные алгоритмы, обеспечивающие выделение дополнительных информативных признаков для задач классификации.
2. Разработать критерий «невязки» в процессе «кодирования-восстановления» как формализованную метрику оценки данных и алгоритмов и интегрировать его в модуль предобработки изображений отпечатков пальцев.
3. Разработать алгоритмы построения тернарного классификатора и протестировать их реализацию на экспериментальных данных.
4. Разработать методы коррекции решений каскадных детекторов объектов на изображениях, использующих малое количество примеров для обучения.
5. Продемонстрировать на реальных биометрических базах данных, что предложенные процедуры и алгоритмы обучения повышают точность распознавания целевых объектов на изображении и обеспечивают возможность обучения на малых количествах примеров.

Объект и предмет исследования

Объектом исследования являются нейроморфные алгоритмы для распознавания визуальных образов и принятия решений.

Предмет исследования — методы оценки качества данных, динамический выбор алгоритма обработки и корректировка решений в нейроморфных алгоритмах коллективного распознавания.

Научная новизна

1. Показано, что расширение признакового пространства с помощью динамики однородной нейроноподобной среды позволяет повысить качество алгоритмов принятия решений в задаче классификации лиц.
2. Впервые предложена формализация динамики невязки в процессе «кодирование-восстановление» как внутреннего сигнала качества, а также показано, что применение

адаптивного выбора алгоритма бинаризации с помощью невязки повышает качество распознавания изображений на примере отпечатков пальцев.

3. Разработан алгоритм построения тернарного классификатора (эксперта) *OnSVM*, обеспечивающий корректное распознавание в условиях частичной информативности и неопределенности, а также его дообучение.

4. Реализован алгоритм корректировки решений каскадного детектора объектов на изображениях, использующий внутренние состояния и признаки для повышения его точности.

5. Разработана методика тестирования алгоритмов корректировки решений каскадных детекторов на размеченных базах данных изображений.

Теоретическая и практическая значимость

В работе формализованы параметры латерально-ингибиторных функций связи типа латеральное торможение, введено понятие динамики невязки как индикатора качества сигнала, разработана теория тернарного классификатора, разработана модификация алгоритма бустинга M-Adaboost, предложена новая постановка потоковой машины опорных векторов (OnSVM) с максимизацией зазора, а также предложен подход к коррекции ошибок детекторов на основе динамических сверток.

Предложенные алгоритмы применимы при разработке биометрических систем распознавания лиц и отпечатков пальцев, детекторов объектов на видео, систем мониторинга и диагностики, а также для ИИ-модулей, работающих в условиях ограниченных данных и данных со смещением распределений. Часть методов внедрена в НИОКТР “PhysioAssist”, НИОКТР “БСИИРОКО” и зарегистрирована как программное обеспечение.

Методы и методология

В диссертационной работе использован комплекс методов когнитивного, математического и численного моделирования, ориентированный на построение и исследование нейроморфных алгоритмов принятия решений в задачах распознавания изображений.

Основные положения, выносимые на защиту

1. Расширение признакового пространства с помощью динамики однородной нейроподобной среды позволяет повысить точность алгоритмов классификации лиц. В работе показано, что использование 40 параллельных нейроподобных сред с функцией связи типа латеральное торможение (5 масштабов \times 8 ориентаций) и учёт временной эволюции активности среды приводят к существенному снижению ошибки верификации. Ошибка

базового алгоритма снижается с EER ~13% до ~9.5% при использовании 4-х дискретных шагов нейроноподобной среды, что соответствует итоговой точности распознавания ~90–91% при четырёх эталонных изображениях на класс.

2. На примере задачи классификации отпечатков пальцев показано, что по динамике невязки в циклах «кодирование–восстановление» можно строить адаптивные алгоритмы предобработки, автоматически выбирающие между активным нейроноподобным и пассивным линейно-пороговым фильтром. Эксперименты показали, что активный фильтр показывает ошибку EER порядка 11 %, пассивный — около 13 %, тогда как адаптивный выбор алгоритма по невязке снижает ошибку до 9–10 %, что соответствует уменьшению доли неверных классификаций на 10–15 % по сравнению с лучшим одиночным фильтром.

3. Введён и математически формализован тернарный классификатор с областью компетенции, позволяющий локально ограничивать область уверенного распознавания и снижать ошибки в каскадных детекторах при добавлении новых объектов или атрибутов без изменения основной модели. В задаче классификации атрибутов лиц, предложенные алгоритмы построения тернарных экспертов M-Adaboost и OnSVM показывают заметный рост качества: тернарный режим снижает ошибку на 5–14% по сравнению с бинарным. При этом доля объектов, по которым эксперт возвращает ответ «не знаю», остаётся ограниченной, позволяя безопасно передавать сложные случаи в последующие каскады детекторов, что обеспечивает расширение области компетенции системы без ухудшения базовой точности.

4. Решения каскадных детекторов, использующих модифицированные признаки Цензуса, могут быть скорректированы с помощью линейных правил по малому числу примеров ошибок, существенно меньшему, чем число верных предсказаний. На базах «Цифры» и «Идентификаторы» показано, что обучение FN-корректоров по выборке пропущенных срабатываний (FN) позволяет увеличить полноту детектирования цифр с 0.94 до 0.98 при практически неизменной точности (0.92 → 0.91). Для задачи детектирования идентификаторов корректоры по небольшому числу ложных срабатываний (FP) повышают точность с 0.36 до 0.64 при сохранении высокой полноты (Recall ≈ 0.98).

Обоснованность и достоверность

Достоверность результатов подтверждена результатами тестирования на широко известных и независимых биометрических базах данных, таких как *MNIST*, *OptDigits*, *PenDigits*, *FERET*, *FG-NET+*, а также на специально собранных датасетах изображений лиц, изображений отпечатков пальцев, фрагментов фасадов домов и базы изображений лиц различной этнической принадлежности. Для валидации разработанных алгоритмов

применены методы перекрестной проверки, многократной повторной выборки, сравнение с эталонными реализациями *LIBSVM* и *AdaBoost*. В диссертации представлены графики сходимости, карты невязок, ROC-кривые и сравнения ошибок, подтверждающие корректность моделей.

Публикации автора по теме диссертации

Всего по теме диссертации опубликовано 10 статей в научных журналах из списка изданий, рекомендованных ВАК. Из них: 8 статей в научных изданиях, индексируемых в базах данных Web of Science и Scopus [A1-A3, A5, A7-A10], 9 статей в научных изданиях, индексируемых в базе RSCI [A1-A3, A5-A10].

Апробация результатов

Основные результаты диссертационной работы были представлены на международных и российских научных конференциях: VI всероссийской научно-технической конференции “Нейроинформатика – 2004” (Москва, 2004), VII всероссийской научно-технической конференции “Нейроинформатика – 2005” (Москва, 2005), 13-й всероссийской конференции “Математические методы распознавания образов”, (Зеленогорск, 2007), X всероссийской научно-технической конференции “Нейроинформатика – 2008” (Москва, 2008), XI всероссийской научно-технической конференции “Нейроинформатика – 2009” (Москва, 2009), XV международной научно-технической конференции «Информационные системы и технологии» (Нижний Новгород, 2009), Всероссийской конференции "Нелинейная динамика в когнитивных исследованиях" (Нижний Новгород, 2009), XII всероссийской научно-технической конференции “Нейроинформатика – 2010” (Москва, 2010), 13-й всероссийской научно-технической конференции “Нейроинформатика – 2011” (Москва, 2011), 3-й всероссийской конференции «Нелинейная динамика в когнитивных исследованиях – 2013» (Нижний Новгород, 2013), 15-й всероссийской научно-технической конференции “Нейроинформатика – 2013” (Москва, 2013), 19-й международной научно-технической конференции “Нейроинформатика – 2017” (Москва, 2017), 4-й международной конференции “Нейротехнологии и Нейроинтерфейсы” (Калининград, 2022), 25-й международной научно-технической конференции “Нейроинформатика – 2023” (Москва, 2023)

Алгоритмы и методы, описание которых приведено в главах данной работы, использованы в следующих НИОКТР, грантах и РИД:

НИОКТР “Автоматическая интеллектуальная система оценки биомеханики верхних и нижних конечностей”. П2030/2024-СП4 тема №9. Рег. номер 124091900013-6 (Россия, 2024).

Свидетельство о государственной регистрации программ ЭВМ № 2025610744 “PhysioAssist - Автоматическая интеллектуальная система оценки биомеханики верхних и нижних конечностей” (Россия, 2025).

НИОКТР “Биоморфная система искусственного интеллекта для распознавания образов с коррекцией ошибок (БСИИРОКО)” КодИИ-117137 (Россия, 2022-2025).

НИОКТР “Intelektinė paslaugų teikimo procesų valdymo sistema Magnetca Golf Video Capturing, skirta kompleksiniam golfo paslaugų valdymui” (“Интеллектуальная система видеозахвата ‘Magnetca Golf Video Capturing’ для комплексного управления гольф-сервисами”) 01.2.1-LVPA-T-848-01-0016 (Литва, 2019-2022).

CRDF Грант «Разработка методов обработки и принятия решений по биометрическим данным» (“Development of Application of Pattern Recognition Technology”) RMO-10214 BNL (США, 2000–2009)

Структура и объем диссертации

Диссертационная работа состоит из введения; основной части, состоящей из четырех глав, в которых изложено содержание диссертации; выводов; списка литературы. Общий объем работы составляет 183 страницы машинописного текста, 51 рисунков, 18 таблицы, 42 формулы, 2 приложения и 190 цитируемых работ.

Краткое содержание диссертации по главам и разделам

В первой главе (**Использование динамики преобразования изображений в нейроноподобных средах в задачах классификации**) рассматривается проблема построения нейроноподобных динамических фильтров, способных формировать устойчивые и информативные признаки изображений без долгого обучения на больших выборках [A1-A3]. Классические свёрточные сети концентрируются на статической обработке, тогда как живые сенсорные системы извлекают информацию в ходе непрерывной пространственно-временной эволюции активности (Amari, 1977). Цель главы — показать, как распределённая нелинейная динамика может быть использована для предварительной фильтрации изображений и последующей классификации лиц, а также сформулировать требования к математическим моделям и алгоритмам распознавания, опирающимся на такие фильтры.

В разделе 1.1 (**Динамические уравнения нейроноподобной среды**) решается задача формализации динамики нейроноподобной среды. Рассматривается пара интегро-дифференциальных уравнений для средних активностей возбуждающих и тормозных популяций и, опираясь на предположение, что торможение медленнее возбуждения, выполняется упрощение их до однокомпонентного уравнения (1) (Яхно В.Г. и др., 1994).

$$\tau_u \frac{\partial u}{\partial t} = -u + S_1 F_1 [-T_1 + \alpha_1 \int_{\Omega} W(x, x-r) \cdot u(r, t) dr + u_{ex}] \quad (0)$$

По виду пространственной связи $W(x, x')$ однокомпонентная модель подразделяется на два основных типа: однородная – функция связи одинакова для всех x и неоднородная. Приводится описание влияния параметров на динамику сигнала в среде, а также основные результаты качественного анализа устойчивости, что создает основу для полезной пространственно-временную фильтрации.

В разделе 1.2 (**Виды функций пространственной связи**) ставится задача выбора пространственной связи и показано, как через форму ядра контролировать фильтрующие свойства системы. Рассмотрены три семейства функций связи:

- **Фильтры Габора** — ориентированные полосовые фильтры, пригодные для текстурных и контурных признаков.
- **Классическое латеральное торможение** — функция связи, выделяющая локальные контрасты: $W(r) = (1 - rBr)e^{-rAr}$.
- **Анизотропная модификация** фильтра (2) с параметрами a_x, a_y, b . $W(x, y) = (1 - b \cdot y^2)e^{-a_x \cdot x^2 - a_y \cdot y^2}$.

Для модифицированной функции связи определены ее параметры, используя минимальную толщину выделяемых объектов L_{min} : $a_x = b = \frac{4}{L_{min}^2}$, $a_y = \frac{b}{2}$. Определены ограничения на максимальный размер выделяемых объектов $L_{max} \approx [2\sqrt{17} \cdot L_{min}]$ или более консервативную оценку при малом количестве циклов в среде $L_{max} \approx [\sqrt{3} \cdot L_{min}]$. Завершается раздел списком некоторых прикладных задач, решаемых с помощью однокомпонентной среды и функции связи типа латеральное торможение: подавление шума, выделение контуров, селекция ориентированных текстур, обнаружение углов и т.д. (Kuzhentsov и др., 1998).

В разделе 1.3 (**Использование нейроподобной среды с латеральным торможением в задаче классификации лиц**) решается задача построения алгоритма принятия решения о принадлежности изображений одному объекту на примере лиц. Процедура включает четыре шага:

1. Нормализованное разностное изображение 40×48 px пропускается через банк из 40 однородных нейроподобных сред с различными латеральными фильтрами (5 масштабов \times 8 углов). Карты активации конкатенируются в вектор признаков размерности $\approx 76\ 800$, содержащий как глобальные признаки, так и локальные детали разностного лица.

2. Для каждой пары изображений одного человека вычисляется вектор признаков и помещается во “внутриклассовое пространство” (*IOS*); для разных людей — во “внеклассовое” (*EOS*).

3. На парах (*IOS/EOS*) обучается AdaBoost-каскад из пороговых признаков по координатам вектора. Динамическая фильтрация в нейроноподобной среде подавляет освещение и шум, поэтому такие слабые классификаторы эффективны.

4. На базе 100 персон (4 эталона + 5 тестовых снимков) измерены FAR/FRR. Базовый набор фильтров дал EER $\approx 13\%$; оптимизация масштаба и эксцентриситета ядра снизила её до $\approx 11\%$ без изменения объёма обучающей выборки.

Результаты эксперимента в разделе 1.4 (Выводы) показывают, что на каждом временном шаге возбуждающе-тормозная нелинейная динамика подавляет шум, замыкает разрывы контуров и усиливает устойчивые границы, вследствие этого ошибка (EER) уменьшается до $\sim 9.5\%$ (Рисунок 1). Достигнутая точность ($\sim 90\%$) сопоставима с традиционными методами аналогичной сложности, такими как PCA/”eigenfaces” и LDA/”fisherfaces”, хотя и ниже современных глубоких систем, обучаемых на очень больших массивах данных (Schroff и др., 2015). Это подтверждает практическую жизнеспособность нейроморфного подхода при ограниченных данных и требованиях к интерпретируемости. Система, обученная всего на четырёх эталонных изображениях для каждого из 100 человек, продемонстрировала достаточную точность, а динамическое циклическое обновление нейроноподобных признаков дополнительно повысило надёжность классификации.



Рисунок 1 — Зависимость ошибки от номера итерации.

Во второй главе (Выбор алгоритмов преобразования изображений по динамике невязки на примере задачи классификации отпечатков пальцев) рассматривается проблема адаптивного выбора алгоритмов предобработки изображений и локальной коррекции решений в системах распознавания, где качество входных данных колеблется (Yang и др., 2020). В этой главе акцент сделан на оценке пригодности конкретного сигнала для того или иного алгоритма и выборе “оптимального” алгоритма в процессе работы. В качестве

демонстрации выбрана задача классификации отпечатков пальцев, поскольку она чувствительна к различным шумам, разрывам линий и вариациям контраста.

Раздел 2.1 (Адаптивная модель принятия решений) вводит понятие адаптивной модели принятия решений, основанной на цикле “кодирование - восстановление”. Ключевая идея состоит в том, что величина невязки (расхождения между исходным сигналом и реконструкцией после очередного прохода) служит мерой качества сигнала и характер её изменения используется как признак для автоматического переключения между алгоритмами обработки. В работе сформулирован критерий выбора, который сводится к определению скорости затухания невязки и показано, что для задачи бинаризации отпечатка пальца выбор можно осуществить по первым двум итерациям.

В разделе 2.2 (Оценка качества работы алгоритмов) приведена схема сравнения алгоритмов и получение метрики качества для задачи бинаризации отпечатков пальцев (Рисунок 2). Цель — получить численный показатель пригодности одного из алгоритмов предобработки к локальной структуре данных, не зависящий от природы фильтра (Яхно и др., 2006).

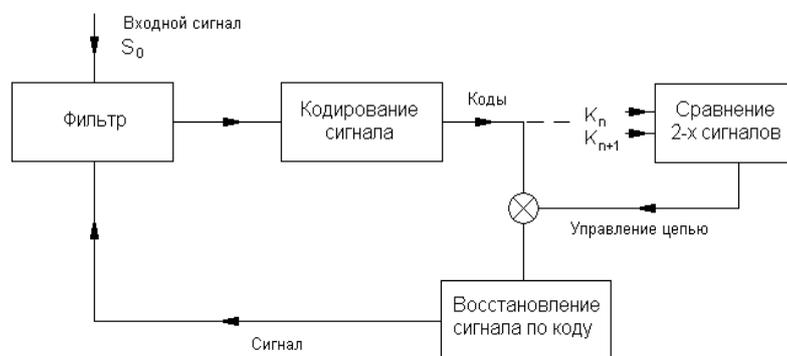


Рисунок 2 — Схема алгоритма анализа фильтров

Рассматриваются два алгоритма предобработки: «активный» неоднородный нейроноподобный фильтр с ориентированными и масштабно-селективными связями, усиливающий устойчивые структурные элементы и нормализующий межгребневые интервалы; и «пассивный» высокочастотный линейно-пороговый фильтр для выравнивания среднего и дисперсии, устойчивый в однородных областях.

В используемой методике в качестве кодирования/восстановления применяются пороговая бинаризация и реконструкция гауссовыми ядрами; невязка — усреднённый модуль разности между бинаризованными изображениями соседних итераций с последующей агрегацией по маске качества областей. Динамика невязки в цикле “кодирование - восстановление” позволяет количественно различать «хорошие» и «плохие» зоны: в шумных фрагментах исходная невязка выше, к 3–4-й итерации в обоих фильтрах наблюдается

существенное падение ошибки и выход к стационарности, что может служить критерием корректности реализации алгоритма (Рисунок 3). Таким образом, невязка служит не только критерием выбора между алгоритмами, но и формализованным показателем качества изображения, позволяя адаптивной системе выступать мета-алгоритмом принятия решений.

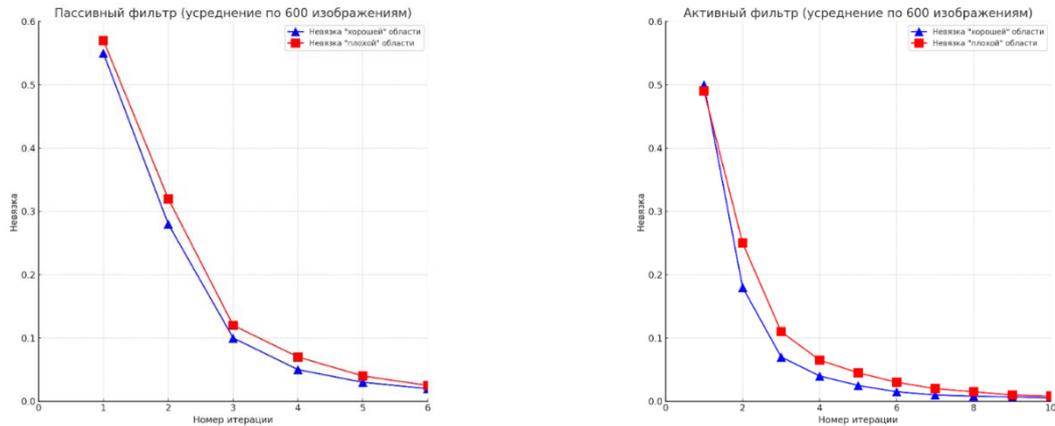


Рисунок 3 — Зависимость средних невязок различных по качеству областей для 600 отпечатков

Раздел 2.3 (Классификация особых точек с помощью адаптивного выбора алгоритма бинаризации) посвящён исследованию эффективности адаптивного выбора алгоритма бинаризации для задачи классификации отпечатков пальцев по особым точкам. Основная идея состоит в том, что использование одного фиксированного метода фильтрации (например, пассивного с глобальным порогом) не гарантирует стабильного выделения структурных элементов в условиях низкого качества изображений. В отличие от этого, адаптивная схема, основанная на динамике невязки, позволяет автоматически переключаться между пассивным и активным алгоритмом, повышая надёжность классификации.

В задаче классифицируются “особые точки” — ядра и дельты, которые являются устойчивыми опорными ориентирами при сопоставлении отпечатков. Их извлечение реализовано на основе анализа поля направлений папиллярного узора. Используется градиентный метод: для каждого пикселя (i, j) вычисляются частные производные $G_x(i, j)$ и $G_y(i, j)$ и по ним определяется угол доминирующей линии $\theta = \frac{1}{2} \arctan \frac{2S_{xy}}{S_x + S_y - S_{xy}}$.

Для выявления сингулярных точек используется *индекс Пуанкаре*. Каждая особая точка описывается гистограммой углов в окрестности 50×50 пикселей из $M=16$ секторов. Среднее направление в секторе кодируется как вектор $\mathbf{f} = [\cos \varphi_1, \sin \varphi_1, \dots, \cos \varphi_M, \sin \varphi_M]$, обеспечивая инвариантность к повороту и устранение разрывов на границе $0^\circ/180^\circ$. Сходство между признаковыми векторами $\mathbf{f}_i, \mathbf{f}_j$ измеряется с помощью косинусной метрики $D(\mathbf{f}_i, \mathbf{f}_j)$ с учётом циклического сдвига.

Разработанная схема сравнения алгоритмов бинаризации включает следующие этапы:

1. Извлечение признаков и присвоение каждой точке класса ID.
2. Формирование обучающей и тестовой выборок случайным разделением пополам.
3. Классификация ближайшего соседа с помощью метрики $D(f_i, f_j)$.
4. Расчёт FAR/FRR, используя минимальные расстояния до “своего” $D_{in}^{(i)}$, “чужого” $D_{out}^{(i)}$ классов и порог T :
$$FAR(T) = \frac{1}{N} \sum_{i=1}^N I(D_{out}^{(i)} < T)$$

$$FRR(T) = \frac{1}{N} \sum_{i=1}^N I(D_{in}^{(i)} > T)$$
 где I – индикаторная функция, N – количество тестовых примеров. Точка пересечения кривых даёт EER.

5. Сравнение трёх подходов: пассивного, активного и адаптивного. В адаптивной схеме выбор ветви для точки осуществляется по скорости убывания невязки между первой и второй итерацией.

6. Повторная выборка и усреднение: эксперимент повторяется 10 раз с разными разбиениями.

Эксперименты проведены на базе из 600 отпечатков (60 пальцев, по 10 снимков), полученных сенсором Veridicom при различных условиях, из которых выделено 1411 особых точек. Результаты сравнения алгоритмов (Таблица 1) показывают, что адаптивная схема обеспечила снижение ошибки почти вдвое по сравнению с пассивным методом. Активная фильтрация выбиралась в 75% случаев, что позволило уменьшить общую ошибку по сравнению с выбором только активного фильтра.

Таблица 1 — Сравнение доли ошибок распознавания классов.

Ошибка	Пассивный	Активный	Адаптивный
Среднее	0.134	0.097	0.072
Отклонение	0.031	0.02	0.023

В разделе 2.4 (Выводы) заключается, что применение адаптивной схемы к задаче классификации особых точек отпечатков пальцев дает значимый результат: выбор фильтра в окрестности каждой особой точки на основе анализа невязки уменьшает общую ошибку распознавания по методу ближайшего соседа. Сравнение двух методов фильтрации — активного нейроподобного и пассивного линейного — показало их комплементарность. Активный фильтр более эффективен для сильно зашумлённых и размытых отпечатков, поскольку способен восстанавливать недостающие фрагменты папиллярного узора и усиливать контраст. Пассивный фильтр быстрее и хорошо работает на чётких изображениях, устраняя фон и выравнивая яркость. Ключевым критерием выбора алгоритма служит динамика невязки на первых итерациях, которая позволяет адаптивно применять наиболее результативный метод в каждой локальной области.

Третья глава (Комитеты слабых классификаторов в задачах классификации объектов на изображении) посвящена проблеме коллективного распознавания, которое изучает способы согласования решений множества классификаторов для получения более точного и устойчивого итогового решения [A5-A7]. В **разделе 3.1 (Введение: коллективное распознавание)** показано, что развитие ансамблевых методов в распознавании связано с идеей декомпозиции сложности и специализации классификаторов по областям признакового пространства (Kittler и др., 1998). Оформились стратегии объединения, такие как простое и взвешенное голосование, байесовские правила, мета-обобщение, динамический выбор по локальной компетентности, нейросетевые агрегаторы и комитетные схемы. Их можно свести к двум парадигмам: оптимизация индивидуальных решений и оптимизация покрытия. В русле оптимизации покрытия развивались методы локальной компетентности: выбор лучшего классификатора в окрестности (Jacobs и др., 1991), схемы с «рефери» (Ortega и др., 2001), иерархические многоуровневые архитектуры и вероятностные оценки компетентности (Seewald & Fürnkranz, 2001). Параллельно формировалось мета-обобщение: выходы базовых моделей рассматривались как признаки для мета-классификатора (Ting & Witten, 2011), что сближало ансамбли с иерархическими нейросетями (Nilnumpetch и др., 2022)

В **разделе 3.2 (Проблема асимметрии ошибок слабых бинарных классификаторов)** рассматривается фундаментальная для ансамблей слабых бинарных классификаторов проблема асимметрии ошибок первого и второго родов: правила, формирующие слабый классификатор хорошо различают лишь один класс, но не оба сразу. Классические схемы бустинга (напр., AdaBoost) минимизируют суммарную взвешенную ошибку и фактически отбрасывают такие классификаторы, ориентируясь на область одновременно малых FAR и FRR (Freund & Shapire, 1999). Для преодоления асимметрии вводится тернарный классификатор-«эксперт» $h_t: X \rightarrow \{-1, 0, +1\}$, допускающий отказ от ответа (0) вне области компетенции и тем самым снижающий число ошибок на «пограничных» объектах. Введены показатели эффективности эксперта R_3 - доля объектов, для которых вынесено уверенное решение, ошибка эксперта E_3 на этой области и бинарная ошибка E_2 , связанные соотношением $E_2 \leq 1 - R_3(1 - E_3)$. При мета-обобщении формируется экспертный комитет с двумя порогами, задающими зоны уверенных решений и *зазор неопределённости*.

Также в этом разделе описан алгоритм M-AdaBoost для тернарных экспертов, который последовательно минимизирует ошибку тернарного классификатора, состоящего из k классификаторов, определяемую как $\epsilon_k = \frac{E_k}{W_k}$, где E_k – суммарный вес ошибок на уверенно классифицированных объектах, а W_k – суммарный вес уверенно классифицированных объектов.

В работе приведено доказательство теоремы о верхней границе ошибки тернарного классификатора, которая ограничена сверху величиной $\epsilon_{final} \leq \prod_{k=1}^K [2\sqrt{\epsilon_k(1-\epsilon_k)}W_k + (1-W_k)]$. Иными словами, рост доли уверенных частных решений приводят к мультипликативному уменьшению итоговой ошибки.

Практическая эффективность показана на задаче детектирования фасадов на изображениях. Для этого использовано модифицированное преобразование Цензуса (МСТ) в качестве признаков и каскад тернарных комитетов, обучаемых итеративно. Сравнение с реализацией классической каскадной структуры Viola-Jones (Viola & Jones, 2001) показывает заметный выигрыш в уменьшении ошибки за счет небольшого снижения эффективности (Таблица 2).

Таблица 2 — Сравнение результатов тестирования бинарного и тернарного детекторов.

	Бинарный детектор	Тернарный детектор
FAR	0.071	0.041
FRR	0.52	0.28
Эффективность (R_3)	1.0	0.94

В разделе 3.3 (Оптимальная разделяющая гиперплоскость) рассматривается принцип максимизации зазора как геометрический эквивалент оптимального “согласия комитета”: чем дальше объект от границы, тем устойчивее коллективное решение и тем ниже ожидаемая ошибка обобщения (Hastie и др., 2001). Эта идея восходит к методу оптимальной гиперплоскости Вапника и соавт. (Вапник & Червоненкис, 1964) и реализована в SVM с допусками ошибок, что обеспечивает высокую обобщающую способность на неполностью разделимых данных. Основные недостатки реализаций SVM — это отсутствие дообучения, квадратичная вычислительная сложность от количества опорных векторов (Cristianini & Shawe-Taylor, 2000) мотивируют искать приближенные решения с помощью итерационных алгоритмов и один из вариантов таких алгоритмов “OnSVM” предложен в разделе 3.3.

Формально, рассматривается пара гиперплоскостей $H_{(w,b^+)}, H_{(w,b^-)} \in H_w$ максимизирующие зазор $b^+ - b^-$ с допусками $\xi_i \geq 0$ и параметрами регуляризации $c_i \geq 0, \eta \geq 0$:

$$\begin{aligned} & \max_{w,b^+,b^-} (b^+ - b^- - \sum_{i=1..N} c_i \xi_i) \\ & \text{s.t.} \begin{cases} y_i \left(\langle w, x \rangle - \frac{1+y_i}{2} b^+ + \frac{y_i-1}{2} b^- \right) \geq -\eta \xi_i \\ \xi_i \geq 0 \\ \|w\|^2 = 1 \end{cases} \end{aligned} \quad (2)$$

Постановка задачи в форма (2) позволяет ввести тернарное правило принятия решений $f_3: X \rightarrow \{-1,0,1\}$, с “зоной неопределённости” между b^+, b^- .

Дальнейший переход к дуальной постановке задачи и замены скалярных произведения на ядровую функцию $K(x, y)$ приводит к оптимизационной задаче:

$$\min(W(\alpha) = \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j K_{i,j}) \quad (3)$$

$$s.t. \begin{cases} \sum_{i: y_i=1} \alpha_i = 1 \\ \sum_{i: y_i=-1} \alpha_i = 1 \\ 0 \leq \alpha_i \leq \frac{c_i}{\eta} \end{cases}$$

, где α – опорные коэффициенты.

Такая постановка позволила сформулировать теоремы о свойствах параметра η , который одновременно является верхней оценкой доли ошибок обучения и нижней оценкой доли опорных векторов, а также об эквивалентности задачи (3) известной модификации ν -SVM.

Чтобы преодолеть ограничения SVM, такие как отсутствие дообучения, рост памяти от числа опорных векторов, высокие затраты при переразметке, разработан последовательный онлайн-алгоритм *OnSVM*. Он решает двойственную задачу (3) итеративно, используя обобщённую схему *SMO/GSMO* с «четвёрками» обучаемых примеров. Процедуры *Insert*, *Solve*, *Remove* последовательно добавляют новые данные, совместно оптимизируют «четверки» примеров из разных классов и удаляют неактивные опорные вектора. Для алгоритма *OnSVM* вводятся ускорения пересчёта градиента и ядровых сумм, что снижает число вызовов ядра с $\mathcal{O}(N^2)$ до близкого к линейному по N на эпоху.

Эксперименты на базах примеров рукописных цифр *Optdigits* и *Pendigits* демонстрируют сравнимую точность с известной реализацией *LIBSVM* при меньшем числе опорных векторов (Таблица 3). В целом *OnSVM* достигает качества, близкого к ν -SVM, предоставляя при этом пошаговое дообучение, управление эффективностью через тернарную логику и существенно меньшие требования к памяти на эпохах, что делает максимизацию зазора практически применимой в сценариях потоковых данных и высокоразмерных признаковых пространствах.

Таблица 3 — Сравнительные результаты работы алгоритмов.

Num	OnSVM					LIBSVM	
	nSV	nSV Max	E_2 (%)	E_3 (%)	R_3 (%)	nSV	E_2 (%)
Optdigits	107.2	112.5	0.57	0.02	94.6	140.7	0.5
Pendigits	978.1	1018.4	0.4	0.01	75.76	1149.1	0.39

В разделе 3.4 (Применение алгоритмов построения экспертных комитетов в задаче определения атрибутов лица на изображении) рассматривается задача распознавания атрибутов лица (пол, возраст, этническая принадлежность) с использованием ансамблей тернарных классификаторов и алгоритма последовательного обучения *OnSVM*. Цель раздела

– показать, что построение экспертных комитетов позволяет повысить точность классификации при меньших вычислительных затратах, что особенно важно для систем реального времени и встраиваемых устройств.

Разработанная система включает этап нормализации фрагмента лица, преобразование в интегральное изображение и классификацию атрибутов с помощью комитета. Каждый слабый классификатор строится на признаках *MCT*, а финальное решение формируется в тернарной схеме $(-1, 0, 1)$.

Тестировались три семейства алгоритмов: *M-AdaBoost* на тернарных слабых классификаторах, *OnSVM-1.0* — последовательный SVM с ядром RBF, обученный на полной тренировочной части и признаках, отобранных *M-AdaBoost*, *OnSVM-0.5* — тот же алгоритм, обученный на случайной половине тренировочной части. Использовались три коллекции данных: *FERET* для пола (мужчины 785 / женщины 461), *FG-NET+* для возраста (взрослые 722 / дети 905), *RUS-IND* для этноса (европейцы 910 / азиаты 646). Для каждого атрибута проводилось *S* рандомизированных разбиений на обучение 70% / тест 30%: для пола и возраста $S=58$, для этноса — $S=20$ и подсчитывались оценки бинарной точности, тернарной точности и эффективности (Таблица 4).

Таблица 4 — Усредненные характеристики алгоритмов в задачах классификации.

Алгоритм	Бин. точность %	Тер. точность %	Эффективность %
M-Adaboost	88	96	91
OnSVM-1.0	90	96	92
OnSVM-0.5	83	92	87

В разделе 3.5 (Выводы) заключается, что использование предложенного последовательного алгоритма *OnSVM* в сочетании с ансамблями тернарных классификаторов обеспечивает значительное улучшение качества распознавания лицевых атрибутов при одновременном снижении вычислительных затрат. Применение тернарной логики позволило сократить совокупную ошибку классификации атрибутов лица в среднем на 2–6% по сравнению с классической бинарной схемой. Наибольший прирост зафиксирован в задачах распознавания пола и возраста, где доля правильно классифицированных примеров увеличивалась за счёт корректной обработки неопределённых ситуаций, которые в бинарных системах чаще приводили к ошибкам. Так использование алгоритма *M-AdaBoost* для построения сильных классификаторов в задаче классификации пола привело к увеличению точности с 89% до 96%, а в задаче определения возраста с 80 до 94%.

Алгоритм *OnSVM* показал хорошую сходимость к решению классического *v-SVM*, но при этом обеспечивал компактность моделей, снижая долю опорных векторов в среднем на 20–30%, чем у традиционного *SVM*, при сопоставимой точности. Это снижение напрямую

отражается на требованиях к памяти и вычислительным ресурсам, что критически важно для систем реального времени и встраиваемых приложений, а онлайн-природа *OnSVM* позволяет системе адаптироваться без полной переобучаемости модели.

Четвертая глава (Коррекция ошибок в принятии решений) посвящена методу исправления ошибок в алгоритмах принятия решений с помощью корректоров [A8-A9]. Современные системы искусственного интеллекта (ИИ) демонстрируют высокую эффективность в ряде прикладных задач, однако ошибки их работы остаются неизбежными и потенциально опасными в реальных сценариях применения — от медицины и транспорта до финансовых систем. Причины ошибок многообразны: нарушение предположения о независимости и одинаковом распределении выборок (Н.О.Р.) (Cucker & Smale, 2001), наличие неопределённости в данных, смещение выборки (Liu и др., 2025), преднамеренные искажения данных и т.д.

Традиционное исправление ошибок опирается на повторное обучение модели, что требует больших вычислительных затрат и не гарантирует сохранения ранее достигнутых навыков. Применение корректоров – альтернатива полному или частичному переобучению моделей (Gorban и др., 2021). Корректор представляет собой внешний модуль (алгоритм), встроенный в систему ИИ и предназначенный для диагностики и локальной коррекции ошибок без полного переобучения. Исходная система ИИ остаётся неизменной, а коррекция осуществляется только для выявленных проблемных ситуаций.

В разделе 4.1 (**Метод коррекции алгоритмов распознавания**) изложена базовая методика построения корректоров, а также ее принципиальное отличие от итеративных алгоритмов: корректоры реализуют неитеративное исправление ошибок на основе одного или нескольких размеченных примеров. Для создания корректора используется небольшой набор размеченных ситуаций:

- класс «*норма*» — корректные состояния системы,
- класс «*ошибки*» — размеченные примеры некорректной работы.

Таким образом, задача сводится к бинарной классификации с крайне несбалансированным числом примеров. Другими словами, задача построения корректора — это задача обучения по одному и/или нескольким примерам. Важную роль здесь играют как методы понижения размерности, так и эффект *благословения размерности*, позволяющий использовать линейные алгоритмы (например, метод опорных векторов, дискриминант Фишера) при соблюдении условий регулярности распределений или заменить вероятностный подход на функциональный анализ (Tuukin и др., 2021).

В разделе 4.2 (Коррекция детекторов для задачи детектирования объектов на изображении) описывается разработанная биоморфная система для семантического анализа изображений, которая использует каскадные детекторы, построенные на базе сильных классификаторов (Viola & Jones, 2001), в которых в качестве признаков применяются модифицированное преобразование Цензуса (MCT). Алгоритм каскадного детектора работает по схеме скользящего окна, классифицируя каждый фрагмент изображения как “объект/не объект”.

Каскадные детекторы допускают ошибки двух типов: **FN** - ложные пропуски и **FP** - ложные срабатывания. Для их устранения вводятся корректоры двух типов:

- **FN-корректор**, обучаемый на пропущенных объектах,
- **FP-корректор**, обучаемый на ложных срабатываниях и корректных примерах.

Для отбора фрагментов используется метрика относительного пересечения (*IoU*) окна с эталонной разметкой. Корректоры строятся на основе анализа признаков векторов, снимаемых каскадным детектором с использованием критерия Фишера. Для повышения устойчивости ошибки делятся на кластеры с помощью *k-means*, и для каждого кластера строится отдельная разделяющая гиперплоскость. Алг. 4.1 описывает итоговый алгоритм обучения корректоров, а Алг. 4.2 - алгоритм их применения.

Эксперименты проведены на двух базах: база идентификаторов ж/д цистерн (1153 изображения) и база цифр на цистернах (1067 изображений). Данные делились на обучающую, корректирующую и тестовую выборки (5/4/1), а эксперименты повторялись 10 раз. Метрики качества оценивались по значениям точности и полноты (*Precision* и *Recall*).

Таблица 5 — Результаты тестирования детекторов

База данных	Конфигурация	Precision	Recall
Цифры	Без корректоров	0.92	0.94
Цифры	FN-корректоры (1)	0.91	0.98
Идентификаторы	Без корректоров	0.36	0.98
Идентификаторы	FP-корректоры (5)	0.65	0.94

Применение FN-корректоров значительно повышает полноту детекции (уменьшает количество пропусков), а FP-корректоры эффективно снижают количество ложных срабатываний (Таблица 5) в задачах детектирования. В целом корректоры улучшили метрики на 20–30% по Precision для задач с высокой долей ложных срабатываний и на 4–6% по Recall для задач с высоким числом пропусков. Таким образом, предложенный метод коррекции на основе критерия Фишера и модифицированного преобразования Цензуса является эффективным дополнением к каскадным детекторам и демонстрирует потенциал применения в задачах с ограниченными обучающими данными.

В разделе 4.3 (Модель коррекции с помощью динамических свёрток) предлагается универсальная схема корректировки ошибок детекторов, основанная на сопоставлении ошибочных примеров с текущими наблюдениями. В отличие от подходов, использующих только внутренние сигналы каскада, здесь корректор сравнивает накопленные примеры ошибок с текущим фрагментом изображения и принимает решение о коррекции (Vinyals и др., 2016). В основе подхода лежит идея замены фиксированной метрики схожести обучаемой нелинейной метрикой, реализованной в виде динамической свёрточной сети, ядра для которой генерируются с помощью признакового описания опорного примера. Такая параметризация позволяет адаптировать решающую поверхность «на лету» без длительного дообучения и делает корректор применимым при ограниченном числе примеров.

Динамическая свёртка формирует параметры фильтра как функцию входа, где ветвь \mathbf{Q} порождает описание e_q опорного примера, а ветвь \mathbf{G} обрабатывает текущий фрагмент g , используя фильтры, сгенерированные из e_q . Таким образом, сеть специализируется на конкретном примере ошибки и повышает чувствительность к его признакам по сравнению со статическими CNN.

В эксперименте сопоставлялись две архитектуры при близком числе параметров: базовая статичная CNN и «динамическая» CNN. Обучение проводилось на парах примеров (q, g) с разметкой «ошибка/норма» на базе цифр MNIST. Качество оценивалось метрикой F_1 на тестовой части базы MNIST. При сопоставимой сложности сети динамическая модель показывала более высокую точность и быструю сходимость, её функция потерь убывала быстрее, а F_1 на валидации рос опережающими темпами (Рисунок 4а).

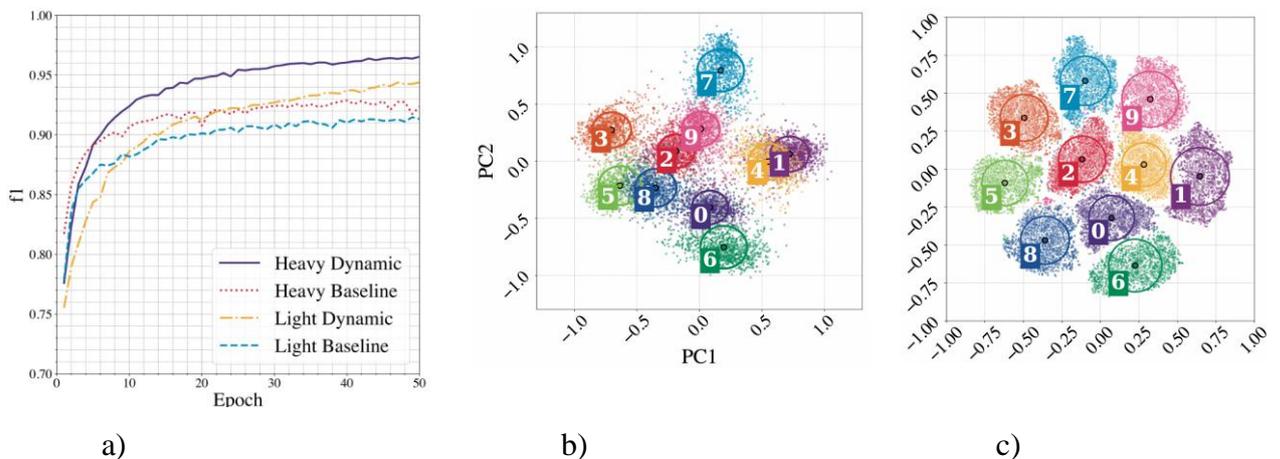


Рисунок 4 — Сравнение характеристик обучения моделей (а) PCA-проекция пространства признаков e_q (b) и проекция tSNE (c).

Дополнительно продемонстрировано, что классы примеров в пространстве признаков образуют компактные и разделимые группы (Рисунок 4 бс), что подтверждает пригодность сопоставления по одному примеру и прототипирования.

В работе реализованы два подхода к построению корректирующих алгоритмов — использование эффекта «благословения размерности» в высокоразмерных пространствах и снижение размерности исходного пространства. Оба метода показали способность существенно повышать качество работы базовых детекторов, позволяя эффективно исправлять ошибки без необходимости переобучения основной модели.

В разделе 4.4 (Выводы) подчеркиваются ряд преимуществ архитектуры корректоров, делающих её привлекательной для практического применения. Прежде всего, она обеспечивает освоение нового класса ошибок без перестройки исходного алгоритма, что особенно важно для автономных систем, где требуется быстрая адаптация. Использование динамических свёрток с адаптивными фильтрами позволяет сети фокусироваться на характерных паттернах ошибки и тем самым повышать точность распознавания аномалий.

Особое значение имеет возможность построения мульти-корректорной системы, в которой входящие данные направляются в специализированные модули в зависимости от типа ошибки. Такой подход обеспечивает масштабируемость и позволяет системе расти вместе с числом новых классов ошибок, не затрагивая уже обученные модули.

Дальнейшие улучшения связаны с выбором более эффективных высокоразмерных пространств для применения стохастических теорем и линейных методов разделения, а также с интеграцией механизмов выявления новизны. Последнее позволит сначала обнаруживать аномальные входы, явно выходящие за рамки обучающего распределения, и только затем запускать коррекцию, снижая количество ложных срабатываний.

В заключении диссертации обобщены результаты исследования, последовательно раскрывающие содержание всех её разделов. Совокупность полученных результатов позволяет рассматривать разработанные в диссертации механизмы как основу для построения перспективных предсказательно-корректирующих архитектур, ориентированных на применение в биометрических системах и автономных системах технического зрения, функционирующих в условиях неполных, зашумлённых и изменчивых данных.

ВЫВОДЫ

1. Показано, что расширение признакового пространства с помощью однородных нейроноподобных сред и использование временной динамики улучшает качество алгоритмов классификации лиц.

2. Разработан фильтр бинаризации отпечатков пальцев на базе неоднородной нейроноподобной среды; эксперименты показали его преимущество над классической нормализацией яркости.

3. Для задачи классификации отпечатков продемонстрировано, что адаптивный выбор алгоритма бинаризации по динамике невязки в цикле «кодирование–восстановление» повышает точность распознавания.

4. Предложен тернарный классификатор-«эксперт» с дополнительным ответом «не знаю», позволяющий формализовать область компетентности.

5. Теоретически и экспериментально обоснован алгоритм *M-Adaboost* для ансамблей тернарных экспертов, снизивший ошибку детектирования фасадов зданий примерно на 40%.

6. Разработан алгоритм *OnSVM*, максимизирующий зазор между ответами экспертов, что обеспечило улучшение классификации атрибутов лица на 2–6% по сравнению с методами бустинга.

7. Реализованы два метода коррекции ошибок распознавания — через эффект «благословения размерности» и редукцию пространства — на примере детекторов объектов.

СПИСОК ЦИТИРУЕМОЙ ЛИТЕРАТУРЫ

- Вапник, В. Н., & Червоненкис, А. Я. (1964). Об одном классе персептронов. *Автомат. и телемех.*, 25(1), 112–120.
- Мазуров, В. Д. (1990). *Метод комитетов в задачах оптимизации и классификации*. Наука.
- Растрингин, Л. А., & Эренштейн, Р. Х. (1981). *Метод коллективного распознавания*. Библиотека по автоматике. Вып. 615. Энергия.
- Яхно, В. Г., Тельных, А. А., Нуйдель, И. В., Полевая, С. А., Парин, С. Б., Беллюстин, Н. С., Еремин, Е. В., Разумов, В. А., Иванов, А. Е., Чайкин, А. В., Шемагина, О. В., Спицын, И. Г., & Краева, Т. А. (2006). Программные модели обработки зрительных сигналов. *Альманах клинической медицины, Том XII*, 69.
- Яхно В.Г., Беллюстин Н.С., Красильникова И.Г., Кузнецов С.О., Нуйдель И.В., Панфилов А. И., Перминов А.О., Шадрин А.В., & Шевырев А.А. (1994). Исследовательская система принятия решений по фрагментам сложного изображения, использующая нейроноподобные алгоритмы. *Изв. Вузов. Радиофизика*, Т. 37. №8, 961–986.
- Amari, S. (1977). Dynamics of pattern formation in lateral-inhibition type neural fields. *Biological Cybernetics*, 27(2), 77–87. <https://doi.org/10.1007/BF00337259>

- Amodei, D., Olah, C., Brain, G., Steinhardt, J., Christiano, P., Schulman, J., Dan, O., & Google Brain, M. (2016). *Concrete Problems in AI Safety*.
- Bengio, Y., Lee, D.-H., Bornschein, J., Mesnard, T., & Lin, Z. (2015). *Towards Biologically Plausible Deep Learning*.
- Cristianini, N., & Shawe-Taylor, J. (2000). An Introduction to Support Vector Machines and Other Kernel-based Learning Methods. B *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press.
<https://doi.org/10.1017/CBO9780511801389>
- Cucker, F., & Smale, S. (2001). On the Mathematical Foundations of Learning. *Bulletin of the American Mathematical Society*, 39(1).
- Freund, Y., & Shapire, R. E. (1999). A short introduction to boosting. *Journal of Japanese Society or Artificial Intelligence*, 771–780.
- Gallego, G., Delbruck, T., Orchard, G., Bartolozzi, C., Taba, B., Censi, A., Leutenegger, S., Davison, A., Conradt, J., Daniilidis, K., & Scaramuzza, D. (2020). Event-based Vision: A Survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1), 154–180.
<https://doi.org/10.1109/TPAMI.2020.3008413>
- Geirhos, R., Jacobsen, J.-H., Michaelis, C., Zemel, R., Brendel, W., Bethge, M., & Wichmann, F. A. (2023). Shortcut Learning in Deep Neural Networks. *Nature Machine Intelligence*, 2(11), 665–673. <https://doi.org/10.1038/s42256-020-00257-z>
- Gorban, A. N., Grechuk, B., Mirkes, E. M., Stasenko, S. V., & Tyukin, I. Y. (2021). High-Dimensional Separability for One- and Few-Shot Learning. *Entropy 2021, Vol. 23, Page 1090*, 23(8), 1090. <https://doi.org/10.3390/E23081090>
- Hadsell, R., Rao, D., Rusu, A. A., & Pascanu, R. (2020). Embracing Change: Continual Learning in Deep Neural Networks. *Trends in Cognitive Sciences*, 24(12), 1028–1040.
<https://doi.org/10.1016/J.TICS.2020.09.004>
- Han, C. S., & Lee, K. M. (2021). A Survey on Spiking Neural Networks. *International Journal of Fuzzy Logic and Intelligent Systems*, 21(4), 317–337.
<https://doi.org/10.5391/IJFIS.2021.21.4.317>
- Hastie, T., Friedman, J., & Tibshirani, R. (2001). *The Elements of Statistical Learning*. Springer New York. <https://doi.org/10.1007/978-0-387-21606-5>
- Hendrycks, D., & Dietterich, T. (2019). Benchmarking Neural Network Robustness to Common Corruptions and Perturbations. *7th International Conference on Learning Representations, ICLR 2019*.

- Hodgkin, A. L., & Huxley, A. F. (1952). A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 117(4), 500. <https://doi.org/10.1113/JPHYSIOL.1952.SP004764>
- Izhikevich, E. M. . (2014). *Dynamical Systems in Neuroscience : the Geometry of Excitability and Bursting*. MIT Press.
- Jacobs, R. A., Jordan, M. I., Nowlan, S. J., & Hinton, G. E. (1991). Adaptive Mixtures of Local Experts. *Neural Computation*, 3(1), 79–87. <https://doi.org/10.1162/NECO.1991.3.1.79>
- Kittler, J., Hatef, M., Duin, R. P. W., & Matas, J. (1998). On combining classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3), 226–239. <https://doi.org/10.1109/34.667881>
- Kuzhentsov, S. O., Nuidel, I. V., Panfilov, A. I., & Yakhno, V. G. (1998). Image processing by neuron-like algorithms. *The Proc. SPIE “Optical Information Science and Technology” – in Optical Memory and Neural Networks*, 3402, 479–485.
- Liu, C., Tang, K., Qin, Y., & Lei, Q. (2025). *Bridging Distribution Shift and AI Safety: Conceptual and Methodological Synergies*.
- Nilnumpetch, C., Amornsamankul, S., & Kraipeerapun, P. (2022). Cascade Generalization and Complementary Neural Networks for Multiclass Classification. *International Conference on Electrical, Computer, and Energy Technologies, ICECET 2022*. <https://doi.org/10.1109/ICECET55527.2022.9873449>
- Ortega, J., Koppel, M., & Argamon, S. (2001). Arbitrating Among Competing Classifiers Using Learned Referees. *Knowledge and Information Systems 2001 3:4*, 3(4), 470–490. <https://doi.org/10.1007/PL00011679>
- Rudin, C. (2018). Stop Explaining Black Box Machine Learning Models for High Stakes Decisions and Use Interpretable Models Instead. *Nature Machine Intelligence*, 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
- Samek, W., & Müller, K.-R. (2019). Towards Explainable Artificial Intelligence. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11700 LNCS, 5–22. https://doi.org/10.1007/978-3-030-28954-6_1
- Schroff, F., Kalenichenko, D., & Philbin, J. (2015). FaceNet: A Unified Embedding for Face Recognition and Clustering. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 07-12-June-2015*, 815–823. <https://doi.org/10.1109/cvpr.2015.7298682>

- Seewald, A. K., & Fürnkranz, J. (2001). An evaluation of grading classifiers. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2189, 115–124. https://doi.org/10.1007/3-540-44816-0_12
- Taori, R., Dave, A., Shankar, V., Carlini, N., Recht, B., & Schmidt, L. (2020). Measuring Robustness to Natural Distribution Shifts in Image Classification. *Advances in Neural Information Processing Systems, 2020-December*.
- Ting, K. M., & Witten, I. H. (2011). Issues in Stacked Generalization. *Journal Of Artificial Intelligence Research*, 10, 271–289. <https://doi.org/10.1613/jair.594>
- Tyukin, I. Y., Gorban, A. N., Alkhudaydi, M. H., & Zhou, Q. (2021). Demystification of few-shot and one-shot learning. *International joint conference on neural networks (IJCNN)*.
- Vinyals, O., Blundell, C., Lillicrap, T., Kavukcuoglu, K., & Wierstra, D. (2016). Matching Networks for One Shot Learning. *Advances in Neural Information Processing Systems*, 3637–3645.
- Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1. <https://doi.org/10.1109/CVPR.2001.990517>
- Wilson, H. R., & Cowan, J. D. (1972). Excitatory and inhibitory interactions in localized populations of model neurons. *Biophysical journal*, 12(1), 1–24. [https://doi.org/10.1016/S0006-3495\(72\)86068-5](https://doi.org/10.1016/S0006-3495(72)86068-5)
- Yang, X. S., He, X. S., & Fan, Q. W. (2020). Mathematical framework for algorithm analysis. *Nature-Inspired Computation and Swarm Intelligence: Algorithms, Theory and Applications*, 89–108. <https://doi.org/10.1016/B978-0-12-819714-1.00017-8>

СПИСОК ПУБЛИКАЦИЙ ПО ТЕМЕ ДИССЕРТАЦИИ

Статьи в научных журналах из списка изданий, рекомендованных ВАК, индексируемых в базах данных Web of Science, Scopus, RSCI:

[A1] Sokolov M. E., **Kovalchuk A. V.**, Tel'nykh A. A., Bellyustin N. S., Nuidel I. V., Yakhno V. G. “Face recognition using «lateral inhibition» function features” // *Optical Memory and Neural Networks (Information Optics)*. 2009. № 1 (18). С. 1–5, IF=1.0 (Scopus), Объем – 2 п. л.

[A2] Klinshov V. V., **Kovalchuk A. V.**, Franović I., Perc M., Svetec M. “Rate chaos and memory lifetime in spiking neural networks” // *Chaos, Solitons & Fractals*. 2022. (158). IF=5.4 (WOS, 5-лет), Объем – 0.7 п. л.

[A3] Klinshov V. V., **Kovalchuk A. V.**, Soloviev I. A., Maslennikov O. V., Franović I., Perc M. “*Extending dynamic memory of spiking neuron networks*” // *Chaos, Solitons & Fractals*. 2024. (182). IF=5.4 (WOS, 5-лет), Объем – 1.5 п. л.

[A4] Беллюстин Н.С., Тельных А.А., Разумов В.А., Шемагина О.В., **Ковальчук А.В.**, Яхно В.Г.. “*Применение генетических алгоритмов для уточнения местоположения лица человека на видеоизображении*” // *Нейрокомпьютеры: Разработка, Применение*, 11, (2007), Объем – 0.7 п. л.

[A5] **Kovalchuk A. V.**, Bellyustin N. S. “*Online learning algorithm of kernel-based ternary classifiers using support vectors*” // *Optical Memory and Neural Networks (Information Optics)*, (2013) , 22(3), 193–205, IF=1.0 (Scopus), Объем – 10.5 п. л.

[A6] **Ковальчук А. В.**, Беллюстин Н. С. “*Алгоритм классификации потоковых сигналов на основе последовательной машины опорных векторов*” // ПНД. Известия “ВУЗ”. (2015), 23(5), 62–79, IF=0.371 (RSCI, 5 лет), Объем – 5.9 п. л.

[A7] Bellustin N., Kalafati Y., **Kovalchuk A.**, Telnykh A., Shemagina O., Yakhno V., Vaish A., Sharma, P. “*Instant Human Face Attributes Recognition System*” // *International Journal of Advanced Computer Science and Applications, Special Issue on Artificial Intelligence*. 2011. № 3 (1). С. 112–120, IF=0.7 (WOS), Объем – 2 п. л.

[A8] Stasenko S. V., **Kovalchuk A. V.**, Eremin E. V., Drugova O. V., Zarechnova N. V., Tsirkova M. M., Permyakov S. A., Parin S. B., Polevaya S. A. “*Using Machine Learning Algorithms to Determine the Post-COVID State of a Person by Their Rhythmogram*” // *Sensors 2023, Vol. 23, Page 5272*, 23(11), (2023), 5272, IF=3.7 (Scopus, 5-лет), Объем – 3.5 п. л.

[A9] Soloviev I., **Kovalchuk A.**, Klinshov V. “*Dynamic convolution for image matching*” // *The European Physical Journal Special Topics*, (2024), 1–9, IF=2.5 (Scopus, 5-лет), Объем – 3 п. л.

[A10] **Kovalchuk A. V.**, Lebedev A. A., Shemagina O. V., Nuidel I. V., Yakhno V. G., Stasenko S. V. Enhancing Cascade Object Detection Accuracy Using Correctors Based on High-Dimensional Feature Separation // *Technologies 2025, Vol. 13, Page 593*. 2025. № 12 (13). С. 593, IF=4.2 (Scopus, 5-лет), Объем – 12 п. л.

Ковальчук Андрей Викторович

Разработка нейроморфных алгоритмов принятия решений в задачах распознавания объектов
на изображении

Автореф. дис. на соискание ученой степени канд. физ.-мат. наук

Подписано в печать __. __. ____ . Заказ № _____

Формат 60×90/16. Усл. печ. л. 1.5. Тираж 100 экз

Типография _____