

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, главный 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 08 июля 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/files/2026/1647/diss-Kovalchuk-1647.pdf>

Автореферат разослан «05» июня 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 биологически вдохновленные подходы. Биоморфное проектирование интеллектуальных систем предполагает использование принципов организации и работы живых систем при создании алгоритмов и архитектур искусственного интеллекта (ИИ). Актуальность используемого подхода обусловлена несколькими обстоятельствами.

Во-первых, традиционные системы распознавания достигают своего предела эффективности на сложных и изменчивых данных (Amodei D., Olah C., Steinhardt J. и др, 2016; Freund Y., Shapire R. E., 1999). В тех случаях, когда условия выходят за рамки предусмотренных (новые виды шума, ранее невиданные классы образов, изменение свойств сенсоров), классические алгоритмы часто оказываются негибкими (Geirhos R., Jacobsen J.-H., Michaelis C. и др, 2023; Hendrycks D., Dietterich T., 2019). Биоморфный же подход, напротив, предполагает адаптивность и устойчивость, свойственные биологическим системам (Izhikevich E. M., 2014). Мозг животных умеет удивительно хорошо справляться с неполными или искаженными данными, дорисовывать недостающую информацию, переносить знания с одного типа задач на другой. Имитация этих свойств – через динамические нейроподобные ячейки, через автоподстройку алгоритмов – открывает путь к новым, более живучим системам распознавания.

Во-вторых, исследуемый нейроморфный подход вносит вклад в концепцию интеллектуальных систем нового поколения, где жёстко детерминистские алгоритмы сменяются на самообучающиеся и саморегулирующиеся (Hadsell R., Rao D., Rusu A. A., Pascanu R., 2020). Если ранее основной упор делался на увеличение глубины нейронных сетей и объёма данных для офлайн-обучения, то теперь все более ценными становятся свойства непрерывной адаптации, пояснимости решений, способности к автономному улучшению без внешнего вмешательства (Rudin C., 2018; Samek W., Müller K.-R., 2019). Причины этого факта кроются в достижении предела возможностей извлечения информации с помощью статистических подходов и моделей. Биоморфная адаптивная система по своей природе не статична, она самонастраивается в процессе функционирования, и при этом её архитектура позволяет интерпретировать, какие именно модули и почему перестраиваются.

Наконец, с инженерной точки зрения, биоморфный подход предоставляет новые возможности оптимизации. Заимствуя принципы из нейробиологии (параллелизм обработки, событийное управление, избыточность и устойчивость к сбоям и т.д. (Bengio Y., Lee D.-H., Bornschein J., Mesnard T., Lin Z., 2015; Gallego G., Delbruck T., Orchard G. и др., 2020), можно

создавать системы распознавания, более экономичные и надежные, например, за счет снижения количества вычислений с помощью адаптивного управления алгоритмами.

Подводя итог, отметим, что актуальность разрабатываемого подхода определяется растущей потребностью в гибких биометрических системах, способных работать в условиях реального мира, с его непредсказуемостью и разнообразием сигналов.

Степень разработанности проблемы

Первые количественные модели биоэлектрической активности появились в работах Ходжкина и Хаксли, открывших путь к описанию распространения импульсов в возбудимых средах (Hodgkin A. L., Huxley A. F., 1952). Их идеи были развиты в популяционных моделях Уилсона–Коуэна и в теориях латерального торможения Амари, объясняющих формирование устойчивых пространственных паттернов в коре мозга (Сбитнев В. И., Драбкин Г. М., 1975; Amari S., 1997; Wilson H. R., Cowan J. D., 1973). Позднее Чуа и Янг предложили клеточные нейронные сети как аппаратную дискретизацию непрерывных нейронных полей (Chua L. O., Yang L., 1988), что дало импульс широкому спектру приложений — от импульсных PCNN-фильтров до обработки изображений и распознавания образов (Johnson J. L., 1994; Ranganath N. S., Kuntimad G., Johnson J. L., 1995). Тем не менее большинство работ сосредоточено либо на теоретической динамике, либо на низкоуровневой фильтрации. Возможности и роль динамических режимов, встроенных в контур классификации в комплексных системах, остается еще слабо изученной.

Традиционные методы качества (FAR/FRR и др.) фиксируют итоговую ошибку, но не позволяют судить о пригодности конкретного примера для данного алгоритма. В ответ на это в работах (Яхно В. Г., 2001) предлагается цикл кодирование – восстановление с анализом невязки как внутреннего сигнала качества. Идея перекликается с автоэнкодерами (Hinton G. E., Salakhutdinov R. R., 2006) и разреженным кодированием (Olshausen B. A., Field D. J., 1997), а также с локальными байесовскими схемами Гельмгольца и мета-обучением (Dayan P., Hinton G. E., Neal R. M., Zemel R. S., 1995). Однако в существующих решениях отсутствуют формальные критерии для автоматического выбора алгоритма предобработки, что и закладывается в настоящей работе.

Механизмы коллективного распознавания и алгоритмы построения экспертных комитетов активно исследовались в работах Растригина (Растригин Л. А., Эренштейн Р. Х., 1981), Мазурова (Мазуров В. Д., 1990), а также в более поздних исследованиях (Jacobs R. A., Jordan M. I., Nowlan S. J., Hinton G. E., 1991; Ortega J., Koppel M., Argamon S., 2001; Ting K., 1997) и (Chan P. K., Stolfo S. J., 1997; Merz C. J., 1997; Prodromidis A. L., Chan P. K., Stolfo S. J., 1999). Принятие окончательного решения здесь осуществляется либо выбором наиболее подходящего

классификатора с помощью заранее заданной меры компетенции, либо с помощью обучаемых правил агрегирования решений коллектива.

Рост применения ИИ в критических областях обострил проблему непредсказуемых сбоях, связанных с нарушением гипотезы независимости и сдвигом распределений выборок (Cucker F., Smale S., 2001; Hastie T., Tibshirani R., Friedman J., Friedman J., 2009). Полное переобучение дорого и может вносить новые ошибки, поэтому развиваются корректоры — внешние модули, обучающиеся на единичных ошибках и локально исправляющие вывод базовой модели (Gorban A. N., Grechuk B., Mirkes E. M., Stasenko S. V., Tyukin I. Y., 2021). Согласно теоремам стохастического разделения, в сверхвысоких размерностях такие ошибки отделимы линейными границами (эффект «благословения размерности») (Gorban A. N., Tyukin I. Y., 2017), а потому корректор можно строить по one/few-shot-схеме.

Цель и задачи исследования

Цель работы — разработка и исследование элементов нейроморфной 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 изображениях и обеспечивают возможность обучения на малых количествах примеров.

Объект и предмет исследования

Объектом исследования являются нейроподобные системы для распознавания визуальных образов и принятия решений.

Предмет исследования — методы оценки качества данных, динамический выбор алгоритма обработки и корректировка решений в нейроморфных системах 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 предложен критерий оценки качества изображения на основе динамики невязки в процессе «кодирование-восстановление», а также показано, что применение адаптивного выбора алгоритма бинаризации с помощью невязки повышает качество распознавания изображений 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 нейроноподобной среды позволяет повысить точность алгоритмов классификации лиц. В работе показано, что использование 40 параллельных нейроноподобных 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 \sim 13% до \sim 9.5% при использовании 4-х дискретных шагов нейроноподобной среды, что соответствует итоговой точности распознавания \sim 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 ($0.92 \rightarrow 0.91$). Для задачи детектирования идентификаторов корректоры по небольшому числу ложных срабатываний (FP) повышают точность с 0.36 до 0.64 при сохранении высокой полноты ($\text{Recall} \approx 0.98$).

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-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 (БСИПРОКО)” 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.

Основное содержание работы

В первой главе (**Использование динамики преобразования изображений в нейроподобных средах в задачах классификации**) рассматривается проблема построения нейроподобных 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 нейроподобной среды) решается задача формализации динамики нейроподобной среды. Рассматривается пара интегро-дифференциальных уравнений для средних активностей возбуждающих u и тормозных v популяций и, опираясь на предположение, что торможение медленнее возбуждения, выполняется упрощение их до однокомпонентного уравнения (1) (Яхно В.Г. и др., 1994).

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

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 ax, ay, b . $W(x, y) = (1 - b \cdot y^2)e^{-ax \cdot x^2 - ay \cdot y^2}$.

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 нейроподобной 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 нейроподобных 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).

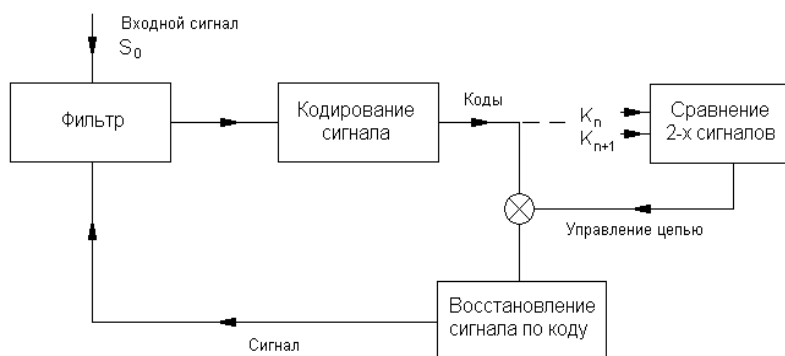


Рисунок 2 — Схема алгоритма анализа фильтров

Рассматриваются два алгоритма предобработки: «активный» неоднородный нейроподобный 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.

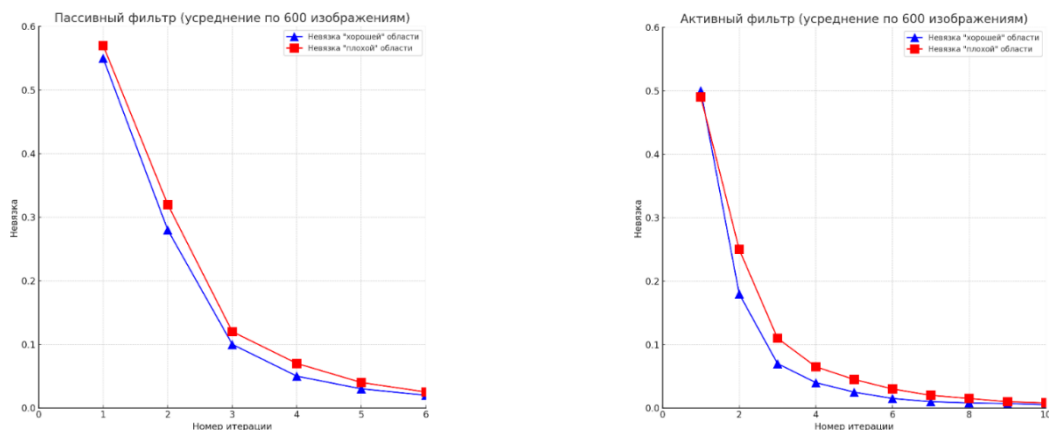


Рисунок 3 — Зависимость средних невязок различных по качеству областей для 600 отпечатков

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 $\theta = \frac{1}{2} \arctan \frac{2 S_{xy}}{S_x + S_y - S_{xy}}$.

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 f_i, f_j измеряется с помощью косинусной метрики $D(f_i, f_j)$ 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 нейророботного 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 $c_i \geq 0, \eta \geq 0$:

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

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:

$$\begin{aligned} \min(W(\alpha) = \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j K_{i,j}) \\ \text{s.t.} \begin{cases} \sum_{v_i: y_i=1} \alpha_i = 1 \\ \sum_{v_i: y_i=-1} \alpha_i = 1 \\ 0 \leq \alpha_i \leq \frac{c_i}{\eta} \end{cases} \end{aligned} \quad (3)$$

, 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 сверток) 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 Q порождает описание e_q опорного примера, а ветвь 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).

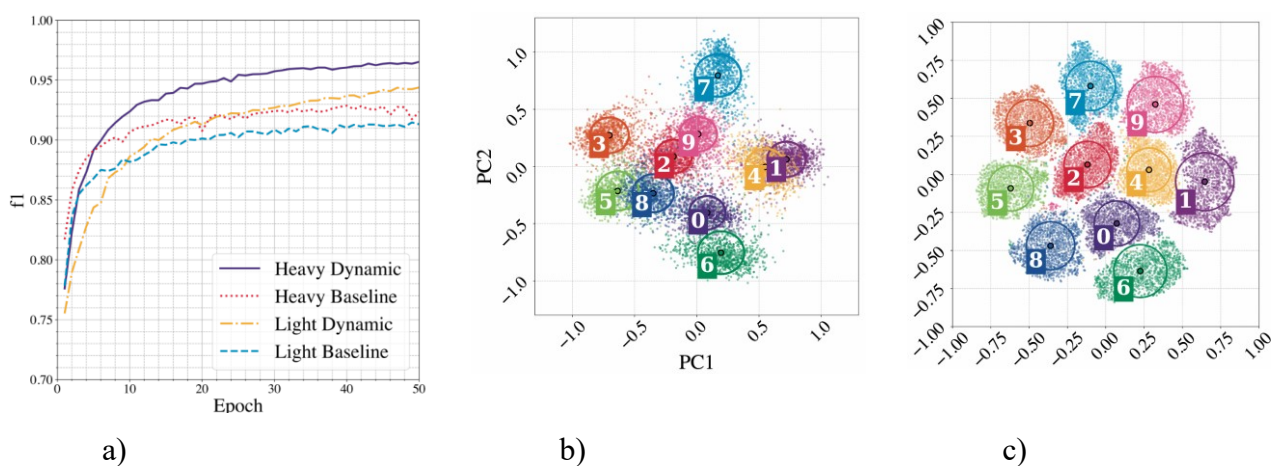


Рисунок 4 — Сравнение характеристик обучения моделей (а) PCA-проекции пространства признаков e_q (b) и проекция tSNE (c).

Дополнительно продемонстрировано, что классы примеров в пространстве признаков образуют компактные и разделимые группы (Рисунок 4 bc), 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.

ВЫВОДЫ

1. Показано, что расширение признакового пространства с помощью серии однородных однокомпонентных нейроподобных сред с различающимися параметрами функции связи типа латеральное торможение, а также использование временной динамики позволяют улучшить качество базового распознающего алгоритма в задаче классификации лиц.

2. Разработан алгоритм фильтрации для бинаризации изображений отпечатков пальцев на основе неоднородной однокомпонентной нейроподобной среды и на собственной базе изображений показано, что качество его изображений выше и его выбор более предпочтителен, чем классический алгоритм нормализации яркости.

3. На примере задачи классификации отпечатков пальцев показано, что адаптивный выбор алгоритма бинаризации на основе анализа динамики невязки изображения отпечатка в процессе “кодирования-восстановления” позволяет улучшать качество распознавания конечного алгоритма.

4. Предложена концепция тернарного классификатора, называемого экспертом, который использует дополнительный ответ для обозначения границы области своей компетенции и введены параметры для оценки качества такого классификатора.

5. Предложен, теоретически и экспериментально обоснован алгоритм M-Adaboost для построения ансамблей тернарных классификаторов методом накачки, который позволяет уменьшить общую ошибку на ~40% на примере детектирования фасадов домов на изображении

6. Разработан алгоритм OnSVM, основанный на принципе максимизации зазора между ответами ансамбля классификаторов, для построения и дообучения экспертного комитета. Эффективность алгоритма продемонстрирована в задачах классификации атрибутов лица человека и на них показано преимущество решения OnSVM перед алгоритмами накачки на 2-6%.

7. Реализованы два подхода к коррекции алгоритмов распознавания - с использованием эффекта “благословения” размерности и с помощью редукции исходного пространства - на примере детектора объектов на изображении и сравнении двух изображений.

8. Разработан механизм “внимания” на основе динамических сверток для задач технического зрения, позволяющий выделять признаки на изображения в зависимости от внешних управляющих сигналов, и показана его эффективность в задаче сравнения двух изображений.

ЗАКЛЮЧЕНИЕ

В диссертации представлено комплексное исследование нейроморфных алгоритмов принятия решений в задачах распознавания объектов на изображении, охватывающее четыре взаимосвязанных уровня обработки визуальной информации: динамическую фильтрацию, адаптивный выбор алгоритмов, построение коллективных моделей и разработку корректоров и механизмов внимания.

В первой главе исследована динамика преобразования изображений в нейроподобных средах. Сформулированы и проанализированы уравнения возбуждающе-тормозной динамики, рассмотрены однородные и неоднородные функции пространственной связи, включая модифицированные латеральные фильтры, позволяющие выделять объекты различных масштабов и ориентаций. Разработана процедура формирования признаков на основе банка нейроподобных сред; экспериментально показано, что временная динамика улучшает разделимость классов в задаче классификации лиц.

Во второй главе предложена адаптивная модель принятия решений, основанная на цикле «кодирование – восстановление», и введено формализованное понятие динамики невязки как индикатора качества изображения. Разработана методика сравнения алгоритмов бинаризации отпечатков пальцев, включающая активный (нейроподобный) и пассивный фильтры. На собственной базе изображений показано, что анализ изменения невязки на первых итерациях позволяет автоматически выбирать алгоритм, наиболее подходящий к локальной структуре данных, что ведёт к повышению качества классификации отпечатков пальцев.

В третьей главе выполнен анализ комитетных методов классификации. Формализовано понятие тернарного классификатора-эксперта как модели с областью компетентности и описаны параметры его качества. Разработан алгоритм M-AdaBoost для построения ансамблей экспертов;

теоретически обоснована его работа в условиях асимметричных ошибок. Экспериментально показано, что M-AdaBoost обеспечивает уменьшение ошибки ансамбля по сравнению с классическими методами бустинга, включая задачу детектирования фасадов зданий.

Разработан алгоритм OnSVM, реализующий принцип максимизации зазора между ответами членов экспертного комитета и обеспечивающий вставку и удаление опорных векторов в потоковом режиме. Показано, что предложенный метод повышает точность классификации атрибутов лица на 2–6% по сравнению с бустинговыми ансамблями.

В четвертой главе исследованы два подхода к построению корректоров: на основе эффекта стохастического разделения в высоких размерностях и на основе редукции пространства признаков. Дополнительно предложен механизм внимания на базе динамических свёрток, позволяющий выбирать релевантные признаки в задачах сравнения изображений.

Перспективным направлением развития является создание альтернативных общепринятым архитектур анализа данных, в которых ядром служит не статическая конвейерная обработка признаков, а опережающее предсказание входного сигнала и его согласование с внутренними моделями. В таких системах распределённая нейроноподобная среда должна формировать многомерное внутреннее представление образа объекта (информационный образ), которое не просто реагирует на вход, а задаёт ожидаемую структуру сигнала и управляет динамикой его обработки.

Особый интерес представляет развитие архитектур с постоянными обратными связями, преднастраивающими входные фильтры на основе текущего внутреннего состояния системы и накопленных представлений. В этом случае блоки «внимания», корректоры и ансамбли экспертов могут рассматриваться как элементы единого предсказательно-корректирующего контура: внутренний образ объекта задаёт ожидания, через обратные связи модулирует параметры фильтрации и распознавания, а невязка между предсказанным и реальным сигналом служит мотивационным сигналом для адаптации.

Работа соответствует паспорту специальности 5.12.4 - «Когнитивное моделирование» в пунктах 7 и 8, п.7. Подходы к детекции и корректировке ошибок систем искусственного интеллекта: математическая, профессиональная и обыденная человеческие точки зрения. Анализ и устранение причин коммуникативных неудач в этой области; п. 8. Искусственные нейронные сети (включая конволюционные и импульсные сети) при моделировании базовых когнитивных функций обучения, распознавания, запоминания фигуративной (образной), процедурной и декларативной информации.

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., Plevaya 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.