

**МИНИСТЕРСТВО ПО РАЗВИТИЮ ИНФОРМАЦИОННЫХ
ТЕХНОЛОГИЙ И КОММУНИКАЦИЙ РЕСПУБЛИКИ УЗБЕКИСТАН**

**НУКУССКИЙ ФИЛИАЛ ТАШКЕНТСКОГО УНИВЕРСИТЕТА
ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ
ИМЕНИ МУХАММАДА АЛЬ-ХОРАЗМИЙ**

ФАКУЛЬТЕТ «КОМПЬЮТЕРНЫЙ ИНЖИНИРИНГ»

КАФЕДРА ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Допуск к защите

Заведующей кафедрой

Турениязова А. _____

« ____ » _____ 2019 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА

**на тему: Разработка нечеткой логической методы для
распознавания биометрических признаков**

Выполнил:

Жумамуратов А.

Научный руководитель:

к.т.н. Айтмуратов Б.Ш.

НУКУС - 2019 г.

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	3
ГЛАВА I. ОСНОВНЫЕ ПОНЯТИЯ И ВИДЫ РЕАЛИЗАЦИИ	7
1.1 Биометрические системы распознавания внешности	7
1.2 Нейронные сети и их реализация	21
1.3. ОБУЧЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ И ЕЁ КЛАССИФИКАЦИИ ПО ИХ АРХИТЕКТУРЕ	26
ГЛАВА II. ОСНОВНЫЕ МЕТОДЫ И АЛГОРИТМЫ РАЗПОЗНОВАНИЯ	32
2.1. ОСНОВНЫЕ МОДЕЛИ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ.....	32
2.2 ЛИНЕЙНЫЕ ОБОЛОЧКИ КАК ОДНОСЛОЙНЫЕ НЕЙРОННЫЕ СЕТИ.....	37
2.3 ЛИНЕЙНЫЕ ОБОЛОЧКИ КЛАССИФИЦИРОВАННЫХ ВЫБОРОК ОБЪЕКТОВ И ИСПОЛЬЗОВАНИЕ НЕЧЕТКОЙ ЛОГИКИ.....	41
2.4 Конечно-сходящийся алгоритм построения кусочно-линейного КЛАССИФИКАТОРА	42
ГЛАВА III. СОЗДАНИЕ ПРОГРАММНОГО КОМПЛЕКСА	48
3.1. ОПИСАНИЕ ПРОГРАММНОГО КОМПЛЕКСА РАСПОЗНАВАНИИ БИОМЕТРИЧЕСКИХ ПРИЗНАКОВ	48
3.2 Проведение вычислительного эксперимента.....	52
ЗАКЛЮЧЕНИЕ.....	56
СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ.....	58

ВВЕДЕНИЕ

Развитие информационных технологий стимулировало развитие различных областей ее применения. Экспоненциальный рост объемов информации и необходимость оперативно реагировать в любых ситуациях потребовали поиска адекватных путей решения возникающих проблем. Эффективнейшим из них является путь интеллектуализации информационных технологий [5].

Под интеллектуальными информационными технологиями (ИИТ) обычно понимают такие информационные технологии, в которых предусмотрены следующие возможности:

- наличие баз знаний, отражающих опыт конкретных людей, групп, обществ, человечества в целом, в решении творческих задач в выделенных сферах деятельности, традиционно считавшихся прерогативой интеллекта человека (например, такие плохо формализуемые задачи, как принятие решений, проектирование, извлечение смысла, объяснение, обучение и т. п.);
- наличие моделей мышления на основе баз знаний: правил и логических выводов; аргументации и рассуждения; распознавания и классификации ситуаций; обобщения и понимания и т. п.;
- способность формировать вполне четкие решения на основе нечетких, нестрогих, неполных, недоопределенных данных;
- способность объяснять выводы и решения, то есть наличие механизма объяснений;
- способность к обучению, переобучению и, следовательно, к развитию.

В настоящее время ИИТ подошли к принципиально новому этапу своего развития. Так, за последние 10 лет существенно расширились возможности ИИТ за счет разработки новых типов логических моделей, появления новых теорий и представлений. «Узловыми» точками в развитии ИИТ считаются [4]:

переход от логического вывода к моделям аргументации и рассуждения;

поиск релевантных знаний и порождение объяснений;
понимание и синтез текстов;
когнитивная графика, то есть графическое и образное представление знаний;
мультиагентные системы;
интеллектуальные сетевые модели;
вычисления, основанные на нечеткой логике, нейронных сетях, генетических алгоритмах, вероятностных вычислениях (реализуемых в различных комбинациях друг с другом и с экспертными системами);
проблема метазнаний.

На сегодняшний день существует значительное число разнообразных моделей искусственных нейронных сетей. Все они отличаются алгоритмами поведения отдельных нейронов и принципами построения топологии связей. Несмотря на относительно благополучное состояние в области разработки различных математических моделей нейронных сетей, имеет место дефицит в области реализаций этих моделей, как на параллельных, так и на последовательных вычислительных системах. Большинство моделей нейронных сетей обладают значительным сходством [3-5].

Искусственные нейронные сети получают все большее распространение за счет следующих факторов:

искусственные нейронные сети способны решать трудно формализуемые (или не формализуемые задачи);

искусственным нейронным сетям присущ параллельный принцип работы, что очень важно при обработке больших объемов данных, особенно мультимедийных (изображение, звук, видео);

исследования в области искусственных нейронных сетей в восьмидесятые годы прошлого века дали успешные результаты, существенно расширившие область применения нейронных сетей.

Каждый раз исследователь, решивший использовать для решения той или иной задачи технологии искусственных нейронных сетей (НС),

сталкивается с вопросом об архитектуре нейронной сети. В большинстве случаев основной метод подбора структуры НС – метод проб и ошибок, который, разумеется, не может гарантировать оптимального решения.

Конструктивные подходы выбора топологии НС, описанные в литературе (Миркес 1999, Степанов 2000, Freeman 1991), сводятся в основном к двум алгоритмам. Первый из них заключается в том, что изначально исследователь задает сложную структуру НС, в которой нейронов и связей между нейронами с избытком хватает для решения конкретной задачи. После того, как НС настроилась на решение задачи, структура НС упрощается. Примером данного метода может служить метод контрастирования (Миркес 1999). Другой подход придерживается обратной идеи. Изначально сеть задается простой, и при необходимости (если сеть плохо решает задачу) добавляются нейроны и связи. Оба этих метода по сути дела являются локальным спуском в пространстве структур НС [6,12].

В выпускной квалификационной работе изучаются вопросы разработки нейроэкспертной системы на основе однослойных нейронных сетей.

Целью данной работы является Изучение методы распознавания образов и искусственного интеллекта с помощью нечеткой логики.

Для достижения цели выполняется следующие:

1. изучить основные понятия распознавания и существующие методы распознавания;
2. изучить о представлении в нейронных сетях;
3. Использование нейронных алгоритмов для распознавания;
4. Создать программное обеспечение один из объектно-ориентированным языке и провести вычислительный эксперимент.

Структура работы.

Данная ВКР состоит из введения трех глав заключения и списка использованной литературы.

Во введении излагается актуальность исследуемой тематики. В первой главе приведены теоретические основные понятия. В данной главе даётся основные понятия и определения нейронных сетей и их реализация. Приведены важнейшие свойства биологических нейронных сетей и подходы к их созданию. Приведено обучение НС и её классификация по их архитектуре. Описаны основные типы правил обучения. А также изучаются основные модели ИНС: однослойная НС, многослойные сети прямого распространения, многослойный перцептрон, RBF-сети, самоорганизующиеся карты Кохонена, сеть Хопфилда.

Во второй главе приведено описание линейных оболочек через однослойные нейронные сети. А также изучаются линейные оболочки классифицированных выборок объектов.

В третьей главе проведены графическое представление метода линейных оболочек, оптимизация линейных оболочек. В данной главе приведен программное обеспечение на базе метода линейных оболочек. Комплекс программ реализован на персональных компьютерах в операционной системе WINDOWS с помощью инструментальной системы DELPHI 7 и рассчитан на пользователей, являющихся экспертами в своей предметной области. В заключении приведены основные результаты ВКР.

В конце работы приводится список использованной литературы.

ГЛАВА I. ОСНОВНЫЕ ПОНЯТИЯ И ВИДЫ РЕАЛИЗАЦИИ

1.1 Биометрические системы распознавания внешности

Биометрические признаки — это четкие, индивидуальные, биологически обусловленные характеристики каждого человека. В принципе не существует двух людей с одинаковыми биометрическими признаками. Примерами биометрических методов идентификации могут служить анализ отпечатков пальцев, геометрической формы рук, узора радужной оболочки или сетчатки глаз, расположения кровеносных сосудов, термического образа, лица, голоса, динамики подписи, ритма работы на клавиатуре и т. д. Стоит отметить, что все они очень сильно зависят от целевой установки и области применения. На сегодня только три биометрических метода уже доказали свою практичность: распознавание по отпечаткам пальцев, радужной оболочке или сетчатке глаз и по чертам лица.

Еще не так давно системы, использующие биометрические методы идентификации, можно было встретить только в научно-фантастических книгах или фильмах. Современная биометрия началась фактически с применений в целях контроля доступа в середине 70-х годов прошедшего столетия. Первые биометрические системы предоставляли довольно высокую степень безопасности только за счет высокой стоимости входящих в них биометрических устройств. Появление в последние годы недорогих микропроцессоров и передовой электронной техники для работы с изображением намного снизило стоимость и увеличило точность биометрических устройств.

Не секрет, что управление работой организации во многом сводится к предотвращению причин, препятствующих выполнению ее функций. Одна из таких причин — нарушение полномочий доступа на территории объектов или к источникам конфиденциальной информации и вычислительным ресурсам организации. Чтобы разграничить доступ сотрудников и клиентов

организации на ее объекты или к информации, представляющей определенную значимость, существуют специальные автоматизированные системы. Сегодня многие учреждения частично или полностью используют в подобных системах биометрию.

Вообще говоря, любая система контроля доступа основана на идентификации или аутентификации абонентов (или групп абонентов) этой системы. Как уже отмечалось, существует ограниченное, хотя и достаточно большое количество характерных свойств и признаков определенной личности, которые можно использовать для ее идентификации. Цель любой системы контроля доступа заключается в том, чтобы предоставить людям, имеющим соответствующие полномочия, возможность прохода в определенные зоны. Как правило, этого можно достичь только путем применения биометрических устройств.

Основная функция любого биометрического устройства — распознавание личности. Контроль доступа требует не только идентификации человека; система может также отпирать дверь, разрешать или запрещать доступ в зависимости от времени суток и, при необходимости, приводить в действие сигнал тревоги. Биометрическая технология может осуществлять эти задачи несколькими способами.

По сравнению с традиционными биометрические методы идентификации личности имеют ряд преимуществ, а именно:

- биометрические признаки очень трудно фальсифицировать;
- в силу уникальности биометрических признаков достоверность идентификации очень высока;
- биометрический идентификатор нельзя забыть, как пароль, или потерять, как пластиковую карточку.

Характеристики биометрических систем

Наиболее важный фактор успеха биометрической системы — это ее одобрение пользователями. Оно, в свою очередь, зависит от нескольких факторов. Во-первых, устройство не должно вызывать у пользователя чувства

тревоги или дискомфорта. Возможно, это субъективный показатель, но он весьма важен для понимания проблем пользователей. Если люди боятся использовать устройство, то, скорее всего, они будут обращаться с ним неправильно и в результате не получат доступа. Во-вторых, биометрическое устройство должно быть простым в использовании. Клиентам нравятся устройства, с которыми просто работать. В-третьих, биометрическое устройство должно функционировать четко и точно. Если биометрическая система работает так, как надо, она делает две вещи: не позволяет войти «плохим» и разрешает вход «хорошим». Однако ни одно устройство не может быть абсолютно совершенным, и биометрические системы — не исключение, они могут допустить ошибку: впустить «плохих» или закрыть вход для «хороших». Возможность таких ошибок выражается уровнем ложных приемов и ложных отказов.

Показателями надежности биометрических систем могут служить вероятности ошибок первого и второго рода. Ошибки первого рода определяют вероятность ложного отказа (FRR, False Rejection Rate) и возникают при отказе в доступе легальному пользователю системы. Ошибки же второго рода показывают вероятность ложного допуска (FAR, False Acceptance Rate) и появляются при предоставлении доступа постороннему лицу. FRR и FAR связаны обратной зависимостью. Современные биометрические системы имеют очень большой разброс этих характеристик. Биометрическую систему также можно характеризовать уровнем равной вероятности ошибок первого и второго рода (EER, Equal Error Rates) — точкой, в которой вероятность ошибки первого рода равна вероятности ошибки второго рода. На основании EER можно делать выводы об относительных достоинствах и недостатках разных биометрических методов. Чем ниже уровень EER, тем лучше. Например, уровень в один процент означает, что из 100 попыток опознания человек будет ошибочно отвергнут или ошибочно узнан один раз.

Еще один параметр, о котором стоит задуматься при выборе и установке биометрической системы, — ее пропускная способность. По сути, это время, которое требуется человеку для взаимодействия с данным устройством.

Выбор системы контроля доступа — сложный вопрос. При этом требуется проанализировать характер возможных угроз, разработать модель потенциального «шпиона», определить требования к системе безопасности, изучить рынок предлагаемых систем и т. д. Делая выбор системы контроля доступа на основе биометрических методов идентификации личности, нужно быть осторожным с официально публикуемыми данными об уровнях ошибок. Поскольку они определяются методикой и длительностью тестирования, объемом и характером статистических выборок, а применение биометрических устройств может быть весьма разнообразным, то уровни ошибок от реализации к реализации могут меняться в широких пределах.

Помимо декларируемой надежности и цены необходимо учитывать и такие факторы, как совместимость с существующими системами. Рассматривая конкретную систему контроля доступа к вычислительным ресурсам, нужно убедиться в корректности ее работы с имеющимся оборудованием и ПО, а также проанализировать возможность ее интеграции в уже установленные системы защиты.

Кроме того, надо понять, насколько приемлема система для пользователей, которые будут с ней сталкиваться. Под приемлемостью для пользователя в данном случае понимается его отношение к процессу аутентификации или идентификации. Так, процедура взятия отпечатков пальцев может рассматриваться как нечто унижающее, вызывая ассоциации с применением ее в криминалистике. С этой точки зрения идентификация по параметрам руки выглядит более безобидной. Немаловажный параметр практически любой системы — скорость проведения регистрации и верификации абонентов. Большинство предлагаемых систем выполняют аутентификацию и/или идентификацию практически в реальном масштабе времени. Продолжительность регистрации нового абонента от нескольких

десятков секунд до нескольких минут также приемлема, поскольку эта процедура выполняется только однажды.

Современная систем должна быть многоуровневой и представлять собой комплекс технических и административных решений. Наилучшие результаты получаются, когда опознание личности проводится и биометрическими, и традиционными методами. Чем больше данных, тем больше потенциал для развития систем безопасности, и биометрия здесь оказывается оптимальным решением.

В соответствии с ростом числа приложений, где возможно применение биометрических технологий, растет и объем производства биометрических устройств, что позволит существенно снизить цены на системы такого рода уже в ближайшее время. Кроме того, уменьшению их стоимости способствует и снижение цен на компьютерные услуги.

Распознавание лица

Один из новых способов, завоевавший значительную популярность, — распознавание облика. Люди легко узнают друг друга по лицам, но автоматизировать подобное опознание вовсе не легко. Большая часть работ в этой области была посвящена тому, чтобы получить изображение при помощи фотографии или видеокамеры. Только в США и Германии над технологиями опознавания по чертам лица работали несколько десятков компаний, которым были выделены правительственные гранты. Первоначально разработки предназначались для спецслужб, но со временем результаты этих исследований разрешили применять и в коммерческих целях. В результате на рынке появилось некоторое количество систем распознавания (правда, не все из них оказались пригодными на практике).

Технология распознавания позволяет сканировать человеческие лица в режиме реального времени. Видеокамера подключается к терминалу, и система определяет, соответствует ли лицо в кадре фотографий из базы данных. Принцип работы системы распознавания по лицу основан на специальном алгоритме оцифровки изображений, позволяющем выбирать на

кадрах лицо человека и оцифровывать его, выделяя большое количество параметров (так называемые базовые точки — скулы, цвет и форма глаз, ширина переносицы, губ и т. д.). В результате каждое лицо описывается уникальным набором параметров, причем с некоторым избытком. Для идентификации с высокой степенью точности требуется не более 40 характеристик, тогда как система обычно задает около 2 тыс. оценочных параметров. Это обеспечивает высокую надежность опознавания независимо от поворота головы, наличия очков, косметики. В принципе для надежного опознавания человека программе достаточно всего несколько десятков базовых точек. Фотография и цифровое описание лица заносятся в базу данных, с которой впоследствии сравнивается распознаваемое лицо.

Вообще говоря, на рынке систем автоматического распознавания лица господствуют два типа систем. Первые базируются на статистическом методе: на основе набора биометрических данных и их обработки формируется некий электронный образец как уникальное в своем роде число, относящееся к конкретной личности. Такой тип систем достаточно широко распространен, но идентификация с их помощью, как правило, не очень надежна.

Методы, относящиеся ко второму типу, близки к человеческому видению проблемы распознавания. Система самообучаема и робастна в отношении изменчивости лица — таких факторов, как возраст, наличие усов или бороды, очков. Для идентификации и верификации можно использовать и старые фотографии. Технология в принципе позволяет работать даже с рентгеновскими снимками. Приемлемость такого принципа пока не удалось превзойти, так как он моделирует «человеческий подход»: один человек разглядывает лицо другого, чтобы его идентифицировать. Как и анализ личной подписи, определение идентичности по фотографии в паспорте относят к наиболее доступному и признанному методу распознавания личности.

Для защиты данных и информации также предпочтительно использовать системы распознавания лица. Кроме того, контроль лица

выполняется с определенным комфортом: он бесконтактен и обеспечивает удобную и быструю обработку данных.

В качестве единственного биометрического приложения метод распознавания лица можно использовать в разных областях. Помимо сравнения с содержанием баз данных цифровых фото и классического контроля доступа (верификации), с помощью этого метода можно бесконтактно распознавать людей и в негрупповых сценариях. Распознавание лица неэффективно только тогда, когда значительные изменения, например, вследствие несчастного случая, делают невозможным даже человеческую визуализацию.

Использование любого биометрического признака имеет свои преимущества и недостатки. Поэтому ни в коем случае нельзя ожидать, что какой-либо отдельный метод добьется приоритетного признания. Большинство экспертов сходятся в том, что пользователь в зависимости от постановки задачи должен сам сделать выбор между тремя методами распознавания: по отпечаткам пальцев, радужной оболочке глаза или лицу.

В отличие от других биометрических технологий (идентификация по отпечаткам пальцев, радужной оболочке глаза или по голосу) система распознавания по чертам лица не требует непосредственного контакта с человеком, личность которого устанавливают. Не нужно просить человека оставлять отпечатки пальцев, смотреть в объектив или произносить какие-то слова.



Идентификация персоны по лицу на пункте контроля доступа.

Распознавание лица — это, пожалуй, единственный биометрический способ идентификации персон, для применения которого не требуется специальная техника. Именно в лицо мы узнаем родных и близких, а не прибегаем, скажем, к сличению отпечатков пальцев или радужной оболочки. Кроме того, использование фотографии для удостоверения личности владельца — традиционная рутина уже на протяжении нескольких десятилетий. Наверное, каждому знаком процесс предъявления пропуска вахтеру и внимательный взгляд в лицо посетителя, а компьютер лишь автоматизирует процедуру. Эти факторы в значительной степени упрощают внедрение распознавания лица в современные комплексы безопасности, позволяя избежать конфликта с пользователями и риска быть отвергнутыми. Метод распознавания лица — это единственный биометрический способ идентификации персон и с точки зрения многоцелевого применения. В отличие от других биометрических методов, применимых только для контроля доступа или сравнения в базе данных, технология распознавания образа позволяет детектировать (находить) лицо человека в видеокадре, либо для последующего сравнения с базой данных, либо наоборот, чтобы скрыть его от случайного зрителя. Благодаря встроенным инфракрасным излучателям компьютер легко распознает каучуковую маску как муляж, имитирующий лицо. Наблюдаемый объект должен иметь человеческую кожу, естественную мимику и быть «живым», в противном случае срабатывает звуковой сигнал предупреждения.

Распознавание по чертам лица происходит на расстоянии, незаметно, не привлекая внимания человека. С точки зрения служб безопасности и спецслужб это несомненное преимущество. Правозащитники же полагают, что применение подобных технологий нарушает право человека на анонимность. Впрочем, производители технологий распознавания подготовились к протестам и позаботились о правах личности. Если система не находит совпадений с лицами в базе данных, то в ее памяти не остается никакой информации о человеке, который появлялся перед камерой.

Производители также заявляют, что в системах применяются стандартные камеры видеонаблюдения. Общество давно привыкло к этим камерам, использование которых уже регулируется законодательством. В развитых странах в магазинах принято предупреждать о том, что в помещении ведется наблюдение. А есть ли терминал для опознавания в кабинете службы безопасности или нет — какое, мол, до этого дело законопослушному посетителю.

Основные потребители подобных биометрических систем — не только службы безопасности (предприятий, аэропортов, супермаркетов, казино, банков), но и государственные учреждения (министерства, силовые ведомства, специальные структуры).



Здесь проходят контроль австрийские парламентарии (вход в здание парламента в Вене).

В России технология распознавания человека по лицу появилась недавно, но интерес к ней довольно высок. В частности, системами распознавания занимается инженерная корпорация «Солинг» (<http://www.soling.ru>). Многолетний опыт работы на рынке позволяет успешно адаптировать зарубежное оборудование к российским условиям и требованиям, внедрять новые технологии в создаваемые и уже существующие комплексы безопасности. Готовые, проработанные решения существуют в настоящее время на базе оборудования ZN Vision Technologies AG (Германия).

Технология и решения ZN Vision Technologies

Компания была основана в 1993 г . на базе Рурского университета (Бохум, Германия) и Южно-Калифорнийского университета (Лос-Анджелес, США). С того времени Центр нейроинформатики (Zentrum für Neuroinformatik) превратился в фирму ZN Vision Technologies AG (<http://www.zn-ag.com>). В 1996 г ., через три года после основания, компания привлекла к себе внимание общественности, получив премию немецкой промышленности за инновации. Последующие награды тоже не заставили себя ждать. В 1998 г . профессор-инженер Вернер фон Зеелен и профессор Кристоф фон дер Мальсбург были награждены премией Карла Хайнца Беккуртса, а в 2000 г . фон дер Мальсбург был отмечен Керберовской европейской научной премией.

ZN Vision Technologies, имеющая в штате всего несколько десятков сотрудников, — одна из ведущих компаний в области автоматического наблюдения. Способность системы наблюдения обучить компьютеры интерпретировать и понимать изображения и события, снятые обычными камерами, базируется на математических методах, которые воспроизводят зрительное восприятие, свойственное человеку. ZN Vision Technologies использует технологию искусственного наблюдения там, где нужно «автоматизировать» анализ увиденного, чтобы повысить эффективность и качество. Сегодня эта технология используется не только в охранных системах, но и в медицинских технологиях. Используя патентованный метод распознавания человека по чертам лица, компания создает продукты, предназначенные для охраны зданий, для поиска людей в фотоархивах и для «разумного» видеонаблюдения. В области здравоохранения полученный врачами фотоматериал обрабатывается и автоматически сравнивается с базой фотоданных по изучаемой проблеме, например, с целью диагностики раковых заболеваний кожи. В сотрудничестве с более чем 15 исследовательскими институтами и 30 известными компаниями ZN Vision Technologies разрабатывает новые продукты в области фотографии, контроля качества в

промышленности, в области автомобильной индустрии, маркетинга, продвижения продаж и увеличения изображений.

На сегодняшний день компания — признанный технологический лидер в разработке систем безопасности. На разработку новых технологий она потратила более 500 человеко-лет и более 30 млн евро. Кроме этого, ZN Vision Technologies постоянно занимается поиском новых сфер применения технологии и работает над расширением возможностей ее практического применения. Технологическое лидерство ZN Vision подтверждено многочисленными национальными и международными патентами и сотрудничеством с ведущими исследовательскими институтами и компаниями. В их число входят, например, фирмы Kaba, Interflex и Государственная типография, занимающие ключевые позиции в области интеграции систем безопасности.

Основываясь на технологии системного наблюдения, ZN Security (подразделение компании ZN Vision Technologies AG), предлагает продукты для автоматической идентификации и верификации людей. Разработанные компанией системы ZN-Face, ZN-Phantomas и ZN SmartEye выступают как основные составляющие при решении задач контроля доступа и аналитического видеонаблюдения.

ZN-Face



Консоль системы ZN-Face.

Система ZN-Face сочетает в себе новейшие компьютерные разработки с системой контроля доступа, основанной на автоматическом распознавании

лиц. Она не только предлагает максимально возможную защиту зон безопасности, например, в банках, на промышленных и военных объектах, в аэропортах и на электростанциях, но может быть использована для любого ограничения доступа, например, на проходных фитнес-студий, клубов и т. д. Системе известны лица всех владельцев магнитных или чип-карточек. ZN-камера делает снимок человека, стоящего на рубеже контроля, и проверяет его в считанные доли секунды. Люди, системе незнакомые, доступа не получают. Специально разработанный модуль оптического фильтра и функция контроля за живым лицом предотвращает любую попытку обмана путем применения фотографий или масок. Система записывает все события, происходящие на контролируемом объекте, а работник службы безопасности в любое время имеет доступ ко всем данным и результатам идентификации.

С 1996 г. создавались различные версии системы, в настоящее время разработано третье поколение — ZN-Face III, в виде как стандартной системы, так и адаптируемой к специальным требованиям заказчика (например, для одного и для неограниченного количества пропускных пунктов).

Сегодня система контроля доступа ZN-Face — наиболее продаваемая в Европе. Первоначально разработанная для атомных электростанций, она теперь применяется как европейским отделением корпорации Microsoft в Германии, так и спортивными клубами в Голландии. В свое время германское ведомство информационной безопасности (Bundes amt fur Sicherheit in der Informationstechnologie, BSI) по окончании многопланового тестирования всех имеющихся на рынке биометрических систем признало соответствующими всем требованиям к обеспечению безопасности лишь продукт Iris Scan, основанный на идентификации по роговице глаза, и ZN-Face, основанный на идентификации по чертам лица.

ZN-Phantomas

Это компьютеризованная база фотоданных, которая может автоматически сравнивать и идентифицировать лица. Для сравнения годится фотография, фоторобот, рисунок или кадр, полученный при видеосъемке. ZN-

Phantomas проводит поиск среди сохраненных в памяти изображений, используя систему распознавания лиц, созданную по образцу работы человеческого мозга на базе технологии органического видения. Скорость работы системы позволяет просматривать 10 тыс. изображений за три минуты.

Многочисленные тесты показали, что квота успешной идентификации составляет практически 100% и не снижается при изменении внешности очками, бородой, прической и т. п. либо по причине старения человека. Таким образом, система оказывает действенную помощь подразделениям полиции в их оперативно-розыскной деятельности для идентификации и поимки преступников. Благодаря ZN-Phantomas становится более эффективной работа со свидетелями, так как можно исключить утомительный бессистемный поиск подозреваемого в фототеке. С 1997 г. ZN-Phantomas используется департаментами полиции в Европе и Америке и доказала свою эффективность, вычислив в Калифорнии двойного убийцу в полицейской базе данных путем сравнения с фотороботом. Помимо розыска преступников, система применяется для поиска пропавших людей и опознания жертв.

Стоит отметить, что система может работать со всеми SQL-базами данных, использующими ODBC-протокол (Oracle, Sybase SQL, DB2, Informix).

ZN-SmartEye

Это система видеонаблюдения с функцией идентификации людей, которой требуется всего несколько секунд, чтобы сравнить изображение лица человека с данными, содержащимися в емкой базе данных в «постоянной» памяти системы. Как только наблюдаемый человек идентифицируется с изображением из базы данных, на экране выводится сообщение и может, например, раздаться сигнал тревоги, чтобы офицер безопасности немедленно принял меры к задержанию. В то время как человеческое внимание начинает ослабевать после нескольких минут наблюдения за изображением на мониторе, ZN-SmartEye ведет наблюдение, не зная усталости, 24 часа в сутки. В частности, ZN-SmartEye защищает зоны безопасности и позволяет проводить скрытое наблюдение за посетителями в общественных местах,

аэропортах, железнодорожных вокзалах, складах, магазинах, клубах или на спортивных аренах. Она может предупредить о визите высокопоставленных гостей или дать знать о появлении мошенников в казино или хулиганов на стадионах.

В настоящее время ZN Vision Technologies работает над новыми решениями, в которых применялись бы опробованные алгоритмы нечеткой логики (например, узнавание регистрационных знаков автомобиля). В частности, в сотрудничестве с Государственной типографией компания намерена разработать для крупных корпораций комплексные решения, позволяющие проводить авторизацию доступа или установление личности в большой массе людей быстрым, относительно недорогим и надежным способом.

Практика распознавания

Тот факт, что метод автоматизированного распознавания клиента по лицу уже зарекомендовал себя на практике, не ставится под сомнение. В числе пользователей данной технологии — такие известные «распознаваемые лица», как Deutsche Bank, Европейский центр ядерных исследований (CERN), российский Центробанк, Национальный банк Литвы, корпорации Microsoft и Siemens, Федеральная типография (Германия). Атомные электростанции и сверхсекретные объекты также охраняются с помощью новой технологии. Первая электронная база данных цифровых фотографий с системой автоматического распознавания лица, созданная в ZN Vision Technologies, позволила многочисленным полицейским службам в Германии, Польше и США оптимизировать следственные действия и добиться качественного улучшения мер по розыску преступников. Интеллектуальный современный видеоконтроль гарантирует безопасность и защиту в местах скопления людей, так как позволяет с помощью информацию баз данных обнаружить известных и опасных персон в режиме реального времени.

Основоположник метода

Кристоф фон дер Мальсбург с 17 лет разрабатывал теорию, позволяющую моделировать работу головного мозга. Впрочем, и тогда, когда он уже возглавлял институт в Геттингене, одновременно работая при университете в Лос-Анджелесе в области исследований работы головного мозга, многие коллеги фон дер Мальсбурга не воспринимали его идеи всерьез. Свою теорию ученый хотел доказать, пытаясь «научить» компьютеры видеть. Свой шанс фон дер Мальсбург получил в начале 90-х годов, когда правительство земли Северный Рейн — Вестфалия распределяло научный бюджет по Объединенной Европе. В то время фон дер Мальсбург преподавал в Бохумском университете. Вместе со своим коллегой, профессором Вернером фон Зееленом, он смог начать практические разработки.

Микросхема для распознавания лиц

В компании STMicroelectronics (<http://www.st.com>) разрабатывается интегральная схема, ускоряющая исполнение алгоритмов распознавания лиц. Она содержит программируемый процессор Xtensa 200 МГц компании Tensilica, соединенный с программируемой логической матрицей (ПЛМ). Матрица реализует расширения языка С, на котором программируется Xtensa, используя специальные возможности процессора. Применение расширений позволяет ускорить обработку почти на порядок. ПЛМ также выполняет в микросхеме функции ввода-вывода. Опытный образец интегральной схемы изготовлен с учетом проектных норм 0,18 мкм.

1.2 Нейронные сети и их реализация

Искусственные нейронные сети – совокупность моделей биологических нейронных сетей. Представляют собой сеть элементов – искусственных нейронов – связанных между собой синаптическими соединениями. Сеть

обрабатывает входную информацию и в процессе изменение своего состояния во времени формирует совокупность выходных сигналов. Работа сети состоит в преобразовании входных сигналов во времени, в результате чего меняется внутреннее состояние сети и формируются выходные воздействия. Обычно НС оперирует цифровыми, а не символьными величинами.

Существенную часть в теории нейронных сетей занимают биофизические проблемы. Для построения адекватной математической модели необходимо детально изучить работу биологических нервных клеток и сетей с точки зрения химии, физики, теории информации и синергетики. Должны быть известны ответы на основные вопросы, касающиеся

1. Как работает нервная клетка — биологический нейрон? Необходимо иметь математическую модель, адекватно описывающую информационные процессы в нейроне. Какие свойства нейрона важны при моделировании, а какие — нет?
2. Как передается информация через соединения между нейронами — синапсы? Как меняется проводимость синапса в зависимости от проходящих по нему сигналов?
3. По каким законам нейроны связаны друг с другом в сеть? Откуда нервная клетка знает, с какими соседями должно быть установлено соединение?
4. Как биологические нейронные сети обучаются решать задачи? Как выбираются параметры сети, чтобы давать правильные выходные сигналы? Какой выходной сигнал считается "правильным", а какой — "ошибочным"?

Важнейшие свойства биологических нейросетей:

1. Параллельность обработки информации. Каждый нейрон формирует свой выход только на основе своих входов и собственного внутреннего состояния под воздействием общих механизмов регуляции нервной системы.

2. Способность к полной обработке информации. Все известные человеку задачи решаются нейронными сетями. К этой группе свойств относятся ассоциативность (сеть может восстанавливать полный образ по его части), способность к классификации, обобщению, абстрагированию и множество других. Они до конца не систематизированы.
3. Самоорганизация. В процессе работы биологические НС самостоятельно, под воздействием внешней среды, обучаются решению разнообразных задач. Неизвестно никаких принципиальных ограничений на сложность задач, решаемых биологическими нейронными сетями. Нервная система сама формирует алгоритмы своей деятельности, уточняя и усложняя их в течение жизни. Человек пока не сумел создать систем, обладающих самоорганизацией и самоусложнением. Это свойство НС рождает множество вопросов. Ведь каждая замкнутая система в процессе развития упрощается, деградирует. Следовательно, подвод энергии к нейронной сети имеет принципиальное значение. Почему же среди всех диссипативных (рассеивающих энергию) нелинейных динамических систем только у живых существ, и, в частности, биологических нейросетей проявляется способность к усложнению? Какое принципиальное условие упущено человеком в попытках создать самоусложняющиеся системы?
4. Биологические НС являются аналоговыми системами. Информация поступает в сеть по большому количеству каналов и кодируется по пространственному принципу: вид информации определяется номером нервного волокна, по которому она передается. Амплитуда входного воздействия кодируется плотностью нервных импульсов, передаваемых по волокну.
5. Надежность. Биологические НС обладают фантастической надежностью: выход из строя даже 10% нейронов в нервной системе не прерывает ее работы. По сравнению с последовательными ЭВМ, основанными на

принципах фон-Неймана, где сбой одной ячейки памяти или одного узла в аппаратуре приводит к краху системы.

Существуют два подхода к созданию искусственных нейронных сетей

- 1) *Информационный подход*: безразлично, какие механизмы лежат в основе работы искусственных нейронных сетей, важно лишь, чтобы при решении задач информационные процессы в НС были подобны биологическим;
- 2) *Биологический подход*: при моделировании важно полное биоподобие, и необходимо детально изучать работу биологического нейрона.

Биологический нейрон моделируется как устройство, имеющее несколько входов (дендриты), и один выход (аксон). Каждому входу ставится в соответствие некоторый весовой коэффициент (w), характеризующий пропускную способность канала и оценивающий степень влияния сигнала с этого входа на сигнал на выходе. В зависимости от конкретной реализации, обрабатываемые нейроном сигналы могут быть аналоговыми или цифровыми (1 или 0). В теле нейрона происходит взвешенное суммирование входных возбуждений, и далее это значение является аргументом активационной функции нейрона, один из возможных вариантов которой представлен на рисунке 1.

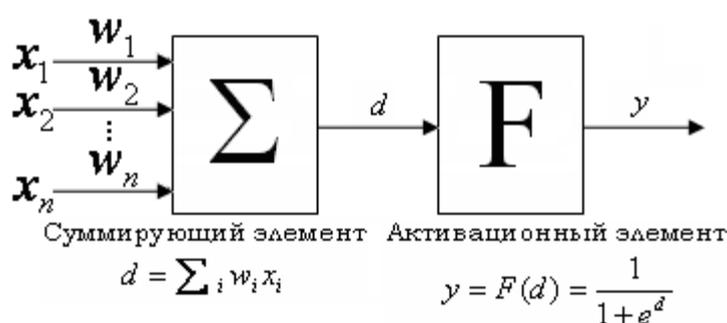


Рис. 1. Искусственный нейрон

Будучи соединенными определенным образом, нейроны образуют нейронную сеть. Работа сети разделяется на обучение и адаптацию. Под обучением понимается процесс адаптации сети к предъявляемым эталонным образцам путем модификации (в соответствии с тем или иным алгоритмом)

весовых коэффициентов связей между нейронами. Заметим, что этот процесс является результатом алгоритма функционирования сети, а не предварительно заложенных в нее знаний человека, как это часто бывает в системах искусственного интеллекта.

Модель формального нейрона. Первой моделью нейрона была модель МакКаллока и Питтса. Авторы предложили использовать бинарный пороговый элемент в качестве модели искусственного нейрона. Этот математический нейрон вычисляет взвешенную сумму n входных сигналов x_j , $j = 1, 2, \dots, n$, и формирует на выходе сигнал величины 1, если эта сумма превышает определенный порог u , и 0 – в противном случае.

В настоящее время под формальным нейроном понимается модель более общего вида. Типичный формальный нейрон производит простейшую операцию - взвешивает значения своих входов со своими же локально хранимыми весами и производит над их суммой нелинейное преобразование:

$$y = f(u), \quad u = w_0 + \sum_i w_i x_i$$

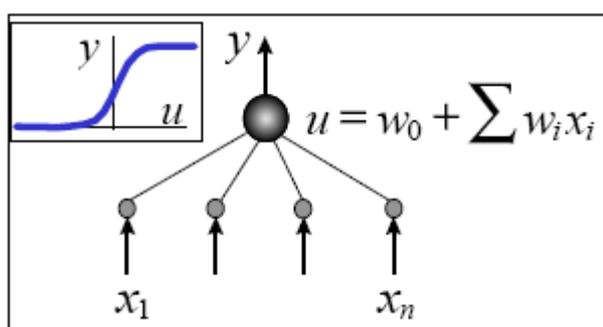


Рис. 2. Модель формального нейрона

Нелинейность выходной функции активации $f(\cdot)$ принципиальна. Если бы нейроны были линейными элементами, то любая последовательность нейронов также производила бы линейное преобразование, и вся нейронная сеть была бы эквивалентна одному нейрону (или одному слою нейронов – в случае нескольких выходов). Нелинейность разрушает линейную

суперпозицию и приводит к тому, что возможности нейронной сети существенно выше возможностей отдельных нейронов.

1.3. Обучение искусственных нейронных сетей и её классификации по их архитектуре

Искусственная нейронная сеть может рассматриваться как направленный граф со взвешенными связями, в котором искусственные нейроны являются узлами. По архитектуре связей искусственные нейронные сети могут быть сгруппированы в два класса (рис.3): сети прямого распространения, в которых графы не имеют петель, и рекуррентные сети, или сети с обратными связями.

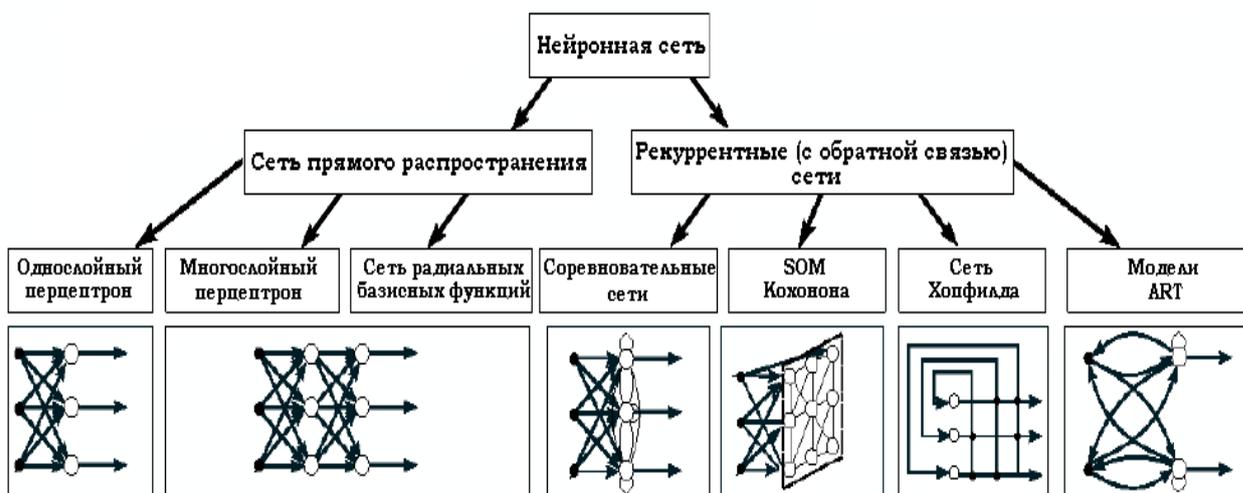


Рис. 3. Систематизация архитектур сетей прямого распространения и рекуррентных (с обратной связью)

В наиболее распространенном семействе сетей первого класса, называемых многослойным перцептроном, нейроны расположены слоями и имеют однонаправленные связи между слоями. На рис.1.2 представлены типовые сети каждого класса. Сети прямого распространения являются статическими в том смысле, что на заданный вход они вырабатывают одну

совокупность выходных значений, не зависящих от предыдущего состояния сети. Рекуррентные сети являются динамическими, так как в силу обратных связей в них модифицируются входы нейронов, что приводит к изменению состояния сети.

Способность к обучению является фундаментальным свойством мозга. В контексте искусственных нейронных сетей процесс обучения может рассматриваться как настройка архитектуры сети и весов связей для эффективного выполнения поставленной задачи. Обычно нейронная сеть должна настроить веса связей по имеющейся обучающей выборке. Функционирование сети улучшается по мере итеративной настройки весовых коэффициентов.

Для конструирования процесса обучения, прежде всего, необходимо иметь модель внешней среды, в которой функционирует нейронная сеть – знать доступную для сети информацию. Эта модель определяет парадигму обучения. Во-вторых, необходимо понять, как модифицировать весовые параметры сети, какие правила обучения управляют процессом настройки. Алгоритм обучения означает процедуру, в которой используются правила обучения для настройки весов.

Существуют три парадигмы обучения: "с учителем", "без учителя" (самообучение) и смешанная. В первом случае нейронная сеть располагает правильными ответами (выходами сети) на каждый входной пример. Веса настраиваются так, чтобы сеть производила ответы как можно более близкие к известным правильным ответам. Усиленный вариант обучения с учителем предполагает, что известна только критическая оценка правильности выхода нейронной сети, но не сами правильные значения выхода. Обучение без учителя не требует знания правильных ответов на каждый пример обучающей выборки. В этом случае раскрывается внутренняя структура данных или корреляции между образцами в системе данных, что позволяет распределить

образцы по категориям. При смешанном обучении часть весов определяется посредством обучения с учителем, в то время как остальная получается с помощью самообучения.

Теория обучения рассматривает три фундаментальных свойства, связанных с обучением по примерам: емкость, сложность образцов и вычислительная сложность. Под емкостью понимается, сколько образцов может запомнить сеть, и какие функции и границы принятия решений могут быть на ней сформированы. Сложность образцов определяет число обучающих примеров, необходимых для достижения способности сети к обобщению. Слишком малое число примеров может вызвать "переобученность" сети, когда она хорошо функционирует на примерах обучающей выборки, но плохо – на тестовых примерах, подчиненных тому же статистическому распределению. Известны 4 основных типа правил обучения:

1. коррекция по ошибке;
2. машина Больцмана;
3. правило Хебба;
4. обучение методом соревнования.

Правило коррекции по ошибке. При обучении с учителем для каждого входного примера задан желаемый выход d . Реальный выход сети u может не совпадать с желаемым. Принцип коррекции по ошибке при обучении состоит в использовании сигнала $(d-u)$ для модификации весов, обеспечивающей постепенное уменьшение ошибки. Обучение имеет место только в случае, когда перцептрон ошибается. Известны различные модификации этого алгоритма обучения [7].

Обучение Больцман. Представляет собой стохастическое правило обучения, которое следует из информационных теоретических и термодинамических принципов [8]. Целью обучения Больцмана является такая настройка весовых коэффициентов, при которой состояния видимых нейронов удовлетворяют желаемому распределению вероятностей. Обучение

Больцмана может рассматриваться как специальный случай коррекции по ошибке, в котором под ошибкой понимается расхождение корреляций состояний в двух режимах.

Правило Хебба. Самым старым обучающим правилом является постулат обучения Хебба [9]. Хебб опирался на следующие нейрофизиологические 15 наблюдения: если нейроны с обеих сторон синапса активизируются одновременно и регулярно, то сила синаптической связи возрастает. Важной особенностью этого правила является то, что изменение синаптического веса зависит только от активности нейронов, которые связаны данным синапсом.

Обучение методом соревнования. В отличие от обучения Хебба, в котором множество выходных нейронов могут возбуждаться одновременно, при соревновательном обучении выходные нейроны соревнуются между собой за активизацию. Это явление известно, как правило "победитель берет все".

Подобное обучение имеет место в биологических нейронных сетях. Обучение посредством соревнования позволяет кластеризовать входные данные: подобные примеры группируются сетью в соответствии с корреляциями и представляются одним элементом. При обучении модифицируются только веса "победившего" нейрона. Эффект этого правила достигается за счет такого изменения сохраненного в сети образца (вектора весов связей победившего нейрона), при котором он становится чуть ближе к входному примеру. Можно заметить, что сеть никогда не перестанет обучаться, если параметр скорости обучения не равен 0. Некоторый входной образец может активизировать другой выходной нейрон на последующих итерациях в процессе обучения. Это ставит вопрос об устойчивости обучающей системы. Система считается устойчивой, если ни один из примеров обучающей выборки не изменяет своей принадлежности к

категории после конечного числа итераций обучающего процесса. Один из способов достижения стабильности состоит в постепенном уменьшении до 0 параметра скорости обучения. Однако это искусственное торможение обучения вызывает другую проблему, называемую пластичностью и связанную со способностью к адаптации к новым данным. Эти особенности обучения методом соревнования известны под названием дилеммы стабильности-пластичности Гроссберга.

В таблице 1 представлены различные алгоритмы обучения и связанные с ними архитектуры сетей (список не является исчерпывающим). В последней колонке перечислены задачи, для которых может быть применен каждый алгоритм. Каждый алгоритм обучения ориентирован на сеть определенной архитектуры и предназначен для ограниченного класса задач

Табл. 1. Известные алгоритмы обучения

Парадигма	Обучающее правило	Архитектура	Алгоритм обучения	Задача
С учителем	Коррекция ошибки	Однослойный и многослойный перцептрон	Алгоритмы обучения перцептрона Обратное распространение Adaline и Madaline	классификация образов; аппроксимация функций; предсказание, управление
	Больцман	Рекуррентная	Алгоритм обучения Больцмана	Классификация образов
	Хебб	Многослойная прямого распространения	Линейный дискриминантный Анализ	анализ данных; классификация образов

	Соревнование	Соревнование	Векторное квантование	Категоризация внутри класса; сжатие данных
		Сеть ART	ARTMap	классификация образов
Без учителя	Коррекция ошибки	Многослойная прямого распространения	Проекция Саммона	Категоризация внутри класса; анализ данных
	Хебб	Прямого распространения или соревнование	Анализ главных компонентов	анализ данных; сжатие данных
		Сеть Хопфилда	Обучение ассоциативной памяти	ассоциативная память
	Соревнование	Соревнование	Векторное квантование	категоризация; сжатие данных
		SOM Кохонена	SOM Кохонена	категоризация; анализ данных
		Сети ART	ART1, ART2	категоризация.
Смешанная	Коррекция ошибки и соревнование	Сеть RBF	Алгоритм обучения RBF	классификация образов; аппроксимация функций; предсказание, управление

ГЛАВА II. ОСНОВНЫЕ МЕТОДЫ И АЛГОРИТМЫ РАЗПОЗНОВАНИЯ

2.1. Основные модели искусственных нейронных сетей

Однослойная нейронная сеть. Хотя один нейрон и способен выполнять процедуры распознавания, сила нейронных вычислений проистекает от соединений нейронов в сетях. Простейшая сеть состоит из группы нейронов, образующих слой, как показано в правой части рис 4. Отметим, что вершины-круги слева служат лишь для распределения входных сигналов. Они не выполняют каких-либо вычислений, и поэтому не будут считаться слоем. По этой причине они обозначены кругами, что бы отличать их от вычисляющих нейронов, обозначенных квадратами. Каждый элемент из множества X отдельным весом соединен с каждым искусственным нейроном. А каждый нейрон выдает взвешенную сумму входов в сеть. В искусственных и биологических сетях многие соединения могут отсутствовать, все соединения показаны в целях общности. Могут иметь место также соединения между выходами и входами элементов в слое.

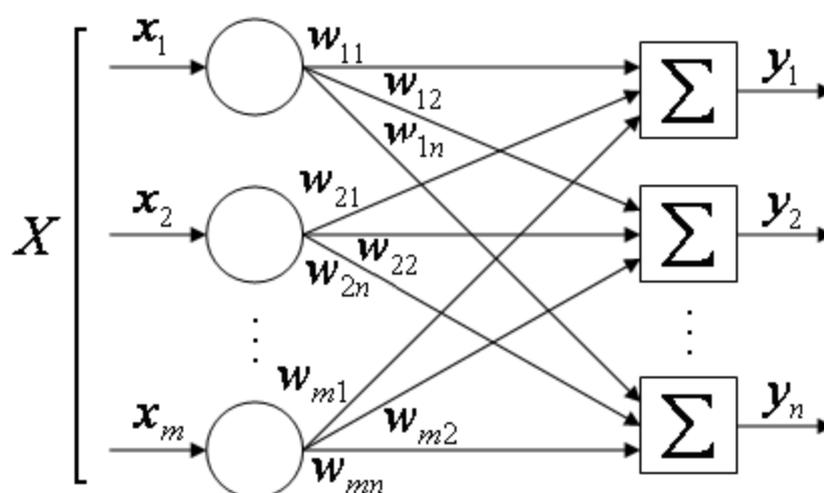


Рис. 4. Однослойная нейронная сеть

Удобно считать веса элементами матрицы W . Матрица имеет m строк и n столбцов, где m – число входов, а n – число нейронов. Например, $w_{2,3}$ – это вес, связывающий третий вход со вторым нейроном. Таким образом, вычисление выходного вектора N , компонентами которого являются выходы y_i ($i=1,n$) нейронов, сводится к матричному умножению $N=XW$, где N и X – векторы-строки.

Многослойные сети прямого распространения. Стандартная L -слойная сеть прямого распространения состоит из слоя входных узлов (будем придерживаться утверждения, что он не включается в сеть в качестве самостоятельного слоя), $(L-1)$ скрытых слоев и выходного слоя, соединенных последовательно в прямом направлении и не содержащих связей между элементами внутри слоя и обратных связей между слоями. На рис.5 приведена структура трехслойной сети.

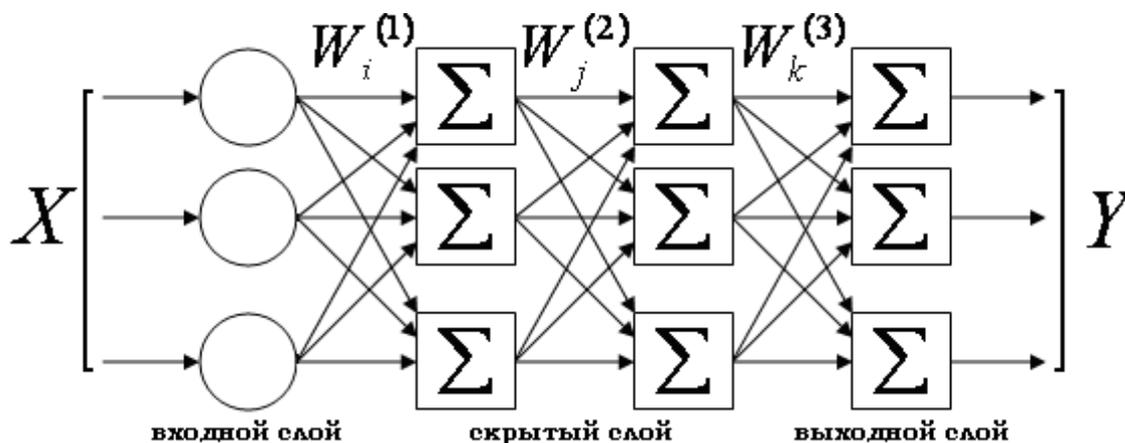


Рис. 5. Типовая архитектура трехслойной сети прямого распространения

Многослойный перцептрон. Наиболее популярный класс многослойных сетей прямого распространения образуют многослойные перцептроны, в которых каждый вычислительный элемент использует пороговую или сигмоидальную функцию активации. Многослойный перцептрон может формировать сколь угодно сложные границы принятия

решения и реализовывать произвольные булевы функции [3]. Разработка алгоритма обратного распространения для определения весов в многослойном перцептроне сделала эти сети наиболее популярными у исследователей и пользователей нейронных сетей. Подавляющее большинство приложений связано именно с применением таких многослойных перцептронов. Как правило, используются именно сети, состоящие из последовательных слоев нейронов. Хотя любую сеть без обратных связей можно представить в виде последовательных слоев, именно наличие многих нейронов в каждом слое позволяет существенно ускорить вычисления используя матричные ускорители.

В немалой степени популярность перцептронов обусловлена широким кругом доступных им задач. В общем виде они решают задачу аппроксимации многомерных функций, т.е. построения многомерного отображения $F : x \Rightarrow y$, обобщающего заданный набор примеров $\{x^a, y^a\}$.

В зависимости от типа выходных переменных (тип входных не имеет решающего значения), аппроксимация функций может принимать вид

- *Классификации* (дискретный набор выходных значений), или
- *Регрессии* (непрерывные выходные значения)

Многие практические задачи распознавания образов, фильтрации шумов, предсказания временных рядов и др. сводится к этим базовым постановкам. Причина популярности перцептронов кроется в том, что для своего круга задач они являются во-первых универсальными, а во-вторых эффективными с точки зрения вычислительной сложности устройствами.

RBF-сети. Сети, использующие радиальные базисные функции (RBF-сети), являются частным случаем двухслойной сети прямого распространения. Каждый элемент скрытого слоя использует в качестве активационной функции радиальную базисную функцию типа гауссовой. Радиальная базисная функция (функция ядра) центрируется в точке, которая определяется

весовым вектором, связанным с нейроном. Как позиция, так и ширина функции ядра должны быть обучены по выборочным образцам. Обычно ядер гораздо меньше, чем обучающих примеров. Каждый выходной элемент вычисляет линейную комбинацию этих радиальных базисных функций. С точки зрения задачи аппроксимации скрытые элементы формируют совокупность функций, которые образуют базисную систему для представления входных примеров в построенном на ней пространстве.

Существуют различные алгоритмы обучения RBF-сетей. Основной алгоритм использует двушаговую стратегию обучения, или смешанное обучение. Он оценивает позицию и ширину ядра с использованием алгоритма кластеризации "без учителя", а затем алгоритм минимизации среднеквадратической ошибки "с учителем" для определения весов связей между скрытым и выходным слоями. Поскольку выходные элементы линейны, применяется неитерационный алгоритм. После получения этого начального приближения используется градиентный спуск для уточнения параметров сети.

Этот смешанный алгоритм обучения RBF-сети сходится гораздо быстрее, чем алгоритм обратного распространения для обучения многослойных перцептронов. Однако RBF-сеть часто содержит слишком большое число скрытых элементов. Это влечет более медленное функционирование RBF-сети, чем многослойного перцептрона. Эффективность (ошибка в зависимости от размера сети) RBF-сети и многослойного перцептрона зависят от решаемой задачи.

Самоорганизующиеся карты Кохонена. Самоорганизующиеся карты Кохонена (SOM) обладают благоприятным свойством сохранения топологии, которое воспроизводит важный аспект карт признаков в коре головного мозга высокоорганизованных животных. В отображении с сохранением топологии близкие входные примеры возбуждают близкие выходные элементы. На

рисунке показана основная архитектура сети SOM Кохонена. По существу она представляет собой двумерный массив элементов, причем каждый элемент связан со всеми n входными узлами.

Такая сеть является специальным случаем сети, обучающейся методом соревнования, в которой определяется пространственная окрестность для каждого выходного элемента. Локальная окрестность может быть квадратом, прямоугольником или окружностью. Начальный размер окрестности часто устанавливается в пределах от $1/2$ до $2/3$ размера сети и сокращается согласно определенному закону (например, по экспоненциально убывающей зависимости). Во время обучения модифицируются все веса, связанные с победителем и его соседними элементами.

Самоорганизующиеся карты Кохонена могут быть использованы для проектирования многомерных данных, аппроксимации плотности и кластеризации. Эта сеть успешно применялась для распознавания речи, обработки изображений, в робототехнике и в задачах управления. Параметры сети включают в себя размерность массива нейронов, число нейронов в каждом измерении, форму окрестности, закон сжатия окрестности и скорость обучения.

Сеть Хопфилда. Хопфилд использовал функцию энергии как инструмент для построения рекуррентных сетей и для понимания их динамики [4]. Формализация Хопфилда сделала ясным принцип хранения информации как динамически устойчивых аттракторов и популяризовала использование рекуррентных сетей для ассоциативной памяти и для решения комбинаторных задач оптимизации.

Динамическое изменение состояний сети может быть выполнено, по крайней мере двумя способами: синхронно и асинхронно. В первом случае все элементы модифицируются одновременно на каждом временном шаге, во втором - в каждый момент времени выбирается и подвергается обработке один

элемент. Этот элемент может выбираться случайно. Главное свойство энергетической функции состоит в том, что в процессе эволюции состояний сети согласно уравнению она уменьшается и достигает локального минимума (аттрактора), в котором она сохраняет постоянную энергию. Если хранимые в сети образцы являются аттракторами, она может использоваться как ассоциативная память. Любой пример, находящийся в области притяжения хранимого образца, может быть использован как указатель для его восстановления.

Ассоциативная память обычно работает в двух режимах: хранения и восстановления. В режиме хранения веса связей в сети определяются так, чтобы аттракторы запомнили набор p n -мерных образцов $\{x_1, x_2, \dots, x_p\}$, которые должны быть сохранены. Во втором режиме входной пример используется как начальное состояние сети, и далее сеть эволюционирует согласно своей динамике. Выходной образец устанавливается, когда сеть достигает равновесия.

Емкость памяти сети Хопфилда конечна, так как сеть с n бинарными элементами имеет максимально 2^n различных состояний, и не все из них являются аттракторами. Более того, не все аттракторы могут хранить полезные образцы. Ложные аттракторы могут также хранить образцы, но они отличаются от примеров обучающей выборки. Максимальное число случайных образцов, которые может хранить сеть Хопфилда, составляет $0.15 \cdot n$. Если запоминаемые образцы представлены ортогональными векторами (в отличие от случайных), то количество сохраненных в памяти образцов будет увеличиваться.

2.2 Линейные оболочки как однослойные нейронные сети.

Существенным недостатком большинства известных методов дискретной оптимизации является их высокая комбинаторная сложность. Так

для всех алгоритмов синтеза рассматриваемых НС поиск их минимальной конфигурации сводится к решению задачи о минимальном покрытии. Задача о минимальном покрытии является оптимизационной и единственный метод, позволяющий найти глобальный оптимум, есть полный перебор всех вариантов покрытий, выражаемый значением $m!$, где m – число объектов обучения.

Из-за того, что полный перебор практически неосуществим при относительно небольших объёмах обучающих выборок, используются эвристические методы, которые позволяют в общем случае получать локально-оптимальные решения задачи. При синтезе НС с минимальной конфигурацией были предложены два эвристических метода получения локально-оптимальных покрытия обучающей выборки объектами-эталоны.

Первый метод реализуется через конечно-сходящийся алгоритм [34] в качестве начального приближения покрывающего множества в котором выбираются объекты линейных оболочек классов. По определению линейные оболочки есть часть граничных объектов классов, обеспечивающих корректное разделение объектов на классы по алгоритму «ближайший сосед». Объекты-эталоны покрытия, полученные конечно-сходящимся алгоритмом, в общем случае не совпадают с объектами обучающей выборки и используются для построения кусочно-линейных решающих функций с минимальным числом кусков гиперплоскостей.

Линейные оболочки представляют подмножество граничных, в смысле задаваемой меры близости (расстояния), объектов классов обучающей выборки, а метод их определения относится к классу поисково-оптимизационных [5].

Для корректного кусочно-линейного классификатора (КЛК) использование в [5, 6] евклидовой метрики при вычислении расстояния между объектами и подмножества граничных объектов в качестве эталонов классов предопределило название метода линейных оболочек. В данной работе под

корректностью понимается алгоритм распознавания не делающий ошибок на фиксированной выборке объектов классов.

Линейными оболочками может ограничиваться анализ некоторых свойств, классифицированных выборок объектов (например, линейной разделимости классов). При классификации наличие линейно неразделимых объектов заставляет применять более сложные виды разделяющих поверхностей, среди которых видное место занимают кусочно-линейные классификаторы [5, 9].

Одной из задач при создании КЛК является выбор таксонной структуры, определяющий число «кусков» гиперплоскостей разделяющей поверхности. Эквивалентной к задаче о минимальном покрытии [5] является задача нахождения минимального числа гиперплоскостей, входящих в КЛК, которые обеспечивают корректное распознавание объектов фиксированной выборки.

Использование моделей для большого числа различных прикладных задач показывает, что экстремальные свойства многих процессов, изучаемых в рамках этих моделей, проявляются на границах областей, в которых эти процессы описываются. Подтверждением этого является использование сеточных методов вычислительной математики для решения большого круга прикладных задач (например, задач фильтрации).

Множество граничных объектов, определяемых по методу линейных оболочек при решении задач распознавания образов, являются эталонами классов, с помощью которых производится корректное разделение объектов обучения по правилу, «ближайший сосед».

С помощью объектов линейной оболочки можно строить эффективные конечно - сходящиеся алгоритмы для корректного распознавания по минимуму расстояния с минимальным числом эталонов классов. Значения эталонов классов и их количество несут определенную информацию о структуре объектов классов и могут служить предметом отдельного, дополнительного изучения.

Учёт структурных особенностей классов объектов при построении КЛК происходит естественным, эволюционным путем, не приходится прибегать к искусственным разбиениям выборки гиперплоскостями. Обработка экспериментальных данных с помощью алгоритмов распознавания на базе метода линейных оболочек может интерпретироваться как интеллектуальный анализ данных.

Наличие линейно неразделимых объектов при классификации заставляет применять более сложные виды разделяющих поверхностей, среди которых видное место занимают кусочно-линейные классификаторы [7].

Одной из задач при создании КЛК является выбор таксонной структуры, определяющей число "кусков" гиперплоскостей разделяющей поверхности. Задача нахождения минимального числа гиперплоскостей входящих в КЛК, которые обеспечивают корректное распознавание объектов фиксированной выборки, эквивалентна задаче о минимальном покрытии.

Построение моделей для большого числа различных прикладных задач показывает, что экстремальные свойства многих процессов, изучаемых в рамках этих моделей, проявляются на границах областей, в которых эти процессы описываются. На использовании этих экстремальных свойств в частности основывается реализация некоторых численных методов для решения задач математической физики (например, сеточных методов).

При решении задач распознавания образов множество граничных объектов, определяемых по методу линейных оболочек, являются эталонами классов, с помощью которых производится корректное разделение объектов обучения по правилу "*ближайший сосед*".

В целях разъяснения содержания рассматриваемого метода часто прибегают к поиску аналогий или различий (иногда весьма отдаленных) с известными методами. Отличие линейных оболочек, задающих граничное подмножество объектов классов, от границ областей, используемых в задачах математической физики следующее:

1. Признаковое пространство, как правило, имеет размерность больше 3;
2. Область признакового пространства, представляющая описание объектов классов, в общем-то, не является связанной;
3. Множество граничных объектов, определяющее линейные оболочки классов, не является фиксированным и зависит как от объёма выборки, так и от заданной метрики, используемой для вычисления расстояния между объектами.

С помощью объектов линейной оболочки можно строить эффективные конечно-сходящиеся алгоритмы для корректного распознавания по минимуму расстояния с минимальным числом эталонов классов, производить выбор минимального покрытия обучающей выборки гиперсферами для реализации процесса распознавания на параллельных вычислительных системах. Значения эталонов классов и их количество несут определенную информацию о структуре объектов классов и могут служить предметом отдельного, дополнительного изучения.

Выбор таксонной структуры классов при построении КЛК происходит естественным, эволюционным путем, не приходится прибегать к искусственным разбиениям выборки гиперплоскостями. Интерпретация результатов обработки экспериментальных данных с помощью алгоритмов распознавания на базе метода линейных оболочек может использоваться для пополнения баз знаний в системах искусственного интеллекта.

2.3 Линейные оболочки классифицированных выборок объектов и использование нечеткой логики

Рассматривается обучающая выборка задачи распознавания с непересекающимися классами, описанная выше. Считается, что есть μ ($2 \leq \mu \leq t$) объектов из E_0 , которых можно использовать в качестве эталонов при распознавании по минимуму расстояния [8]. Требуется

определить минимальное число эталонов необходимых для безошибочного (корректного) разделения на классы множества объектов обучения E_0 .

На множестве допустимых объектов в R^n введем метрику $\rho(x, y)$. В дальнейшем для удобства выкладок будем считать эту метрику евклидовой. Для каждого $S_i \in E_0 \cap K_j$, $i = \overline{1, m}$, $j = \overline{1, l}$ построим последовательность $S_{i_0}, S_{i_1}, \dots, S_{i_{m-1}}$, где $S_i = S_{i_0}$.

Пусть $S_{i_p} \in K_r, r \neq j, p \in \{1, \dots, m-1\}$ ближайший к S_i объект не входящий в класс K_j . Обозначим через $O(S_i)$ окрестность радиуса $\rho(S_i, S_{i_p})$ с центром в S_i , включающую все объекты, для которых $\rho(S_i, S_{i_t}) < \rho(S_i, S_{i_p}), t = \overline{1, p-1}$.

Из $O(S_i)$ найдем объект $S_{i_r}, r \in \{0, \dots, p-1\}$, для которого

$$\rho(S_i, S_{i_r}) = \min_{S_{i_t} \in O(S_i, S_{i_p})} \rho(S_{i_t}, S_{i_t}) \quad (1)$$

Множество объектов $L(E_0) = \{S_{i_r}\}$, определяемых по (1), будем называть линейной оболочкой множества объектов E_0 . Для удобства индексы объектов, входящих в линейную оболочку $L(E_0) = \{S^1, \dots, S^\mu\}, l \leq \mu \leq m$, будем указывать сверху.

Примем объекты линейной оболочки $L(E_0)$ в качестве эталонов для классификации по минимуму расстояния [8]. Использование для этой цели евклидовой метрики будет выражаться в форме построения гиперплоскостей G_1, \dots, G_μ для кусочно-линейного классификатора, где G_i - гиперплоскость, получаемая из эталона $S^i \in L(E_0), i = \overline{1, \mu}$.

Считается, что произвольный допустимый объект S принадлежит к тому же классу что и эталон $S^i \in L(E_0), i = \overline{1, \mu}$, если $G_i(S) > \max_{r \in \{1, \dots, \mu\} \setminus i} G_r(S)$.

2.4 Конечно-сходящийся алгоритм построения кусочно-линейного классификатора

Рассматривается задача о минимальном покрытии эталонами для корректного КЛК, вектора описаний которых могут не совпадать с векторами описаний объектов, реально представленных в обучающей выборке.

Для каждого $S^i \in L(E_0) \cap K_j$, $i = \overline{1, \mu}$, $\mu = |L(E_0)|$, $j = \overline{1, l}$ построим последовательность объектов $K_j \cap E_0$ в порядке возрастания расстояния $\rho(x, y)$ от S^i

$$S_{i_1}, S_{i_2}, \dots, S_{i_{m_j-1}}, \quad (2)$$

с целью вычисления минимального числа эталонов для корректного на обучающей выборке КЛК с помощью конечно-сходящегося алгоритма.

В качестве начального значения эталонов примем вектора описаний объектов линейной оболочки $Z_i^{(1)} = S^i$, $S^i \in L(E_0)$, $i = \overline{1, \mu}$. Верхний индекс в $Z_i^{(1)}$ служит для обозначения шага алгоритма, нижний совпадает с индексом объекта на линейной оболочке.

На t -м шаге алгоритма, $t=2, 3, \dots$ по каждому последовательно предъявляемому эталону $Z_i^{(t-1)}$ вычислим

$$Z_i^{(t)} = (r_i^{(t-1)} Z_i^{(t-1)} + S_{i_{r_i^{(t-1)}}}) / (r_i^{(t-1)} + 1), \quad (3)$$

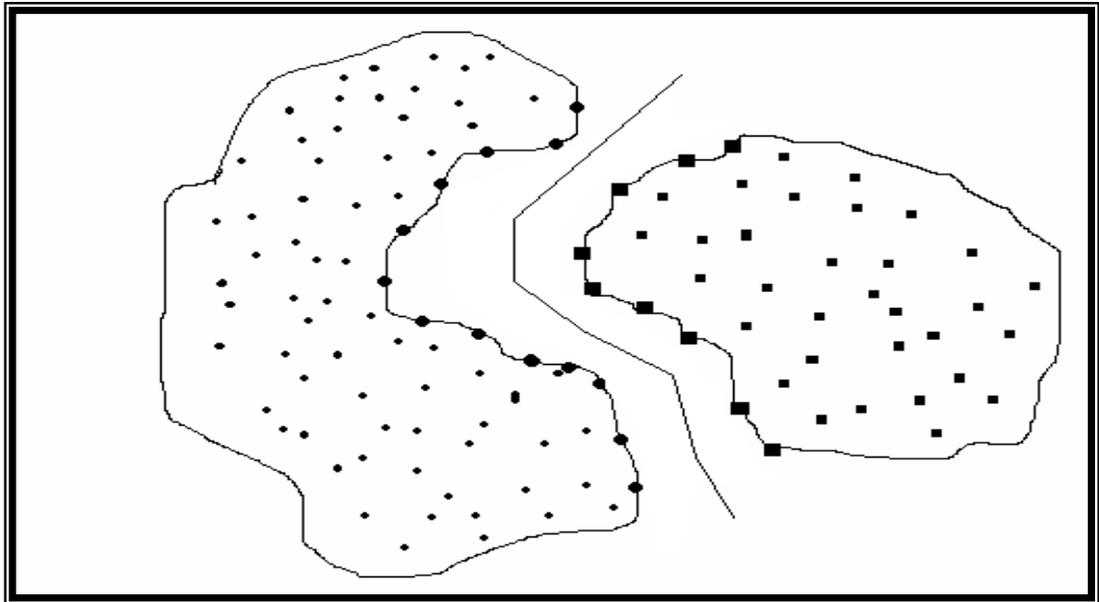
где $r_i^{(t-1)} - 1$ - число объектов (2), используемых для вычисления $Z_i^{(t-1)}$, $r_i^{(1)} = 1$.

Если построенный по эталонам $Z_1^{(t-1)}, \dots, Z_i^{(t-1)}, \dots, Z_\mu^{(t-1)}$ КЛК остается корректным на E_0 , то в качестве нового значения i -го эталона берется (3) и $r_i^{(t)} = r_i^{(t-1)} + 1$, а $\forall d \neq i, Z_d^{(t)} = Z_d^{(t-1)}, r_d^{(t)} = r_d^{(t-1)}$.

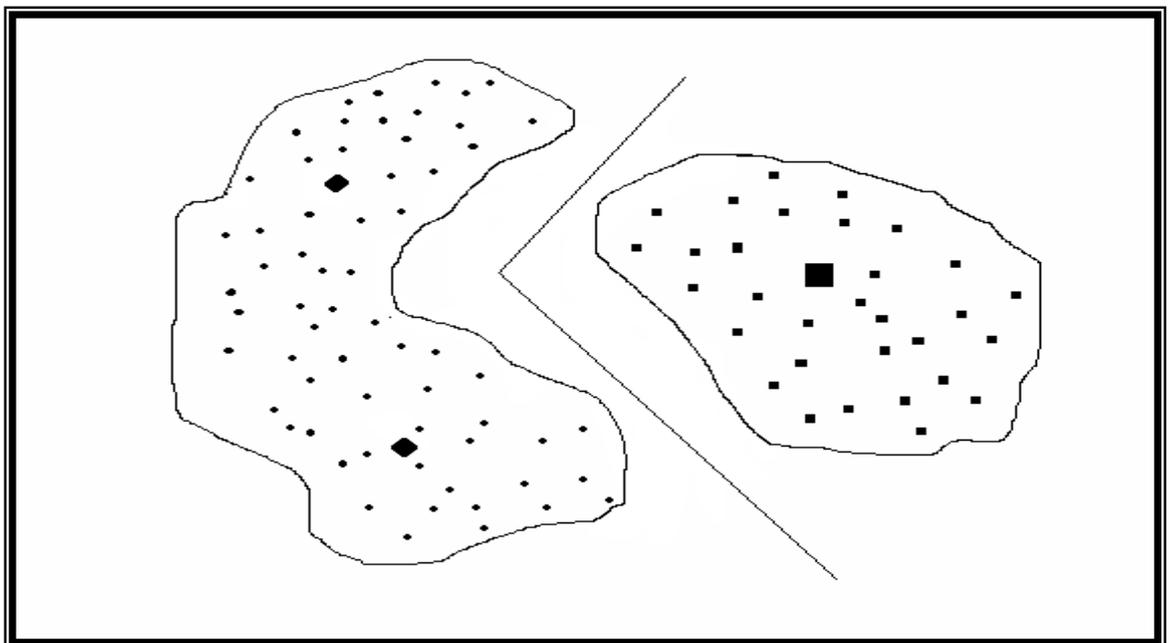
Пусть u - шаг алгоритма, на котором эталон, вычисленный по (3), используется для построения корректного КЛК. Условием сходимости

эталонов к фиксированному положению является $r_i^{(u+i)} = r_i^{(u+i-1)}$, $i = \overline{1, \mu}$ при последовательном вычислении каждого из эталонов по (3).

Графическая представление метода линейных оболочек



Оптимизация метода линейных оболочек



Следует отметить, что описанный алгоритм не даёт, в общем-то, однозначного покрытия обучающей выборки эталонами. Это связано с тем,

что состав объектов в $L(E_0)$ может быть разным, например, до и после локальной оптимизации, основанной на применении процедуры "последовательное исключение", или различаться порядком последовательного предъявления эталонов для вычисления по (3).

Теорема 1. *Минимальное число эталонов класса K_j , $j = \overline{1, l}$ при построении конечно-сходящимся алгоритмом корректного на E_0 КЛК не превышает $\eta_j = |\{S^i \in L(E_0) \cap K_j / r_i^{(t)} < m_j\}| + 1$, где t последний шаг алгоритма.*

Доказательство. При $\eta_j = 1$ доказательство тривиально, так как эталон класса один и он совпадает с центром тяжести объектов класса K_j .

Если $\eta_j > 1$, то это значит, что существуют такие эталоны класса K_j , в вычислении значений векторов описаний которых по (3) участвуют не все объекты из $E_0 \cap K_j$. Теорема доказана.

Множество подмножеств объектов выборки E_0 , использование которых в качестве эталонов при классификации по минимуму расстояния на E_0 дает корректное разделение объектов классов, будем называть множеством линейных оболочек классов.

Можно считать каждую линейную оболочку начальным приближением конечно-сходящегося алгоритма (КСА) определяющего минимальное покрытие эталонами для корректного распознавания объектов E_0 . Значения эталонов минимальных покрытий, вычисляемых с помощью КСА, в общем случае не равны между собой при использовании различных начальных приближений. Искусственность эталонов минимального покрытия заключается в том, что в общем случае их описание не принадлежит E_0 , а является средним значением от определенного числа ближайших объектов конкретного класса.

Неоднозначность числа эталонов, отбираемых по минимуму евклидова расстояния в зависимости от начального приближения КСА, можно наблюдать

по данным, описанным в таблице 2. Класс K_1 имеет форму квадрата, K_2 - обруча внутри которого находится этот квадрат. По геометрическим соображениям очевидно, что оптимальная кусочно - линейная поверхность, отделяющая объекты классов K_1 и K_2 , в идеале должна иметь форму треугольника.

Таб. 2.

Класс K_1			Класс K_2		
Номер объекта	x_1	x_2	Номер объекта	x_1	x_2
1	0.0	0.0	10	-3.8	0.0
2	-1.0	0.0	11	0.0	3.8
3	-1.0	1.0	12	3.8	0.0
4	0.0	1.0	13	0.0	-3.8
5	1.0	1.0	14	-6.0	0.0
6	1.0	0.0	15	-4.2	4.2
7	1.0	-1.0	16	0.0	6.0
8	0.0	-1.0	17	4.2	4.2
9	-1.0	-1.0	18	6.0	0.0
			19	4.2	-4.2
			20	0.0	-6.0
			21	-4.2	-4.2

Действительно, при начальных значениях КСА, определяемых объектами 2,4,6,8,10,11,12,13, эталонными объектами будут $\mathcal{E}_1(0,0)$, $\mathcal{E}_2(-2.275,0)$, $\mathcal{E}_3(0,2.275)$, $\mathcal{E}_4(2.275,0)$, $\mathcal{E}_5(0,-2.275)$ и форма кусочно-линейной поверхности - четырехугольник.

Аналогично при начальных значениях КСА, определяемых объектами 9,14,17,20,21, эталонными будут объекты $\mathcal{E}_1(-0.666,-0.666)$, $\mathcal{E}_2(-2.60,-0.857)$, $\mathcal{E}_3(4.00,2.100)$, $\mathcal{E}_4(-1.27,-1.75)$ и форма кусочно-линейной поверхности - треугольник.

Вычисление эталонных объектов по описанному выше способу осуществляется по принципу "*сначала вширь*". Возможны и другие способы вычисления эталонных объектов, например, такие:

а) эталон \mathcal{E}_j^k , $k=2, \dots, m_r$ продвигается к центру класса K_r ($\mathcal{E}_j^1 = S^j$, $S^j \in L(E_0) \in K_r$) как средне-арифметическое значение k ближайших к нему объектов из (1.3) до тех пор пока сохраняется корректность КЛК (принцип "*сначала вглубь*");

б) аналогично а) эталон \mathcal{E}_j^k перемещается к фиксированному положению с сохранением корректности КЛК путем вычисления $\mathcal{E}_j^k = \alpha \mathcal{E}_j^{k-1} + (1-\alpha) S_{i_k}$, где $0 \leq \alpha \leq 1$, S_{i_k} - k -й по порядку объект из (3) для $S^j \in L(E_0) \cap K_r$.

В качестве критерия для выбора из множества корректных кусочно-линейных поверхностей "*наилучшей*" в определённом смысле может служить такой

$$J(\rho_\mu, E_0) = \sum_{k=1}^m (\rho_\mu(S_k, \mathcal{E}'_t) - \rho_\mu(S_k, \mathcal{E}_t)) \rightarrow \max_{E_0}$$

где \mathcal{E}'_t , \mathcal{E}_t - эталоны минимального покрытия ближайшие к объекту $S_k \in K_r$, $r = \overline{1, l}$ по метрике ρ_μ , соответственно, из классов CK_r , K_r .

Неоднозначность формализации понятия "*похожесть*" объектов порождает и неоднозначность в выборе её измерения [6]. Семейство распознающих алгоритмов инвариантных относительно определенных групп преобразований пространства признаков довольно широко. Практический интерес представляют те из инвариантных алгоритмов, которые всегда правильно классифицируют материал обучения. Очевидно, что метод линейных оболочек также представляет инвариантный алгоритм, для которого нет необходимости указывать условия на преобразования признакового пространства.

Поскольку метод линейных оболочек устойчив к любым допустимым преобразованиям, то актуальным остается вопрос о выборе "*лучшего*" в определенном смысле преобразования. Практически проблема выбора может

быть реализована относительно конечного множества преобразований $\{\varphi_1, \dots, \varphi_k\}$. Предпочтительным может быть выбор преобразования с минимальным числом эталонов покрытия обучающей выборки. Возможны и другие соображения по отбору преобразований признакового пространства.

В общем виде алгоритм $\Pi(E_0, \rho)$ поиска минимального покрытия эталонами выборки E_0 при классификации по минимуму расстояния по метрике ρ представляет собой последовательное выполнение двух операторов $\Pi(E_0, \rho) = V(E_0, \rho) \Omega(E_0, \rho)$, где $V(E_0, \rho)$ - оператор определения исходного подмножества множества E_0 , использование которого в качестве эталонов даёт корректное разделение объектов обучения на классы по минимуму расстояния, $\Omega(E_0, \rho)$ - оператор перемещения эталонов с сохранением корректности алгоритма классификации на E_0 .

ГЛАВА III. СОЗДАНИЕ ПРОГРАММНОГО КОМПЛЕКСА

3.1. Описание программного комплекса распознавании биометрических признаков

Комплекс программ по логической прозрачности нейросетевых систем ориентирован на объяснение процесса принятия решения с помощью обнаружения скрытых закономерностей по заданным экспериментальным данным.

Комплекс программ реализован на персональных компьютерах в операционной системе WINDOWS с помощью инструментальной системы DELPHI 7 и рассчитан на пользователей, являющихся экспертами в своей предметной области.

Описание программ комплекса. Главное окно комплекса программ состоит из меню, нескольких параметров о заданной выборке данных и имеет следующий вид (рис. 6).

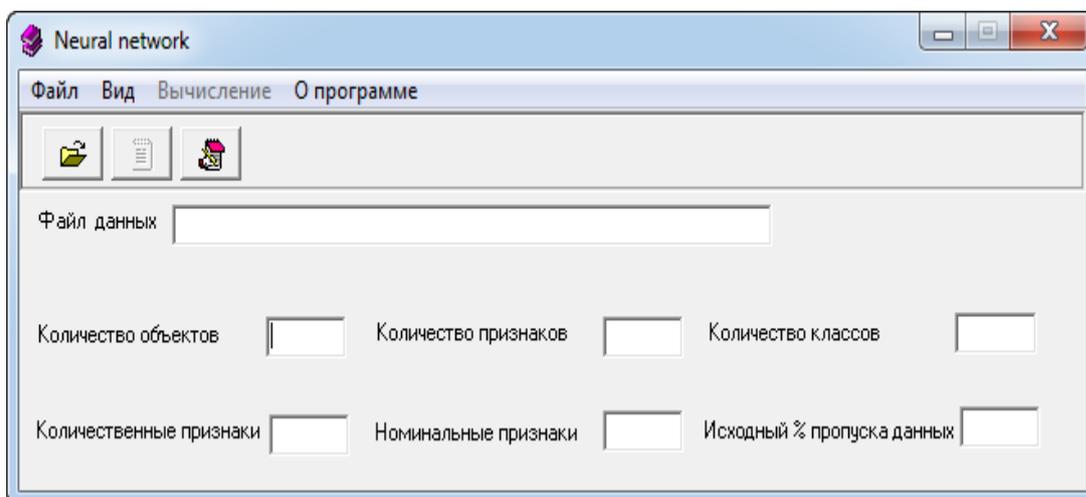


Рис. 6. Главное окно.

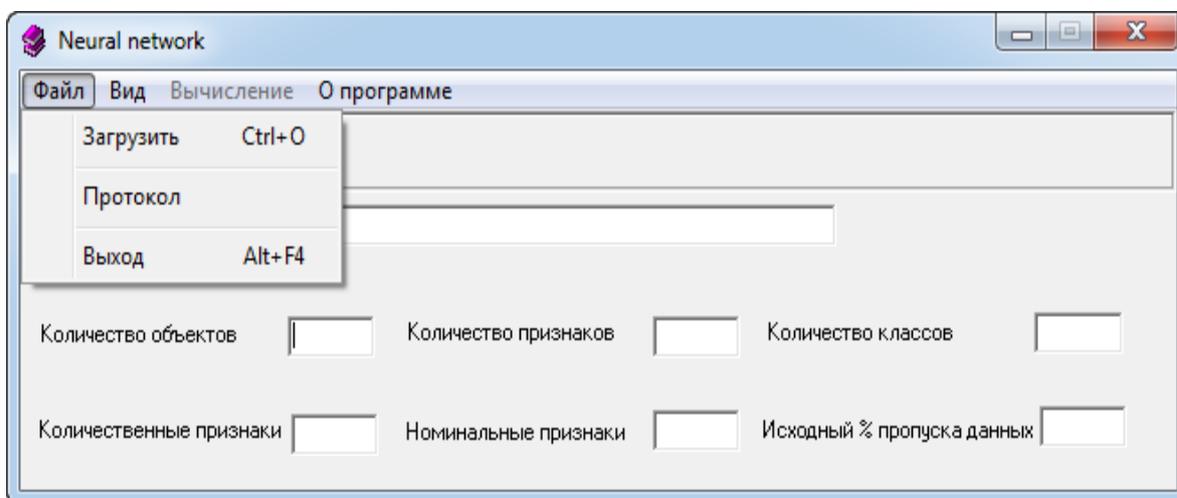


Рис. 7. Главное окно с открытым меню «Файл»

Меню «**Файл**» состоит из следующих трех пунктов (см. рис. 7):

«**Загрузить**» - Загружается указанный пользователем файл;

«**Протокол**» - Запись всех результатов полученных пользователем;

«Выход» - выход из системы.

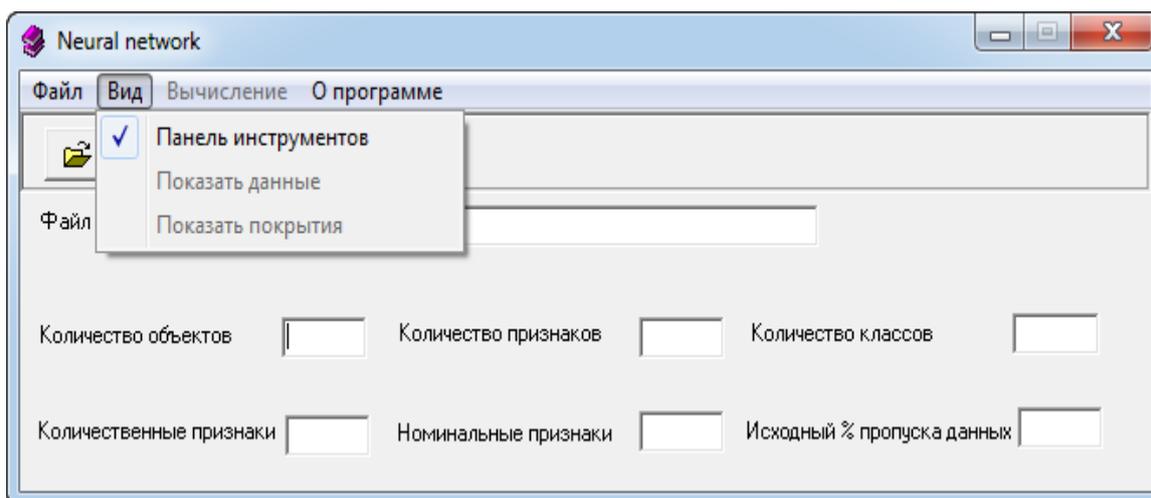


Рис. 8. Главное окно с открытым меню «Вид»

С помощью меню «Вид» (см. рис. 8) можно показать панель инструментов, загруженные данные и объектов – эталонов минимального покрытия.

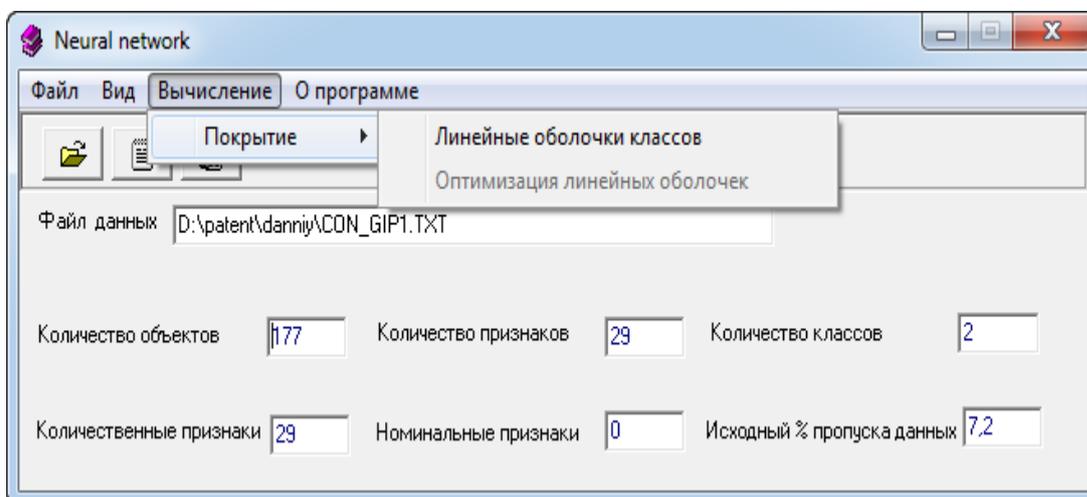


Рис. 9. Главное окно с открытым меню «Вычисление» с пунктом

«**Покрытие**» (см. рис. 9) - вычисляет число объектов – эталонов локально оптимального покрытия и состоит из следующих подпунктов:

- «**Линейные оболочки классов**» - определяет линейные оболочки каждого класса;
- «**Оптимизация линейных оболочек**» - минимизирует число объектов - эталонов линейной оболочки;

Перечень программ комплекса

Пункт «**Загрузить**» (см. рис. 7) состоит из следующих процедур:

Reader – читает данные из заданного файла;

Sort – сортирует данные по классу в порядке возрастания;

Skipping - предназначена для определения общего процента пропусков по заданным данным;

Count – вычисляет число количественных и номинальных признаков;

Transfer – определяет число значений признака без пропусков в K_i и CK_i , где CK_i - дополнение класса K_i , $i = \overline{1, l}$;

Пункт «**Протокол**» (см. рис. 7) состоит из следующей процедуры:

Prot.Show, которая показывает окно протокола;

Пункт «**Линейные оболочки классов**» (см. рис.9) состоит из следующих процедур:

Skipping_mean – заполняет пропуски признака средним значением в классе;

Для вычисления граничных объектов и их оптимизации используется модуль **Lin_s** состоящий из следующих процедур:

Lin_shell – определяет граничные объекты (объекты-эталонные) подмножеств (классов) в множестве E_0 с помощью формулы (1) и содержит функции:

- a) **Metrik** – вычисляет евклидово расстояние между объектами;
- b) **Order** – сортирует объекты по расстоянию.

Пункт «**Оптимизация линейных оболочек**» (см. рис. 9) состоит из следующих процедур:

Optim – строит минимальное покрытие классов по объектам – эталонам;

3.2 Проведение вычислительного эксперимента

Вычислительный эксперимент. Для вычислительного эксперимента были взяты медицинские данные из [5], содержащие описания 177 объекта с помощью 29 количественных признаков. Объекты выборки разделены на два непересекающихся класса: класс 1 - контрольная группа (111 человек), класс 2 - больные гипертонией (66 человек). Количество пропусков в данных равно 7.23 процентам и для заполнения их при выборе минимальной конфигурации НС использовались средние значения признаков в классах.

Перечень из 29 признаков, упорядоченный по мере уменьшения их вклада (8) в разделение объектов классов, выглядел следующим образом:

1. среднее артериальное давление;
2. систолическое артериальное давление;
3. диастолическое артериальное давление;
4. пульсовое артериальное давление;
5. размер полости левого предсердия;
6. возраст;
7. конечный систолический размер левого желудочка;
8. конечный систолический объём левого желудочка;

9. удельное периферическое сопротивление;
10. конечный диастолический объём левого желудочка;
11. конечный диастолический размер левого желудочка;
12. вес;
13. индекс Кердо;
14. фракция выброса;
15. степень укорочения переднезаднего размера левого желудочка в систолу;
16. ударный объём;
17. рост;
18. коэффициент K1;
19. минутный объём;
20. систолический показатель;
21. длительность интервала QT на ЭКГ;
22. длительность систолы;
23. длительность диастолы ;
24. коэффициент K2;
25. длительность интервала QRS на ЭКГ;
26. частота пульса;
27. сердечный индекс;
28. длительность интервала PQ на ЭКГ;
29. длительность интервала RR на ЭКГ.

Результаты вычислительного эксперимента решения с помощью нейроэкспертных систем на основе методом линейных оболочек приведены на рис.10.

Здесь вычисляется число подмножеств граничных объектов (нейронов) в линейном оболочке: видно что общее число объектов 26, из них 11 объектов

принадлежит в первому классу (контрольная группа), а остальные 15 в принадлежит второму (заболевшие гипертонией) (рис.10).

С помощью следующего окно введется данные нового объекта и после нажатия кнопки «Распознавание нового объекта с помощью нейроэкспертной системы» на основе граничных объектов (нейронов) определяются к какому классу принадлежит произвольный объект (Рис. 10). Как сказано выше «Оптимизация линейных оболочек» - минимизирует число объектов - эталонов линейной оболочки. Результаты и распознавания нового объекта после оптимизации приведены в Рис.11. После оптимизации видно, что общее число объектов становится 13, из них 7 объектов принадлежит в первому классу (контрольная группа), а остальные принадлежит второму (заболевшие гипертонией) (Рис.10).

Form3

Введите значения признаков нового объекта

Пр №15	Пр №16	Пр №17	Пр №18	Пр №19	Пр №20	Пр №21	Пр №22	Пр №23	Пр №24	Пр №25
40	0.6	0.6	0.4	0.4	0.5	58	141	31	83	5

Объект №	Признак №1	Признак №2	Признак №3	Признак №4	Признак №5	Признак №6	Признак №7	Признак №8	Признак №9	Признак №10
94	неурон							0.16	0.44	0.06
114								0.16	0.42	0.14
119								0.18	0.4	0.08
122								0.16	0.36	0.08
126								0.14	0.32	0.08
128	63	999	999	160	90	0.9	0.2	0.4	0.06	
134	51	999	999	150	90	0.72	0.16	0.36	0.09	
140	69	184	83	160	100	0.88	0.16	0.4	0.06	
144	48	154	74	140	90	0.94	0.12	0.36	0.08	

Этот объект принадлежит -> контрольная группа (111 человек)

OK

Класс №1. Чило эталонов11
Класс №2. Чило эталонов15
Общее количество объект-эталонов \ 26

Распознавание нового объекта с помощью нейроэкспертной системы

Закреть

Рис.10. Окно результатов нахождения подмножеств граничных объектов.

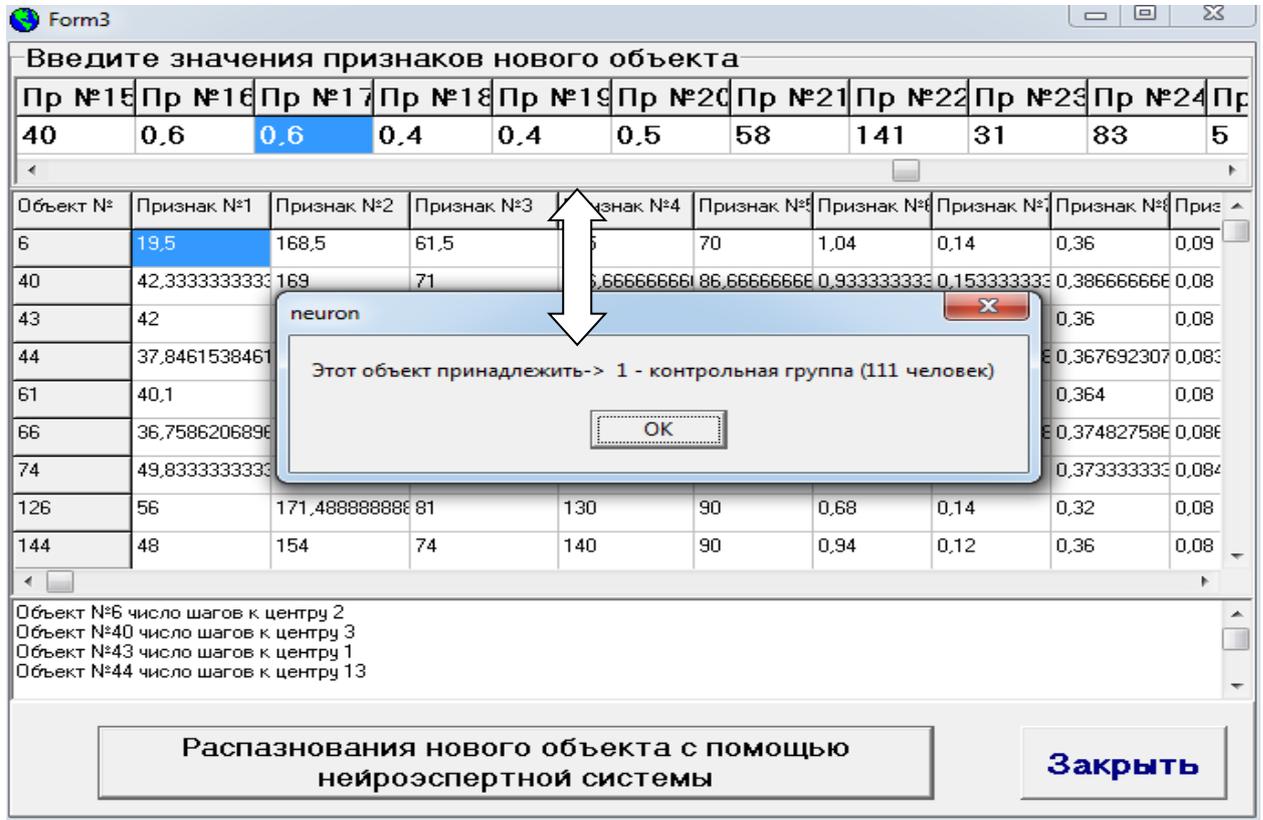


Рис.11. Окно результатов оптимизации подмножеств граничных объектов.

Как, показывает вычислительный эксперимент после оптимизации метода линейных оболочек задача решается быстрее и тратит мало ресурсов.

ЗАКЛЮЧЕНИЕ

Качественное осмысление и принятие решений по огромным объёмам данных, накапливаемых в современных компьютерных системах, делает актуальным разработку новых информационных технологий. Это служит объяснением повышенного интереса специалистов к использованию интеллектуальных методов анализа данных, основу которых представляют методы распознавания образов и искусственного интеллекта.

В выпускной квалификационной работе даётся описание разработок нейроэкспертной системы на основе однослойных нейронных сетей. Приводится вычисление устойчивости как меры структурного разнообразия классифицированных выборок объектов, методика выбора лучшей метрики из конечного набора.

Значительное место в работе отведено описанию двух моделей синтеза искусственных нейронных сетей (НС) с минимальной конфигурацией. Первая основывается на использовании метода линейных оболочек для оптимального кусочно-линейного решающего правила с минимальным числом кусков гиперплоскостей.

Источником новых знаний является использование методов объясняющих процесс принятия решения НС.

В работе для вычислительного эксперимента были взяты медицинские данные, содержащие описания 177 объекта с помощью 29 количественных признаков. Из которого, можно сделать вывод, что после оптимизации метода линейных оболочек задача решается быстрее и тратит мало ресурсов.

Разработан критерий с помощью которого определяются вклады в процесс принятия решения как отдельных показателей так и их комбинаций.

Предложен метод отбора минимального набора независимых разнотипных признаков для синтеза НС с минимальной сложностью.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ