

МИНИСТЕРСТВО ПО РАЗВИТИЮ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ  
И КОММУНИКАЦИЙ РЕСПУБЛИКИ УЗБЕКИСТАН

ТАШКЕНТСКИЙ УНИВЕРСИТЕТ ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ  
ИМЕНИ МУХАММАДА АЛЬ-ХОРАЗМИЙ

*На правах рукописи*

УДК 004.8; 621.379

БАБАЯН РОМАН ИГОРЕВИЧ

Исследование методов построения и свойств нейроимитационных моделей  
для обработки ТВ изображений

Специальность: 5А330601 – Дастурий инжиниринги

Диссертация на соискание академической степени магистра

Работа рассмотрена  
и допускается к защите  
Зав. каф. ПОИТ  
Бабомурадов О. Ж.

Научный руководитель  
к.ф.-м.н., доцент Кабулов Р. В.

\_\_\_\_\_

« \_\_\_ » \_\_\_\_\_ 2018 г.

\_\_\_\_\_

« \_\_\_ » \_\_\_\_\_ 2018 г.

**Ташкент 2018**

O'ZBEKISTON RESPUBLIKASI AXBOROT TEXNOLOGIYALARI VA  
KOMMUNIKATSIALARINI RIVOJLANTIRISH VAZIRLIGI  
MUXAMMAD AL-XORAZMIY NOMIDAGI TOSHKENT AXBOROT  
TEXNOLOGIYALARI UNIVERSITETI

**Fakultet:** DI

**Magistrant:** Babayan R.I.

**Kafedra:** ATDT

**Ilmiy raxbar:**

k.f.-m.n. dotsent Kabulov R.V.

**O'quv tili:** 2016/2018 yil

**Mutaxassislik:** 5A330601-

Dasturiy injiniring

**MAGISTRLIK DISSERTATSIYASIGA ANNOTATSIYA**

**mavzu** «TV tasvirlariga ishlov berish uchun neyron taqlid qilish modellarining yaratilish usullarini va xususiyatlarini tadqiqot qilish»

Ushbu dissertatsiyada ishi grafik ma`lumotlarini qayta ishlash jarayonida, ekranda ko'rinadigan rasmning sifatini yaxshilash maqsadida va shu bilan birga aloqa kanallari orqali uzatiladigan axborot hajmini kamaytirish uchun sun`iy neyronlar to'rlarini ishlatish masalasini yoritiladi.

Koxonen neyron to'ri, Xopfield va Xemming assotsiativ to'ri va konvolutsiya neyron to'ri neyronlar to'ri modellari, hamda NeuroIterator, NeuroPro, NeuroGenesis va Signeyro neyroimitatsion dasturlari ko'rib chiqilgan.

Raqamli televideniyaning neyro to'rli texnologiyalari, intellektual video kuzatuvlar, hamda harakatlanadigan ob`ektlarni boshqarishda yordam sifatida qo'llash tavsiya etildi.

Ilmiy raxbar:

k.f.-m.n. dotsent Kabulov R.V.

Magistratura talabasi:

Babayan R.I.

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

**ТАШКЕНТСКИЙ УНИВЕРСИТЕТ ИНФОРМАЦИОННЫХ  
ТЕХНОЛОГИЙ ИМЕНИ МУХАММАДА АЛ-ХОРАЗМИЙ**

**Факультет:** Программный  
инжиниринг

**Магистрант:** Бабаян Р.И.

**Кафедра:** Программное  
обеспечение информационных  
технологий

**Научный руководитель:**  
к.ф.-м.н., доцент Кабулов Р. В.

**Учебный год:** 2016/2018 год

**Специальность:** 5A330601-  
Программный инжиниринг

**АННОТАЦИЯ МАГИСТЕРСКОЙ ДИССЕРТАЦИИ**

**на тему «Исследование методов построения и свойств  
нейроимитационных моделей для обработки ТВ изображений»**

. Данная диссертационная работа освещает вопрос применения искусственных нейронных сетей для обработки графических данных с целью повышения качества выводимого на экран изображения при одновременном снижении объема передаваемой по каналам связи информации. Рассмотрены такие модели нейронных сетей, как нейронная сеть Кохонена, ассоциативные сети Хопфилда и Хэмминга, сверточная нейронная сеть, а также нейроимитаторы NeuroIterator, NeuroPro, NeuroGenesis и Сигнейро. Даны рекомендации по использованию нейросетевых технологий в цифровом телевидении, интеллектуальном видеонаблюдении и управлении подвижными объектами.

Научный руководитель:

к.ф.-м.н., доцент Кабулов Р. В.

Студент магистратуры:

Бабаян Р.И.

**MINISTRY OF DEVELOPMENT OF INFORMATION TECHNOLOGIES  
AND COMMUNICATIONS OF THE REPUBLIC OF UZBEKISTAN**

**TASHKENT UNIVERSITY OF INFORMATION TECHNOLOGIES  
NAMED AFTER MUXAMMAD AL-KHWARIZMI**

**Faculty:** Software engineering

**Degree student:** Babayan R.I.

**Department:** SIT

**Scientific supervisor:**

Ph.D., docent Kabulov R.V.

**Academic years:** 2016-2018

**Specialty:** 5A330601- Software engineering

**ANNOTATION OF THE MASTER THESIS**

on the subject " Research of methods of construction and properties of  
neuroimitative models for processing TV images"

This thesis covers the use of artificial neural networks for the processing of graphic data in order to improve the quality of the displayed image while reducing the amount of information transmitted through the communication channels. Considered such models of neural networks as Kohonen neural network, Hopfield and Hamming associative networks, convolutional neural network, as well as neuroimitators NeuroIterator, NeuroPro, NeuroGenesis and Signeiro. Recommendations are given on the use of neural network technologies in digital television, intelligent video surveillance and management of mobile objects

Scientific supervisor:

Ph.D., docent Kabulov R.V.

Degree student:

Babayan R.I.

## ОГЛАВЛЕНИЕ

<b>Введение .....</b>	<b>6</b>
<b>1 ОБЗОР СОВРЕМЕННЫХ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ ОБРАБОТКИ ИЗОБРАЖЕНИЙ.....</b>	<b>10</b>
1.1 Общие понятия и возможности нейросетевых технологий .....	10
1.2 Типы нейронных сетей и их основные характеристики.....	17
1.3 Применение нейросетевых технологий в задачах обработки изображений .....	28
1.4 Анализ современного состояния аппаратно-программного обеспечения для моделирования работы искусственных нейронных сетей	31
Выводы по главе.....	34
<b>2 АНАЛИЗ ПРИНЦИПОВ ПОСТРОЕНИЯ И РАБОТЫ ИМИТАЦИОННЫХ СРЕДСТВ ИНС.....</b>	<b>36</b>
2.1 Принципы построения и работы современных нейроимитационных моделей.....	36
2.2 Анализ особенностей построения и работы современных и перспективных искусственных нейронных сетей для обработки изображений .....	41
2.3 Анализ типов и возможностей нейроимитаторов NeuroIterator, NeuroPro, NeuroGenesis, Сегнейро .....	42
Выводы по главе.....	56
<b>3 ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ НЕЙРОИМИТАЦИОННЫХ СРЕДСТВ ПО ОБРАБОТКЕ ИЗОБРАЖЕНИЙ .....</b>	<b>59</b>
3.1 Исследование возможностей ассоциативной сети Хопфилда .....	59
3.2 Исследование возможностей ассоциативной сети Хэмминга .....	62
3.3 Исследование возможностей нейронной сети Кохонена .....	66
3.4 Исследование возможностей сверточной нейронной сети .....	69
3.5 Выработка рекомендаций по использованию нейросетевых технологий в цифровом телевидении, интеллектуальном видеонаблюдении и управлении подвижными объектами .....	72
Выводы по главе.....	79
<b>Заключение.....</b>	<b>81</b>
<b>Список литературы .....</b>	<b>86</b>

## Введение

В настоящее время сфера информационных технологий в Узбекистане находится в стадии ускоренного развития, свидетельством чего, в частности, является осуществляемый в данный момент переход на цифровое телевизионное вещание [1]. Данное обстоятельство, а также то, что уже существуют цифровые телевизоры с высокопроизводительными процессорами по обработке входящих сигналов, позволяет осуществить внедрение в них технологий искусственного интеллекта в виде искусственных нейронных сетей.

Исследования по искусственным нейронным сетям связаны с тем, что способ обработки информации человеческим мозгом в корне отличается от методов, применяемых обычными цифровыми компьютерами. Мозг представляет собой чрезвычайно сложный, нелинейный, параллельный компьютер. Учеными доказано, что мозг состоит из огромного числа структурных компонентов – нервных клеток, называемых также нейронами. Нейрон создает соединения с другими нейронами, количество которых в точках сопряжения может составлять от 10 до 100000. Сигналы, распространяемые по нейронной сети, управляют активностью мозга в течение короткого интервала, а также становятся причиной долговременных изменений состояния самих нейронов и их соединений.

Разработка искусственных нейронных сетей началась в начале XX века, но только в 90-х годах, когда вычислительные системы стали достаточно мощными, нейронные сети получили широкое распространение. Создание нейронных сетей было вызвано попытками понять принципы работы человеческого мозга и, без сомнения, это будет влиять и на дальнейшее их развитие. Однако, в сравнении с человеческим мозгом нейронная сеть сегодня представляют собой весьма упрощенную модель, но несмотря на это весьма успешно используются при решении самых различных задач. Хотя решение на основе нейронных сетей может выглядеть и вести себя как обычное программное обеспечение, они различны в принципе, поскольку

большинство реализаций на основе нейронных сетей «обучается», а «не программируется»: сеть учиться выполнять задачу, а не программируется непосредственно.

**Целью работы** является сравнительный анализ существующих и перспективных вариантов обработки видеоданных при помощи искусственных нейронных сетей на основе их возможностей по увеличению качества изображения.

**Основными задачами диссертации являются:**

- анализ принципов работы искусственных нейронных сетей, различных архитектур, приемов и методов их создания;
- анализ влияния различных вариантов искусственных нейронных сетей на качество изображения.
- выработка рекомендаций по использованию искусственных нейронных сетей.

**Объектом исследования** являются графические данные в виде последовательных статических кадров либо непрерывного потока информации и влияние, которое на них оказывает обработка при помощи искусственных нейронных сетей.

**Предметом** данного исследования является анализ приемов, методов и способов обработки видеоданных при помощи искусственных нейронных сетей для повышения качества изображения.

**Методы исследования:** для решения поставленных задач и достижения цели диссертации в ней использовались методы сравнительного анализа, системного анализа, компьютерное моделирование, метод «черного ящика», дедукция и индукция.

**Краткий литературный обзор по теме исследования**

На сегодняшний день теме искусственных нейронных сетей посвящен широкий круг публикаций, основными из которых являются работы Хокинса, Хайкина, Рассела, Потапова, Осовского и другие. В них

рассматриваются принципы работы искусственных нейронных сетей, различные архитектуры, приемы и методы их создания.

**Научная новизна** данной диссертационной работы заключается в исследовании и практической реализации передовых достижений в сфере искусственных нейронных сетей в области обработки изображений для цифрового телевидения и выработке рекомендаций по использованию искусственных нейронных сетей для увеличения качества демонстрируемого изображения.

**Актуальность** данного исследования обусловлена тем, что в настоящее время происходит активное развитие в области нейросетевого моделирования, что позволяет создавать программы, которые адаптируются к входному потоку данных, в результате чего появляется возможность создания устройств или программ, которые после анализа принимаемого кадра будут иметь возможность на его основе самостоятельно улучшать качество изображения.

**Теоретическая и практическая значимость результатов исследования** состоят в том, что оно позволяет определить наиболее эффективные архитектуры искусственных нейронных сетей и области их применения для улучшения качества изображения.

**Апробация работы.** Основные положения диссертационной работы докладывались и обсуждались на следующих научно-технических конференциях:

- на Республиканской научно-технической конференции на тему «Значение информационно-коммуникационных технологий в инновационном развитии реальных отраслей экономики», г. Ташкент, 6-7 апреля 2017 г.;
- на Международной конференции на тему «Роль информационно-коммуникационных технологий в инновационном развитии реальных отраслей экономики», г. Ташкент, 5-6 апреля 2018 г.

Диссертационная работа состоит из введения, 3 глав, заключения и списка литературы из 27 наименований. Основной текст содержит 80 страниц и иллюстрируется 18 рисунками.

**Во введении** обоснована актуальность темы, научная новизна и практическая ценность исследования, изложены цель и задачи исследования, его аннотация.

**В первой главе** проведен обзор современных нейросетевых технологий для обработки изображений, рассмотрены общие понятия и возможности нейросетевых технологий, типы нейронных сетей и их основные характеристики, применение нейросетевых технологий в задачах обработки изображений, анализ современного состояния аппаратно-программного обеспечения для моделирования работы искусственных нейронных сетей

**Во второй главе** проведен анализ принципов и работы имитационных средств ИНС, рассмотрены принципы построения и работы современных нейроимитационных моделей, произведен анализ особенностей построения и работы современных и перспективных искусственных нейронных сетей при обработке изображений, а также анализ типов и возможностей нейроимитаторов NeuroIterator, NeuroPro, NeuroGenesis и Сигнейро

**В третьей главе** проведено исследование возможностей нейроимитационных средств по обработке изображений, в частности, исследование возможностей ассоциативной сети Хопфилда, нейронной сети Кохонена, ассоциативной сети Хэмминга, сверточной нейронной сети, а также выработаны рекомендации по использованию нейросетевых технологий в цифровом телевидении, интеллектуальном видеонаблюдении и управлении подвижными объектами

**В заключении** сформулированы теоретические и практические выводы по диссертационной работе и даны рекомендации по использованию искусственных нейронных сетей при обработке видеоданных.

# **1 ОБЗОР СОВРЕМЕННЫХ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ ДЛЯ ОБРАБОТКИ ИЗОБРАЖЕНИЙ**

## **1.1 Общие понятия и возможности нейросетевых технологий**

С самого начала двадцать первого века компьютерные технологии все больше проникали в нашу жизнь, давая возможности, которые ранее воспринимались как невероятные. Однако растущие с каждым годом сложность и объем информационных потоков затрудняют их обработку и анализ, даже с учетом непрекращающегося увеличения производительности компьютерных систем. Для решения данной проблемы сегодня в основном применяют интеллектуальные информационные системы, к которым относятся экспертные системы и системы поддержки принятия решения. Но, несмотря на высокую эффективность таких комплексов, они имеют ряд недостатков, наиболее значительными являются большая стоимость и сложность разработки, ограниченная вариативность поведения – выбор осуществляется только в рамках заложенной на этапе проектирования архитектуры правил обработки данных, отсутствующая возможность автоматического распознавания новых классов входных данных – они должны вводиться вручную. В данной ситуации есть еще одно решение, которое в большей степени избавлено от вышеуказанных недостатков – так называемые искусственные нейронные сети и основанные на них нейросетевые технологии.

Нейросетевые технологии – совокупность аппаратных и/или программных методов и средств обработки информации, использующих искусственные нейронные сети (ИНС). ИНС, в свою очередь, состоят из набора связанных в соответствии с определенной пространственной архитектурой искусственных нейронов, которые представляют собой элементарные вычислительные ячейки, функционирующие в соответствии с математической моделью работы реального биологического нейрона. Данная

модель базируется на следующих принципах: нейрон имеет несколько входов и только один выход, входы нейрона воздействуют на проходящий по ним сигнал, нейрон суммирует приходящие к нему сигналы, нейрон генерирует исходящий сигнал при помощи специальной функции, которая определяет, как множество сигналов на входах будут преобразованы в единственный сигнал на выходе (рис. 1.1) [3].

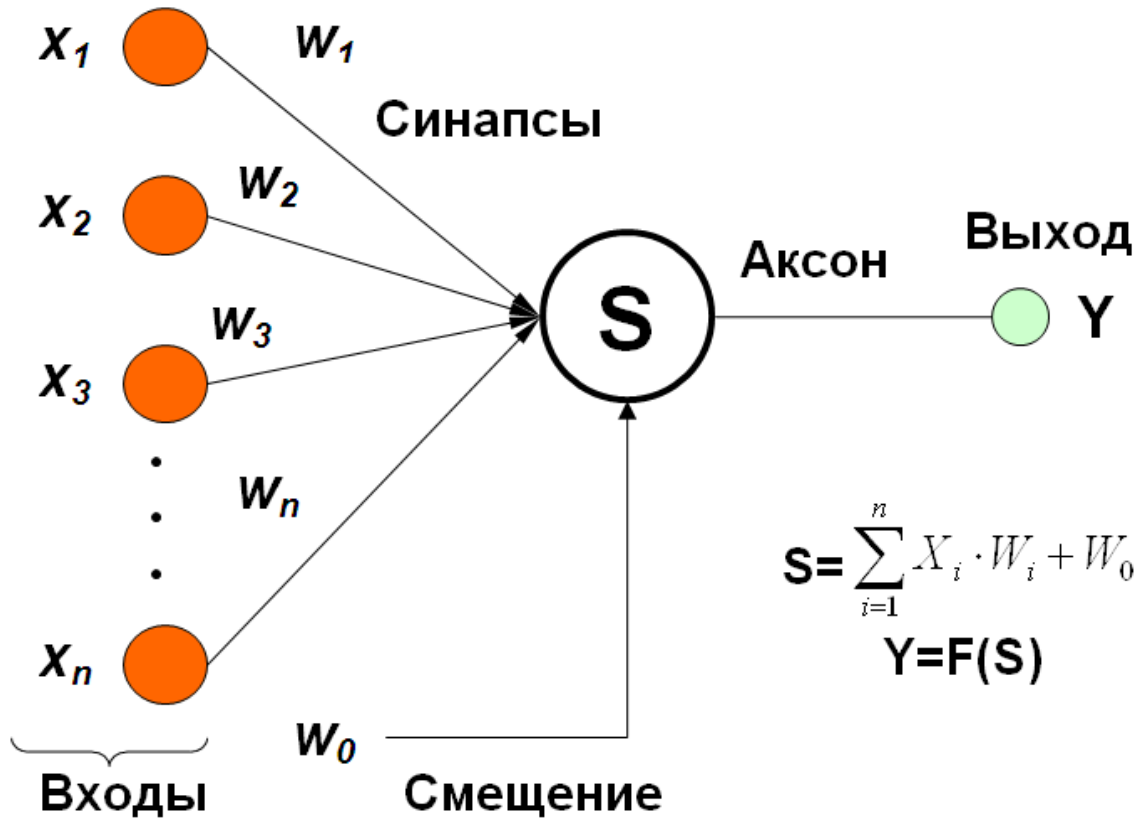


Рис. 1.1. Схема искусственного нейрона

В соответствии с этими принципами можно сформулировать математическую модель биологического нейрона: выход нейрона связан с его входами нелинейной функцией

$$Y = G(X, W) \quad (1.1)$$

где:

- $X$  – набор сигналов на входах нейрона,
- $W$  – набор коэффициентов воздействия на сигнал, привязанных к входам нейрона, так называемые веса входов,
- $Y$  – сигнал на выходе нейрона.

Функция G состоит из двух последовательных шагов – суммирования уровней входных сигналов с учетом весов входов (1.2) и вычисления величины выходного сигнала путем применения к полученной сумме «активационной» функции (1.3).

$$S = \sum_{i=0}^n X_i W_i \quad (1.2)$$

$$Y = F(S) \quad (1.3)$$

Функция активации служит для нормализации выходного сигнала. В качестве таковой может использоваться любая функция, удовлетворяющая критерию непрерывности на всей области определения. Некоторые из возможных функций активации перечислены в табл. 1 [4], однако наиболее часто применяется сигмоид (1.4).

$$Y = \frac{1}{1 + e^{-aS}} \quad (1.4)$$

Таблица 1.1.  
Варианты функции активации для искусственного нейрона

Название	Формула	Область значений
Линейная	$Y = aS$	$(-\infty; \infty)$
Полулинейная	$Y = \begin{cases} aS, & S > 0 \\ 0, & S \leq 0 \end{cases}$	$(0; \infty)$
Логистическая (сигмоидальная)	$Y = \frac{1}{1 + e^{-aS}}$	$(0; 1)$
Гиперболический тангенс (сигмоидальная)	$Y = \frac{e^{aS} - e^{-aS}}{e^{aS} + e^{-aS}}$	$(-1; 1)$
Экспоненциальная	$Y = e^{-aS}$	$(0; \infty)$
Синусоидальная	$Y = \sin S$	$(-1; 1)$
Сигмоидальная (рациональная)	$Y = \frac{S}{a +  S }$	$(-1; 1)$
Шаговая (линейная с насыщением)	$Y = \begin{cases} 1 & S \geq 1 \\ S & -1 < S < 1 \\ -1 & S \leq -1 \end{cases}$	$(-1; 1)$
Пороговая	$Y = \begin{cases} 1, & S \geq a \\ 0, & S < a \end{cases}$	$(0; 1)$
Модульная	$Y =  S $	$(0; \infty)$

Знаковая (сигнатурная)	$Y = \begin{cases} 1, & S > 0 \\ -1, & S \leq 0 \end{cases}$	$(-1; 1)$
Квадратичная	$Y = S^2$	$(0; \infty)$

Выбор функции активации зависит от характера обрабатываемых данных и от того, осуществлялась ли их предварительная нормализация.

Как было указано выше, нейронная сеть в целом представляет собой совокупность отдельных нейронов, соединенных в соответствии с некоторой схемой. Рассмотрим три варианта топологии ИНС [4]:

- Полносвязная сеть (рис. 1.2а): выход каждого нейрона связан с входами всех остальных нейронов в сети, в том числе сам с собой.







Рис. 1.2. Варианты топологии нейросети

- Многослойная сеть (рис. 1.2б): в структуре сети можно выделить отдельные группы нейронов без внутренних связей, но с сильными

межгрупповыми связками (как правило, каждый с каждым) – слои. В классическом случае слои следуют друг за другом, последовательно передавая сигнал от первого к последнему, однако существуют и вариации, например, с возвратом сигнала на предыдущие слои, или с передачей сигнала от текущего слоя не на последующий, а на некоторый более отдаленный.

- Слабосвязная сеть (рис. 1.2в): выход каждого нейрона связан с входами только ближайших к нему нейронов в сети.

Из этих трех вариантов больше всего применяются многослойные сети, поэтому проанализируем такую структуру подробнее. Первый слой нейронной сети в данном случае имеет, в отличие от остальных, только по одному входу на каждый нейрон и де-факто служит лишь для нормирования поступающей информации и предоставления следующему слою доступа ко всему массиву входных данных, по этой причине данный слой не учитывается при определении количества активных слоев ИНС. Далее расположены один и более так называемых скрытых (так как они не доступны снаружи) слоев, на которых и происходит обработка информации. Последний, выходной слой, завершает эту обработку и готовит результат для выдачи, то есть состояние выходов его нейронов после проведения вычислений является итоговым ответом нейросети.

Искусственная нейронная сеть, в отличие от обычной компьютерной программы, после построения не содержит никаких правил по трансформации входных данных в выходные. Эти правила, выраженные конкретными значениями весов межнейронных связей, сеть формирует сама в ходе особого процесса – машинного обучения. Его суть заключается в следующем: на вход сети подается тестовая выборка в виде подмножества реальных данных, после чего анализируется ответ нейросети – он сравнивается с эталоном и на основе этого сравнения происходит соответствующая корректировка весов, целью которой является минимизация разности между ответом сети и эталоном. В качестве эталона может служить соответствующий тестовым данным набор «правильных»

ответов (обучение с учителем) либо же предыдущие ответы ИНС для объектов, принадлежащих тому же классу, что и текущий (обучение без учителя). Это позволяет на основе некоей стандартной нейросети получить широкое разнообразие готовых конструкций, например, заготовка под нейронную сеть для классификации объектов может с равным успехом проводить эту классификацию в самых разных условиях, в зависимости от источника данных для тестовой выборки. После прохождения обучения нейросеть считается готовой к реальной работе.

Основными задачами, где в настоящее время активно используются ИНС, являются: распознавание образов, классификация объектов, принятие решений и управление, кластеризация, прогнозирование, аппроксимация, сжатие данных и ассоциативная память (восстановление данных), анализ данных, оптимизация и другие. Эти и подобные им задачи (или сходящиеся к ним) требуется решать, в основном, в следующих категориях [5]:

- Промышленность – управление технологическими процессами, идентификация химических компонент, контроль качества артезианских вод, оценка экологической обстановки, прогнозирование свойств синтезируемых полимеров, управление водными ресурсами, оптимальное планирование, разработка нефти и газа, управление работой прессы, идентификация вида полимеров, управление ценами и производством, оптимизация работы моторов, обнаружение повреждений, оптимизация закупок сырья, контроль качества изделий, приложения аналитической химии, анализ проблем функционирования заводов и магазинов, прогнозирование потребления энергии;

- Высокие технологии – проектирование и оптимизация сетей связи, анализ и сжатие изображений, распознавание печатных и рукописных символов, фальсификации в пищевой и парфюмерной промышленности, обслуживание кредитных карт, идентификация и верификация говорящего субъекта, видеонаблюдение, автоматизированное распознавание речевых

команд, распознавание слитной речи с (и без) настройкой на говорящего субъекта, речевой ввод текста в компьютер;

- Оборона – анализ визуальной аэрокосмической информации, отбор целей, обнаружение наркотиков и взрывчатых веществ, сличение изображений с криминальной базой данных, предсказание целесообразности условного освобождения;

- Наука и техника – поиск неисправностей в научных приборах, диагностика печатных плат, идентификация продуктов, синтез новых видов стекла, автоматизированное проектирование, оптимизация биологических экспериментов, геофизические и сейсмологические исследования, распознавание ингредиентов, спектральный анализ и интерпретация спектров, интерпретация показаний сенсоров, моделирование физических систем, анализ данных в ботанике, планирование химических экспериментов, отбор сенсоров для контроля химических процессов, прогноз температурного режима технологических процессов, диагностика сбоев сигнализации;

- Здравоохранение – идентификация микробов и бактерий, диагностика заболеваний, интерпретация ЭКГ, анализ качества лекарств, обработка и анализ медицинских тестов, прогнозирование результатов применения методов лечения, оптимизация атлетической подготовки, диагностика слуха;

- Бизнес и финансы – выбор сбытовой политики, принятие административных решений, предсказания на фондовой бирже, анализ финансового рынка, исследование фактора спроса, моделирование бизнес-стратегии, предсказание наступления финансовых кризисов, прогноз прибыли (cash-flow), предсказание и расшивка "узких мест", прогноз эффективности кредитования, прогнозирование валютного курса, прогнозирование и анализ цен, построение макро- и микроэкономических моделей, предсказание необходимых трудодней для реализации проекта, прогнозирование продаж, анализ целей маркетинговой политики, прогнозирование экономических индикаторов, анализ страховых исков,

отбор перспективных кадров, стратегии в области юриспруденции, оценка и прогнозирование стоимости недвижимости.

Столь широкий охват демонстрирует наиболее важные преимущества нейросетей перед классическими программами: адаптируемость (легкая переобучаемость при больших потоках входных данных); возможность потенциального распараллеливания вычислений; способность обучаться на примерах без программирования, что позволяет отказаться от поиска каких-либо аналитических зависимостей между входными данными и результатами; обучение на неполной, противоречивой и искаженной информации; не требуют выполнения условия отсутствия взаимосвязи между входными факторами, как это требуется в регрессионном анализе. К недостаткам же ИНС следует отнести «непрозрачность» процесса получения результата; трудность его интерпретации; необходимость приводить исходные данные к цифровой форме; плохой анализ принципиально новых ситуаций, не представленных ранее примерами в обучающей выборке.

## **1.2 Типы нейронных сетей и их основные характеристики**

За период с момента изобретения в 40-х годах XX века до настоящего времени было создано множество структурных вариаций ИНС, адаптированных под те или иные условия.

Перечислим основные классификации нейросетей [6]:

- По типу информации на входе – аналоговые, двоичные, образные.
- По характеру обучения – с учителем, без учителя, с подкреплением.
- По способу определения весов связей – с фиксированными связями (устанавливаются при проектировании сети), с динамическими связями (вычисляются путем обучения).
- По времени передачи сигнала по связям между нейронами (в том случае, если это учитывается в функции активации) – синхронные (для всех

связей время равно некоторой константе), асинхронные (время назначается индивидуально для каждой связи).

- По варианту топологии – полносвязные (все нейроны соединены между собой), многослойные (соединенные нейроны образуют группы), слабосвязные (соединяются только близлежащие нейроны).

- По характеру связей – сети прямого распространения сигнала, рекуррентные нейросети, радиально-базисные ИНС (с соответствующей функцией активации), самоорганизующиеся карты и другие.

Перечислим основные архитектуры нейросетей, которые используются сегодня в научных, коммерческих и других проектах:

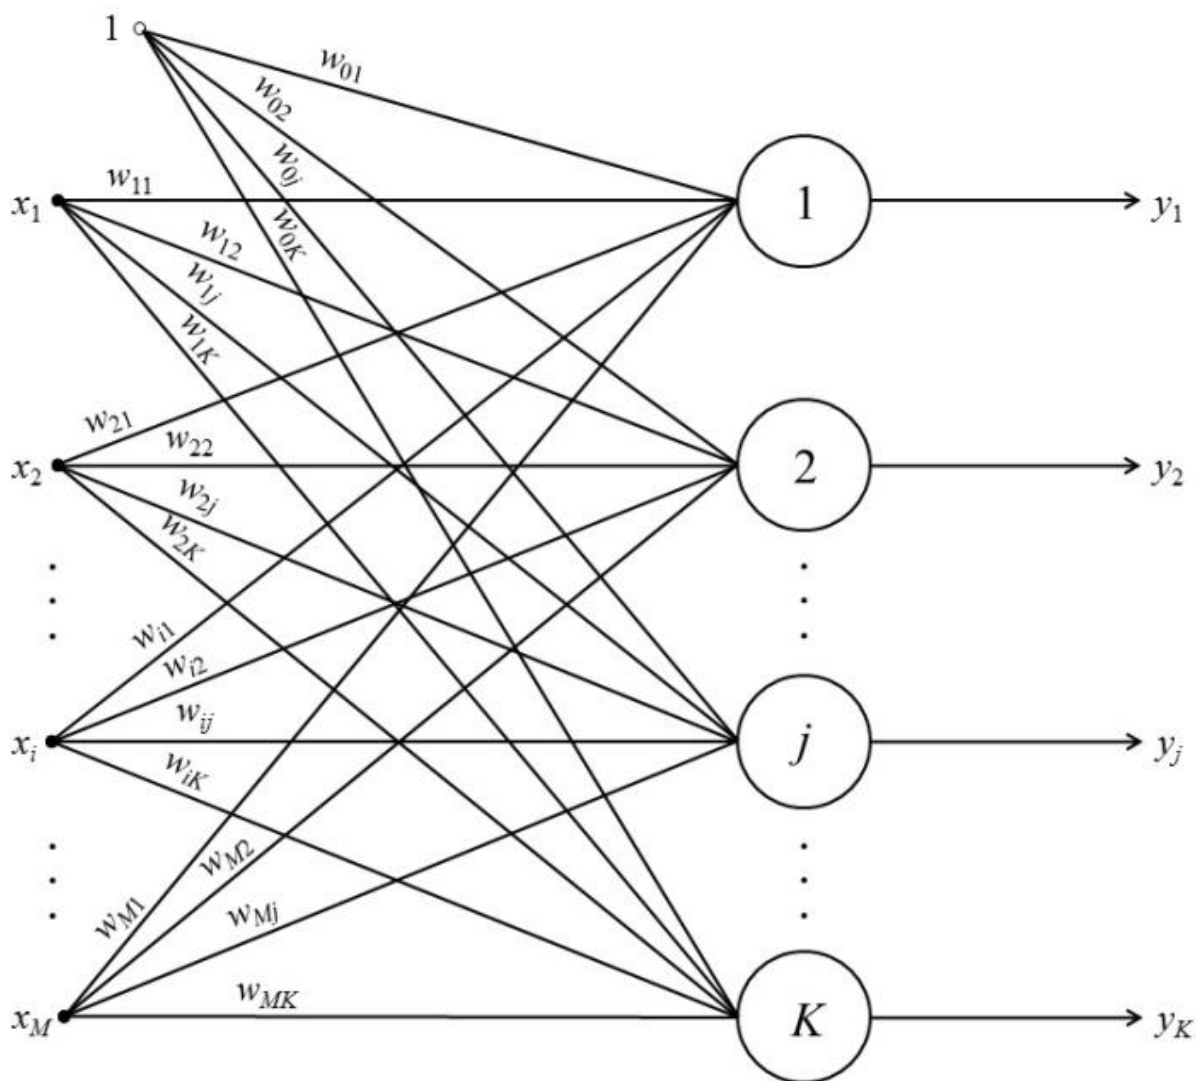
- Перцептрон;
- Сеть Хэмминга;
- Сеть Ворда;
- Сеть Хопфилда;
- Нейронный газ;
- Когнитрон;
- Сеть радиально-базисных функций (RBF-сеть);
- Сеть Кохонена;
- Сети адаптивного резонанса;
- Свёрточная нейронная сеть.

Рассмотрим архитектуры перечисленных нейронных сетей более подробно.

**Перцептрон** – нейронная сеть, состоящая из пассивного входного и одного или нескольких активных слоев, с прямым распространением сигнала, использующая пороговую функцию активации. Количество нейронов в пассивном слое определяется числом признаков объекта, в выходном слое – числом классов, существующих в предметной области. Позволяет создать набор ассоциаций между входом и выходом сети, выполняя таким образом роль классификатора. [7][8]

Исторически именно перцептрон был первой искусственной нейронной сетью. Построенный в 1957 году Ф. Розенблаттом, он был предназначен для изучения вероятной модели хранения и организации информации в головном мозге. Для его обучения была разработана специальная методика обучения нейросетей, основанная на принципах обучения человека – «метод коррекции ошибки». Позднее, в 1960-м, появилась его аппаратная реализация в виде нейрокомпьютера «Марк-1», способного опознавать некоторые буквы латиницы.

Структурная схема двух вариантов реализации перцептрона – однослойного (а) и многослойного (б) – показана на рисунке 1.3.



a)




Рис. 1.3. Структурная схема нейросети «Перцептрон»  
 а) – однослойный, б) – многослойный.

**Сеть Хэмминга** – это нейронная сеть с тремя слоями, имеющая обратную связь, ее схематическое изображение можно увидеть на рисунке 1.4. Применяется для классификации объектов. Первый слой не имеет влияния на работу сети, он содержит число нейронов, равное числу признаков классифицируемых объектов и используется только для ввода сигналов. Количество нейронов во втором и третьем слоях равно количеству классов классификации. Каждый нейрон первого слоя связан с каждым нейроном из второго. Нейроны третьего слоя связаны с вторым слоем в соотношении один к одному, между собой же они имеют отрицательные обратные связи на всех входах, кроме того, который связан с собственным выходом каждого нейрона — он имеет положительную обратную связь. Классификация объектов происходит на основе расстояния Хэмминга – меры

принадлежности объекта к некоторому классу в виде количества различающихся признаков у классифицируемого и эталонного образца [13].




Рис. 1.4. Структурная схема нейросети «Сеть Хэмминга»

**Сеть Ворда** (рис. 1.5) – нейронная сеть, содержащая три и более слоев, с прямым распространением сигнала. Отличается от остальных тем, что скрытые слои разбиты на некоторое количество блоков, использующих различные функции активации, таким образом, что в нейросети образуется соответствующее количество параллельных и независимых потоков обработки данных. Данная топология позволяет проводить оценку входящей информации сразу по нескольким критериям, что улучшает результаты работы, в частности, при распознавании образов и прогнозировании [14].

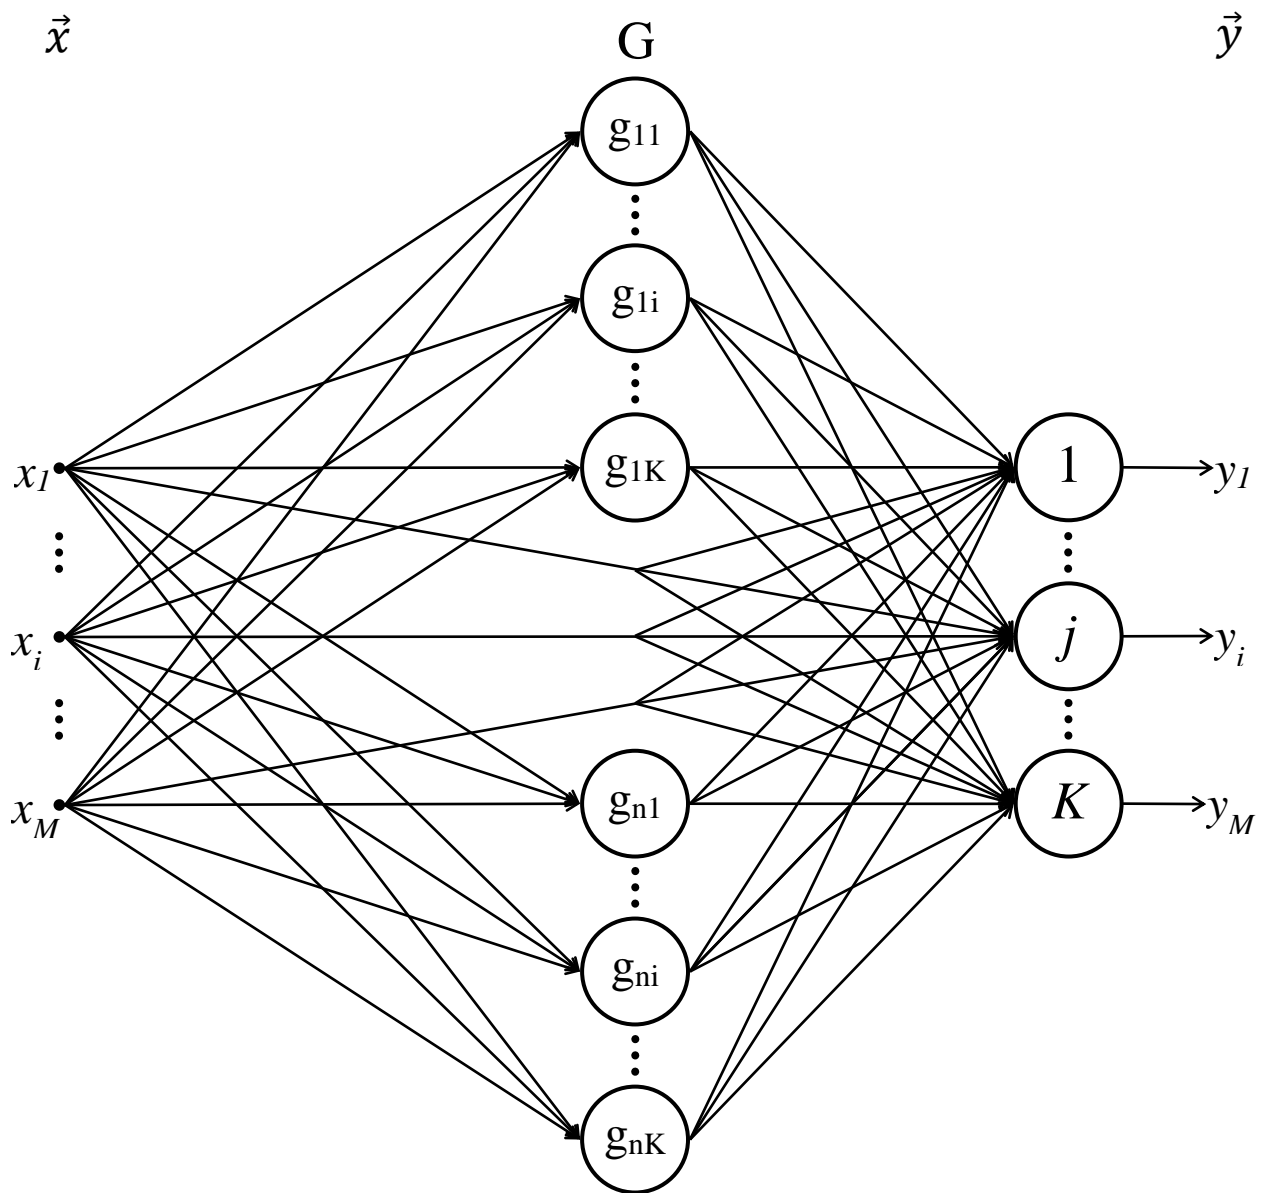


Рис. 1.5. Структурная схема нейросети «Сеть Ворда»

**Сеть Хопфилда** (рис. 1.6) – нейронная сеть, организованная по принципу полносвязности, имеет один слой. Значения входов и выходов – бинарные, из диапазона  $\{-1; 1\}$ . Может работать как автоассоциативная память (классификация объектов согласно ранее запомненным образам) или фильтр при восстановлении сигналов [12].




Рис. 1.6. Структурная схема нейросети «Сеть Хопфилда»

**Нейронный газ** – алгоритм создания и обучения нейронной сети для задач классификации, предназначенный для задач кластеризации данных и самостоятельно определяющий количество нейронов в сети и их пространственную структуру, а также веса связей между ними.

**Когнитрон** – нейронная сеть, состоящая из нескольких слоев, в каждом из которых можно выделить «тормозящие» и «возбуждающие» нейроны. Связи нейронов со следующего слоя распространяются не на весь предыдущий, а только на его «ближайших» соседей, однако области такого соседства перекрываются и в результате один нейрон первого слоя начинает пирамиду активизации, затрагивая с каждым слоем все больше нейронов. Указанная структура имитирует систему биологического зрения, где

находящиеся выше в иерархии слои могут распознавать все более абстрактные и сложные образы, в то время как первый понимает только элементарные геометрические фигуры – точка, линия. Когнитрон применяется для распознавания образов [15].

**Сеть радиально-базисных функций (RBF-сеть)** (рис. 1.7) – нейронная сеть с прямым распространением сигнала, с одним и более скрытыми слоями, использующая радиально-базисную функцию активации. Основное свойство такой функции – симметричное и монотонное относительно некоторой вертикальной оси уменьшение значения, например, функция Гаусса  $f(x) = e^{-\alpha(x-T)^2}$ . Может применяться для прогнозирования, классификации данных или управления [9].




Рис. 1.7. Структурная схема нейросети «Сеть радиально-базисных функций»

**Сеть Кохонена** (рис. 1.8) – нейронная сеть из двух слоев: пассивного входного и активного слоя Кохонена, состоящего из адаптивных линейных сумматоров. Различают самообучаемые и самоорганизующиеся варианты данного типа нейросетей. Как в случае самообучения, так и для самоорганизации число нейронов пассивного слоя определяется количеством значимых признаков объекта, однако число нейронов в активном слое различается: в самообучающейся ИНС оно эквивалентно заранее

определенному числу классов, а для самоорганизующейся – числу групп объектов, которые отличаются между собой более некоторой пороговой величины, при этом новый объект, проанализированный нейросетью, либо попадет в один из уже существующих кластеров, либо на его основе будет сформирован новый. Обычно нейросеть Кохонена используется для задач кластеризации или прогнозирования свойств, а также для уменьшения размерности данных без потери информации [10].

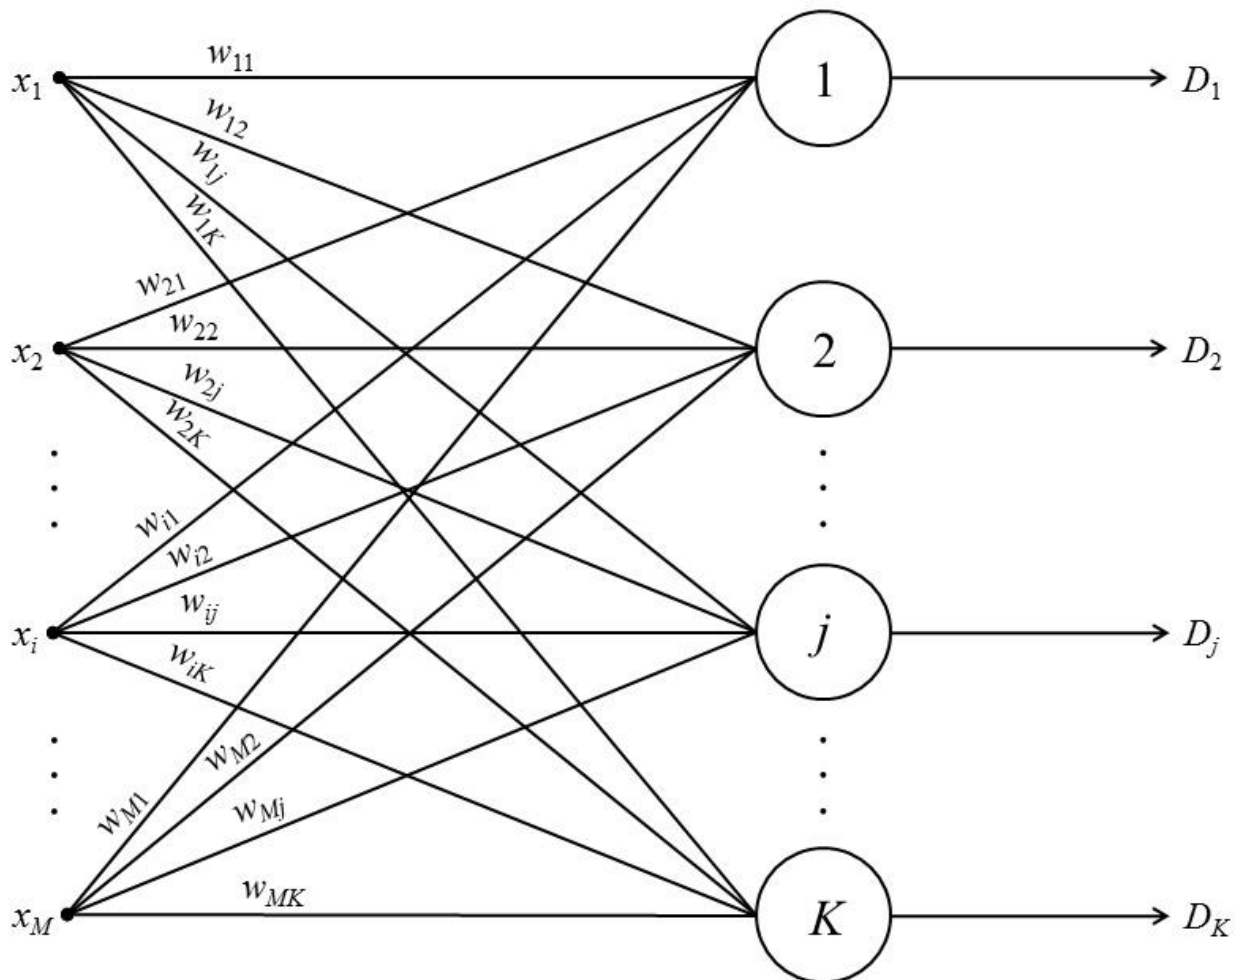


Рис. 1.8. Структурная схема нейросети «Сеть Кохонена»

**Сеть адаптивного резонанса** (рис. 1.9) – нейронная сеть, применяемая для классификации образов, использует в своей работе такие особенности головного мозга, как распознавание ранее встречавшихся образов и запоминание новых без ущерба для уже известных. Данная ИНС состоит из пассивного входного слоя и активного классифицирующего. Число нейронов

в пассивном слое равно числу признаков объекта, каждый его нейрон слоя связан с каждым нейроном активного слоя. Рассматриваемый тип нейросети имеет некоторые особенности, в частности, у нее нет фиксированного разделения на этап обучения и этап применения – она учится непрерывно, начиная с момента запуска; второй особенностью является то, что связь нейронов пассивного и активного слоев двойная: одна линия отвечает за кратковременную память, производящую первичную классификацию входного образа, вторая – за долговременную, которая окончательно определяет класс образа или формирует новый [11].




Рис. 1.9. Структурная схема нейросети «Сеть адаптивного резонанса»

Данная нейросеть относится к самоорганизующимся, то есть первоначально активный слой не содержит нейронов, он «накапливает» их по мере работы на основе образов, которые не были отнесены к какому-либо из уже существующих кластеров.

**Свёрточная нейронная сеть** (рис. 1.10) – нейронная сеть с несколькими слоями, является сетью прямого распространения, основное назначение – распознавание образов. В ходе обработки используется так называемая «матрица свертки», в которой закодирован тот или иной элементарный графический объект. После обработки очередного слоя набором матриц с различными типами объектов на следующем слое формируется карта расположения графических примитивов (или признаков наличия таковых), на основе которой нейросеть делает заключение о том, что находится на изображении [2].

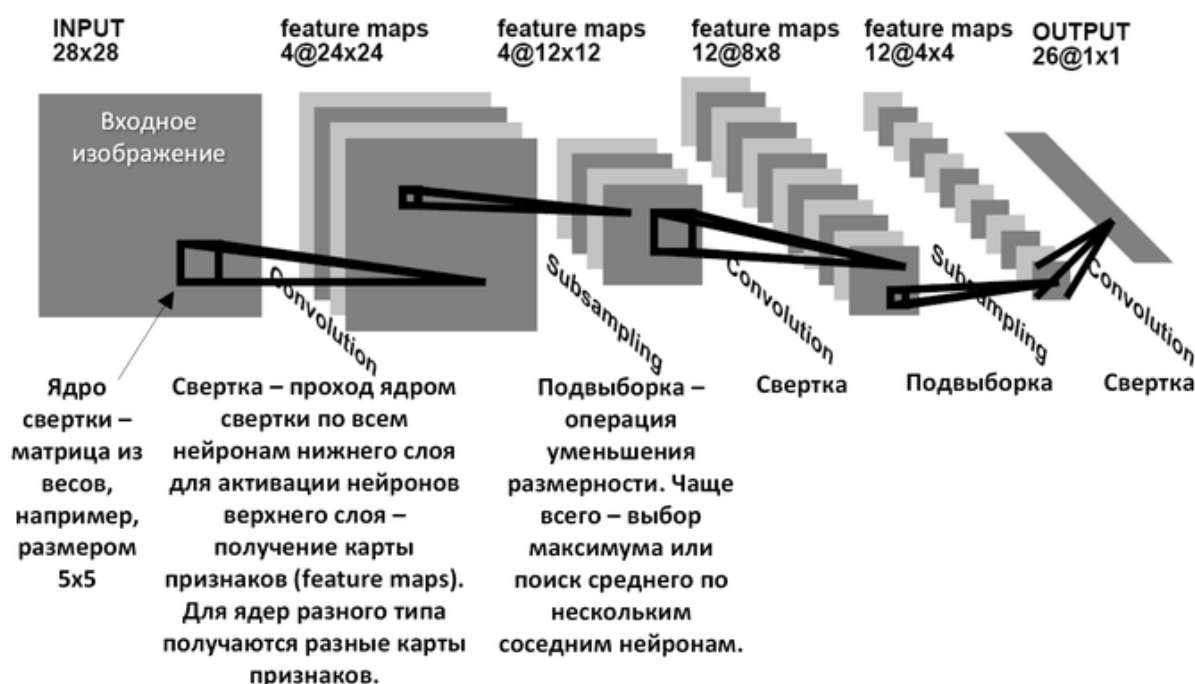


Рис. 1.10. Структурная схема нейросети «Свёрточная сеть»

Подавляющее большинство других сетей являются развитием какой-либо сети из списка выше, например, многослойный перцептрон Розенблатта, многослойный перцептрон Румельхарта, сеть Джордана, сеть

Элмана, неокогнитрон, хаотическая нейронная сеть, сеть встречного распространения, сеть обобщённой регрессии и другие.

### **1.3 Применение нейросетевых технологий в задачах обработки изображений**

В настоящее время степень использования нейросетей при работе с изображениями составляет лишь около 10% от всех возможных операций по преобразованию картинки, но в эту область входят наиболее сложные и трудно формализуемые задачи: распознавание образов (в том числе распознавание лиц и текста), поиск совпадающих изображений, восстановление зашумленных кадров.

Первая из перечисленных задач на сегодняшний день является также и одной из наиболее актуальных. Для ее решения теория нейронных сетей может предоставить несколько вариантов архитектуры ИНС, среди которых есть многослойные персептроны, сети адаптивного резонанса, сети радиально-базисных функций, сверточные нейросети. Само распознавание образов, или, другими словами, их классификацию, можно формально описать как определение принадлежности заданного объекта, который представлен набором значимых характеристик, к какому-либо классу из полного множества. Пороговые признаки каждого класса заранее выделены, поэтому фактически рассматриваемая задача сводится к сравнению характеристик объекта с каждым классом и выбор наиболее подходящего из них. В случае графических данных входной объект может быть как непосредственно исходным изображением, так и результатом какого-либо его предварительного преобразования. Примерами таких преобразований могут служить: бинарные матрицы, полученные в результате прохождения изображения через пороговый фильтр, обрабатывающий каждый пиксель в соответствии с некоторым правилом (по яркости, по наличию цвета, по свойствам окружающих пикселей); набор координат точек, составляющих

контур элемента изображения, найденного при помощи детектора границ Кэнни или его аналога; координаты ключевых точек на изображении (самые яркие, пересечения границ или линий, наиболее удаленные от некоторого центра). Предварительная обработка также может включать поворот, сжатие и растяжение, масштабирование и другие аффинные преобразования. Тип и порядок применяемых шагов предобработки зависит от выбранной архитектуры ИНС, так, например, для перцептрона желательно уменьшить количество возможных вариаций входных данных, приведя их к единому формату, в то время как для сверточной нейросети достаточно очистить картинку от шума или даже не производить никаких манипуляций – ИНС самостоятельно отфильтрует требуемую информацию, проведет ее анализ и определит принадлежность к тому или иному классу объектов.

Другая сфера применения нейросетей – восстановление изображений, имеющих поврежденные пиксели. Для этого, как правило, используются кластеризующие или классифицирующие ИНС – в процессе обучения они формируют «базу данных» сигнатур фрагментов с различными сюжетами, затем по ней проводится поиск наиболее подходящего к поврежденной области фрагмента, на основе которого и происходит восстановление.

Кроме того, стремительно развивается такая область, как стилизация изображений, то есть использование одного изображения в качестве фильтра для другого – в результате создается новая картинка, являющаяся комбинацией двух исходных. Данный функционал реализован доступным через Интернет сервисом «Ostagram» [16], пользователь которого может самостоятельно создавать шедевры изобразительного искусства наподобие того, который показан на рисунке 1.11.

Еще одна область применения нейросетей – превращение черно-белых изображений в цветные. Здесь наибольших успехов удалось добиться проекту «Colorful Image Colorization» [17], применившему для этого модифицированный вариант сверточной нейронной сети. Пример результата ее работы можно увидеть на рисунке 1.12.



Рис. 1.6. Пример стилизации изображения при помощи нейросети



Рис. 1.7. Пример восстановления цветности изображения при помощи нейросети

## **1.4 Анализ современного состояния аппаратно-программного обеспечения для моделирования работы искусственных нейронных сетей**

В настоящее время искусственные нейронные сети проектируются и реализуются в трех основных категориях: программные, аппаратные и гибридные [18].

Программные нейросети – при работе ИНС все ее элементы и характеристики, такие, как функция активации, веса связей между нейронами и их пространственная структура, представляют собой структурированные данные, хранящиеся в оперативной памяти компьютера, а сама нейросеть является обычной исполняемой программой. В этом варианте параметры нейросети задаются в программном коде или считываются из внешнего хранилища информации. Данный тип нейросетей является наиболее распространенным вследствие более низких затрат на создание готового продукта, его высокую универсальность, возможность переобучения ИНС. Недостатком по сравнению с аппаратными нейросетями является меньшее быстродействие, так как они выполняются на универсальных процессорах, не адаптированных под использование нейронных сетей. Программные нейросети вследствие присущего каждой программе свойства переносимости могут свободно распространяться или быть доступными через сеть Интернет в качестве веб-сервисов. Примерами данного класса нейросетей являются такие имитаторы ИНС, как [19]:

- ECANSE — предоставляет среду разработки для проектирования, моделирования и тестирования нейронных сетей и их применения для производства оптимизированного программного решения;
- Neural Network Framework — набор библиотек для создания нейронных сетей с произвольной топологией и смешанного типа нейронов. Включает в себя техническую информацию и почтовые рассылки;

- NeuroSolutions — среда разработки нейронных сетей с графическим интерфейсом. Поддерживает несколько типов сетей и алгоритмов обучения и другие.

Аппаратные нейросети – большинство или все составляющие части искусственной нейронной сети выполнены в виде дискретных или интегрированных компонентов, в этом случае ИНС в целом – это печатная плата и элементы на ней, как правило, нейропроцессор и периферийные устройства, которые могут быть реализованы в цифровом или аналоговом исполнении (рис. 1.13). Нейропроцессор представляет собой специализированную микросхему, которая адаптирована под нейросетевые вычисления. Типичными составляющими такой микросхемы являются коммутатор, регистры, блоки памяти и вычислительный модуль, содержащий матрицу умножения, триггеры, мультиплексоры и дешифраторы. При разработке нейропроцессоров, в частности, нейроморфных процессоров, применяется так называемая кластерная асинхронная архитектура, в которой используется большое количество параллельно соединенных ядер, каждое из них может имитировать работу сотен искусственных нейронов.




Рис. 1.8. Примеры нейропроцессоров

Роль нейропроцессора также может выполнять программируемая логическая интегральная схема (ПЛИС), которую проще производить, чем специальные микросхемы. Аппаратные ИНС являются специализированными устройствами, направленными на решение конкретной задачи и их разработка существенно дороже, чем для

программных нейросетей. В качестве примера аппаратной реализации можно привести [20]:

- Многокристальные полупроводниковые пластины Wafer Scale Integration фирмы Hitachi. На пластине размещается сеть Хопфилда с 576 нейронами, каждый из которых имеет 64 восьмиразрядных весовых коэффициента;
- ZISC036 (Zero Instruction Set Computer) фирмы IBM. Этот кристалл, первый в серии подобных, позволяет работать с 36 прототипами – входными векторами, которые отличаются от эталонных векторов больше некоторой пороговой величины. Кристаллы легко каскадируются для увеличения числа прототипов. Вектора состоят из 64 восьмиразрядных элементов. Пороговая величина расстояния выбирается любой. Входной вектор загружается последовательно за 3.5 микросекунды, и результат появляется через 0.5 микросекунды;
- Чип ANNA фирмы AT&T выполнен по цифровой технологии, но внутри использует конденсаторные заряды для хранения весов. Чип содержит 4096 весов, число нейронов варьируется от 16 до 256 с числом входов у нейрона 256 или 16, соответственно. Веса имеют точность 6 разрядов. Для однослойной сети с 64 входами и 64 нейронами достигается скорость  $2,1 * 10^9$  операций умножения значения входа на его вес и прибавления результата к общей сумме.

Гибридные или смешанные нейросети – данная технология совмещает в себе два предыдущих подхода, при этом обычно неизменные свойства ИНС, например, функция активации или пространственная структура, реализуются аппаратно, в то время как изменяющиеся характеристики наподобие весовых коэффициентов размещаются в оперативной памяти. Другим вариантом исполнения гибридной нейросети является программная реализация ее структуры, но в то же время входы и выходы – специальные датчики и индикаторы. По степени гибкости гибридная нейросеть занимает промежуточное положение – она способна к переобучению, но может решать

только определенный класс задач. Обычно подобные нейросети устанавливаются в микроконтроллеры и другие встраиваемые решения, например, распознавание лиц при съемке или опознание владельца по лицу в смартфонах [21].

### **Выводы по главе**

В результате обзора современных нейросетевых технологий для обработки изображений было установлено следующее:

- Нейросетевые технологии – это совокупность аппаратных и/или программных методов и средств обработки информации, использующих искусственные нейронные сети (ИНС). ИНС состоит из набора связанных в соответствии с определенным пространственным шаблоном искусственных нейронов, которые представляют собой элементарные вычислительные ячейки, функционирующие в соответствии с математической моделью работы реального биологического нейрона, базирующейся на следующих принципах: нейрон имеет несколько входов и только один выход, входы нейрона воздействуют на проходящий по ним сигнал, нейрон суммирует приходящие к нему сигналы и затем генерирует исходящий сигнал при помощи специальной функции (функции активации), которая определяет, как множество входных сигналов будут преобразованы в одиночный сигнал на выходе.
- Существуют три основных топологии нейросетей – полносвязная, многослойная и слабосвязная, различающиеся плотностью и характером соединений между отдельными нейронами.
- Функция активации служит для нормализации выходного сигнала. В качестве таковой может использоваться любая функция, удовлетворяющая критерию непрерывности на всей области определения, наиболее часто применяется сигмоид  $Y = \frac{1}{1+e^{-aS}}$ .

- В ходе жизненного цикла ИНС есть уникальная стадия, присущая только нейросетям – обучение. Данный этап представляет собой коррекцию весов связей между нейронами и, если это предусмотрено архитектурой нейросети, изменение ее топологии, с целью минимизации результирующей ошибки сети.
- Одним из наиболее широко используемых вариантов применения искусственных нейронных сетей в сфере обработки изображений является технология распознавания образов, суть которой заключается в формировании на основе входящих графических данных некоторого набора критериев и последующее сравнение полученного набора с эталонными образцами, характеризующими тот или иной класс объектов предметной области.
- Нейросети могут быть реализованы на практике в трех вариантах – как программные, аппаратные или гибридные. В первом случае все элементы и характеристики ИНС, такие, как функция активации, веса связей между нейронами и их пространственная структура, представляют собой структурированные данные, хранящиеся в оперативной памяти компьютера, а сама нейросеть является обычной исполняемой программой. Во втором – большинство или все составляющие части искусственной нейронной сети выполнены в виде дискретных или интегрированных компонентов, а ИНС в целом – это печатная плата и элементы на ней, как правило, нейропроцессор и периферийные устройства, которые могут быть реализованы в цифровом или аналоговом исполнении. Третий вариант предполагает совмещение первых двух, при этом обычно неизменные свойства ИНС, например, функция активации или пространственная структура, реализуются аппаратно, в то время как изменяющиеся характеристики наподобие весовых коэффициентов размещаются в оперативной памяти.

## **2 АНАЛИЗ ПРИНЦИПОВ ПОСТРОЕНИЯ И РАБОТЫ ИМИТАЦИОННЫХ СРЕДСТВ ИНС**

### **2.1 Принципы построения и работы современных нейроимитационных моделей**

Процесс построения нейроимитационной модели, или, другими словами, нейросети, начинается со сбора информации для ее обучения, причем набор данных должен обладать следующими свойствами: полностью характеризовать предметную область и не иметь внутренних противоречий, когда одни и те же исходные данные дают разный результат [6].

Далее при необходимости следует провести нормализацию входных данных, это особенно актуально в том случае, если размерности различных параметров отличаются друг от друга, и их фильтрацию для отделения шума.

Следующий шаг – создание непосредственно самой искусственной нейронной сети – начинается с построения архитектуры, которая выбирается исходя из поставленной задачи на основе анализа примененных ранее в аналогичных случаях вариантов. Если же до этого подобных ситуаций не возникало, следует ориентироваться на формальные признаки, позволяющие отнести решаемую задачу к той или иной категории, после чего эмпирическим методом выбирается наиболее подходящая конфигурация ИНС.

Основные категории задач, решаемых искусственными нейронными сетями: распознавание образов и классификация, принятие решений и управление, кластеризация, прогнозирование, аппроксимация данных, сжатие информации и ассоциативная память, анализ данных, оптимизация.

Четвертым шагом является выбор функции активации для искусственных нейронов. Здесь следует учесть, что некоторые архитектуры нейросетей, в частности, сеть Ворда, предусматривают различные функции активации для разных слоев или групп слоев ИНС. Основными параметрами

функции активации являются ее область определения (она должна быть непрерывной) и область значений, а также необходимость предварительной нормализации входных данных. Наиболее часто используемыми функциями активации с областью значений  $[0; 1]$  являются [2]:

- Пороговая функция:  $F(x) = \begin{cases} 1 & , \text{если } x > 0 \\ 0 & , \text{если } x \leq 0 \end{cases}$
- Кусочно-линейная функция:  $F(x) = \begin{cases} 1 & , x \geq \frac{1}{2} \\ x + \frac{1}{2} & , -\frac{1}{2} < x < \frac{1}{2} \\ 0 & x \leq -\frac{1}{2} \end{cases}$
- Сигмоидальная функция:  $F(x) = \frac{1}{1+e^{-\alpha x}}$ , где  $\alpha$  – коэффициент наклона сигмоиды.

В том случае, когда требуется область значений  $[-1; 1]$ , изменяются лишь формулы расчета:

- Пороговая функция:  $F(x) = \begin{cases} 1 & , x > 0 \\ 0 & , x = 0 \\ -1 & x < 0 \end{cases}$
- Кусочно-линейная функция:  $F(x) = \begin{cases} 1 & , x \geq \frac{1}{2} \\ x & , -\frac{1}{2} < x < \frac{1}{2} \\ -1 & x \leq -\frac{1}{2} \end{cases}$
- Сигмоидальная функция:  $F(x) = \tanh(x)$ .

Следующий этап реализации – это непосредственное построение архитектуры нейросети на некотором языке программирования либо физически, в зависимости от того, является ли создаваемая ИНС программной или аппаратной. В случае выбора программного варианта необходимо принять во внимание то, относится ли целевая топология нейросети к самообучаемым или ее структура фиксирована – в первом случае, в отличие от второго, нужно обеспечить возможность динамического изменения параметров ИНС во время ее работы; аппаратные нейросети могут быть только фиксированными. Как правило, при практической реализации искусственных нейронных сетей происходит четкое разделение топологии на

статические элементы, такие, как функция активации, и динамические, к которым относятся весовые коэффициенты связей между нейронами, поскольку для них используются различные по характеристикам объекты (конструкции языка программирования или блок микросхемы) – статические не могут изменяться во время работы, но обладают высоким быстродействием, динамические же поддерживают изменение, но это относительно медленный процесс.

Далее разработчик должен провести специализированную процедуру, которая не имеет аналогов в классическом программировании – обучение ИНС. Суть этого процесса состоит в том, чтобы при помощи специальных алгоритмов произвести коррекцию весов связей между нейронами (слоями нейронов) для получения на выходе нейросети того или иного сочетания сигналов в зависимости от комбинации значений на входе сети.

Так как это наиболее важный этап создания готовой к использованию искусственной нейронной сети, следует рассмотреть его более подробно.

Существуют две основные методики обучения – с учителем и без учителя. В первом случае для проведения процедуры обучения требуется набор парных данных – первый компонент из пары содержит то, что будет предъявлено на вход нейросети, а второй – то, что должно быть получено на ее выходе. Во втором случае ИНС должна иметь обратные связи либо алгоритм коррекции весов связей должен учитывать как входные, так и выходные значения для каждого нейрона, изменяя их так, чтобы для схожих наборов входных значений нейросеть генерировала одинаковый ответ [4].

Само обучение, как правило, проводят по общему алгоритму, состоящему из трех основных шагов – выбрать объект из обучающей выборки и вычислить для него ответ нейросети, оценить полученный результат, провести коррекцию весов сети. Все элементы обучающей выборки, при ее наличии, используются только один раз. Если была протестирована вся выборка, считается, что завершилась так называемая эпоха обучения, что позволяет оценить степень завершенности обучения,

количество прошедших эпох, длительность обучения и другие возможные критерии завершения обучения.

Перечислим основные методики коррекции весов: метод коррекции ошибки (и основанный на нем метод обратного распространения ошибки), обучение на основе опыта, правило Хебба, конкурентное обучение [2].

Суть метода коррекции ошибки, который может использоваться только при обучении с учителем, состоит в том, что результирующий ответ нейросети оценивается с точки зрения его отклонения от требуемого, то есть нахождения ошибки сети, при помощи которой затем производится коррекция весов на входах обучающегося нейрона в соответствии с так называемым дельта-правилом, определяющимся формулой (2.1), где  $w'_{jk}$  – новое значение веса связи между  $j$ -м и  $k$ -м – на текущем,  $w_{jk}$  – предыдущее значение указанного веса,  $\eta$  – параметр скорости обучения, характеризующий степень влияния ошибки сети на изменение веса связей на данной эпохе обучения,  $x_j$  – входящее значение сигнала со стороны  $j$ -го нейрона предшествующего слоя,  $e_k$  – величина ошибки сети для  $k$ -го нейрона текущего слоя.

$$w'_{jk} = w_{jk} + \eta x_j e_k \quad (2.1)$$

Обучение на основе опыта применяется в основном в задачах кластеризации или классификации и основывается на том, что «близкие» друг к другу объекты с большой вероятностью принадлежат одному и тому же кластеру (классу). Как правило, в нейросетях, обучающихся по данной методике, каждый нейрон выходного слоя обозначает тот или иной кластер, причем на входящий образ могут среагировать как один нейрон, что означает полное совпадение, так и несколько одновременно – совпадение частичное. Важной частью данной методики обучения является выбор меры оценки близости объектов (расстояние Хемминга, Евклидово расстояние и другие), а также определение области коррекции весов (только для нейрона, обозначающего найденный кластер, или для его «соседей» тоже).

Правило Хебба – методика изменения весов межнейронных связей, базирующаяся на следующем принципе: вес связи увеличивается, если оба нейрона, которые она связывает, активны и уменьшается, если активен лишь один из них или оба нейрона неактивны. Математически этот принцип можно выразить формулой (2.2):

$$w'_{jk} = w_{jk} + F(x_j, y_k) \quad (2.2)$$

где значения  $w'_{jk}$  и  $w_{jk}$  аналогичны таковым в формуле (2.1), а  $F$  – некоторая функция, которая зависит от  $x_j$  и  $y_k$  – состояния активности нейронов соответственно предыдущего и текущего слоев, связываемых корректируемой связью. В простейшем случае она может быть выражена при помощи формулы (2.3), где  $\eta$  – параметр скорости обучения, однако такая реализация опасна возникновением состояния перенасыщения при постоянной активности связи, поэтому лучше использовать формулу, представленную выражением (2.4), которая учитывает средние значения  $x_j$  и  $y_k$  –  $\bar{x}$  и  $\bar{y}$ , в таком варианте вероятность перенасыщения ниже.

$$F(x_j, y_k) = \eta x_j y_k \quad (2.3)$$

$$F(x_j, y_k) = \eta(x_j - \bar{x})(y_k - \bar{y}) \quad (2.4)$$

Конкурентное обучение, как и обучение на основе опыта, применяется для задач кластеризации, однако в нем ответ сети формирует только один активный нейрон выходного слоя. Этот тип обучения использует такие принципы, как: каждый нейрон имеет свою реакцию на входящий сигнал, величина выхода нейронов ограничена, нейрон с максимальным выходом активизируется, остальные – тормозятся. Формула коррекции веса связи для такого случая показана уравнением (2.5):

$$w'_{jk} = w_{jk} + \begin{cases} \eta(x_j - w_{jk}) & , \text{ если нейрон } k \text{ активен} \\ 0 & \text{ иначе} \end{cases} \quad (2.5)$$

Существование возможности обучения открывает широкие перспективы по использованию нейросетей одной и той же конфигурации в самых различных областях после профильного обучения.

Последний этап разработки – проверка качества обучения, для чего используются примеры данных, которые не участвовали в процессе обучения, при этом количество примеров должно быть обратно пропорционально требуемой вероятности появления ошибки.

## **2.2 Анализ особенностей построения и работы современных и перспективных искусственных нейронных сетей для обработки изображений**

Искусственные нейронные сети для обработки изображений в целом не отличаются по архитектуре и функционированию от нейросетей с другим назначением. Их разница проявляется в большем количестве нейронов в слоях и увеличенной сложности топологии ИНС вследствие того, что при работе с изображениями нейросеть имеет дело не с несколькими параметрами, характеризующими исследуемый процесс или объект, а с массивом точек (пикселей) всего изображения в целом, если же учесть еще и возможное изменение цвета точки – число входных параметров ИНС возрастет прямо пропорционально числу вариантов цвета пикселя или потребуется использовать предварительную нормализацию значений и функции активации, позволяющие принимать на вход вещественные числа. Поэтому для обработки изображений применяются в основном искусственные нейронные сети специальной архитектуры, обладающей свойством инвариантности относительно размеров входящего изображения, например, сверточная нейросеть. Другим подходом, который может применяться в случае обработки компонентных изображений, то есть таких, где структура пикселя представляется суперпозицией значений некоторого набора базовых цветов, например, красного, зеленого и синего, является независимая обработка каждого цветового канала отдельной нейросетью или отдельным блоком общей нейросети с последующим сведением полученных результатов в единое целое.

### **2.3 Анализ типов и возможностей нейроимитаторов NeuroIterator, NeuroPro, NeuroGenesis, Сегнейро**

Изучение доступной информации по искусственным нейронным сетям показало, что есть два пути провести моделирование работы ИНС на обычном персональном компьютере: первый – установить и настроить среду разработки и самостоятельно реализовать требуемый тип нейросети, и второй – использовать специализированную программу, которая позволяет создавать и обучать собственные искусственные нейронные сети на основе некоторой базовой конфигурации, после чего готовую ИНС можно извлечь из программы в виде отдельного модуля и использовать в прикладном проекте – нейроимитатор. Далее будут исследованы четыре примера таких нейроимитаторов: NeuroIterator, NeuroPro, NeuroGenesis и Сегнейро.

#### **Нейроимитатор NeuroIterator и его возможности [22].**

Основным назначением нейроимитатора является исследование нейронных сетей, однако, он может найти свое применение и в качестве нейросетевого классификатора или нейросетевой системы прогнозирования. Нейроимитатор написан на Borland C++ 5.02 с использованием библиотеки классов OWL 2.X. Нейроимитатор позволяет исследовать формируемые нейронные сети, нейронные сети с формируемой матрицей межнейронных связей и обучаемые нейронные сети.

Реализация формируемых нейронных сетей и сетей с формируемой матрицей межнейронных связей заключается в выборе моделей нейроподобных элементов, параметров их передаточных функций и структуры сети.

Нейроимитатор NeuroIterator имеет четыре базовых модели нейроподобного элемента - с линейной передаточной функцией, с сигмовидной передаточной функцией, с пороговой передаточной функцией и с функцией гауссова распределения. В NeuroIterator к параметрам

передаточной функции нейроподобного элемента относятся ее смещение, порог срабатывания и уровень насыщения, что в определенной мере приближает модели нейроподобных элементов нейроимитатора к биологическим нейронам. Каждая из базовых моделей нейроподобных элементов может иметь до 200 модификаций.

Формируемые нейронные сети и сети с формируемой матрицей межнейронных связей описываются при помощи внутреннего макроязыка. Макроязык нейроимитатора состоит из 9 операторов и позволяют описывать нейронные сети практически любой сложности.

- Оператор NEURONS определяет общее число нейроподобных элементов в сети. Число нейронов в сети не должно превышать 200.
- Оператор SIMTIME позволяет задать модельное время работы сети.
- Оператор TIMESTEP задает шаг моделирования работы нейронной сети.
- Оператор MODEL позволяет ассоциировать модель нейроподобного элемента с отдельным нейроном или с группой нейронов сети.
- Оператор SUSPEND позволяет определить число шагов ожидания, или иными словами, число шагов, в течение которых состояние отдельного нейрона или группы нейронов сети не изменяется.
- Оператор INITSTATE задает начальное состояние нейроподобного элемента или группы нейроподобных элементов сети.
- Оператор INPUTLAYER позволяет описать входной слой сети. Для каждого нейроподобного элемента сети в нейроимитаторе реализована возможность формирования активизирующей его функции.
- Оператор OUTPUTLAYER позволяет описать выходной слой нейронной сети. Число нейронов выходного слоя нейронной сети не должно превышать четырех.

- Оператор NETWORKLAYOUT позволяет описать структуру нейронной сети - входной, выходной и скрытые слои сети и задать весовые коэффициенты межнейронных связей.

- Оператор END завершает описание нейронной сети.

Результаты моделирования работы формируемых нейронных сетей и сетей с формируемой матрицей межнейронных связей могут быть представлены в виде графиков и числовых значений активности нейронов выходного слоя сети.

Нейроимитатор NeuroIterator позволяет также отследить динамику активности нейронов выходного слоя сети.

В том случае, если нейронная сеть воспроизводит функциональные зависимости, аналитические выражения которых известно, то с целью сравнения результатов работы сети с точными, предусмотрена возможность ввода этих аналитических зависимостей. Если нейронная сеть воспроизводит решение линейного дифференциального уравнения или нормальной системы дифференциальных уравнений, то в этом случае предусмотрена возможность сравнения результатов работы сети с результатами интегрирования дифференциального уравнения (системы дифференциальных уравнений) методом Рунге-Кутты 4-го порядка аппроксимации.

Последовательность формирования и исследования формируемых нейронных сетей и сетей с формируемой матрицей межнейронных связей:

1. Используя внутренний макроязык нейроимитатора описать структуру нейронной сети. Пример описания нейронной сети поставляется с демонстрационной версией программы.

2. Сформировать модели нейроноподобных элементов – кнопка «Создать модели нейронов» (рис. 2.2а), или выбрать соответствующую команду из локального меню (по правой кнопке мыши). Примеры моделей нейронов также поставляются с демонстрационной версией программы.

3. Проверить правильность описания нейронной сети – кнопка «Проверить описание» (рис. 2.2б), или соответствующая команда локального меню.

4. Если это необходимо, то сформировать активирующие нейроны входного слоя функциональные зависимости – кнопка «Создать входной слой» (рис. 2.2в), или команда локального меню. Нажать кнопку «Посчитать...».

5. Смоделировать работу нейронной сети – кнопка «Посчитать...» блока диалога «Проверка правильности описания нейронной сети».

6. Посчитать аналитические зависимости активности нейронов выходного слоя или проинтегрировать линейное дифференциальное уравнение (систему нормальных дифференциальных уравнений 4-го порядка) – кнопки «Аналитический расчет выходного слоя» и «Интеграция дифференциального уравнения» (рис. 2.2г и 2.2д соответственно).

7. Результаты работы нейронной сети: графики – кнопка «Показать графики» (рис. 2.2е), числовые значения: кнопка «Показать в цифрах» (рис. 2.2ж), динамика: кнопка «Показать динамическое представление» (рис. 2.2з).



Рис. 2.2. Пиктограммы панели инструментов нейроимитатора NeuroIterator

Нейроимитатор NeuroIterator работает также и с обучаемыми нейронными сетями, в частности, он может научить нейронную сеть с прямыми связями распознавать образы методом обучения с обратным распространением ошибки (back propagation online и back propagation randomized) либо выделять устойчивые признаки во входных образах по методу Хебба или по методу конкуренций.

Для обучения нейронной сети одним из вышеуказанных методов необходимо описать входной, выходной и, при их наличии, скрытые слои

сети. Описание слоя сети заключается в определении количества нейронов в слое, типа их передаточной функции и, для скрытых слоев сети, числа нейронных ансамблей. Число скрытых слоев не должно превышать десяти, а число нейронов в слое – 20. Число эталонных образов, по которым осуществляется обучение нейронной сети, практически не ограничено.

Нейроимитатор позволяет оценить точность восстановления эталонных образов. Кроме того, существует возможность исследовать работу обученной нейронной сети на промежуточных образах, т.е. образах, которые были опущены при формировании обучающей выборки.

По результатам обучения нейронной сети тем или иным методом, нейроимитатор позволяет сгенерировать файл описания нейронной сети, содержащий пороговые значения передаточных функций нейронов и веса межнейронных связей. Содержимое этого файла может быть использовано для создания и последующего исследования нейронной сети с прямыми связями как формируемой нейронной сети.

### **Нейроимитатор NeuroPro [23][24].**

Данный программный продукт представляет собой менеджер обучаемых искусственных нейронных сетей, позволяющий производить следующие базовые операции:

1. Создание нейропроекта;
2. Подключение к нейропроекту файла (базы) данных в формате dbf (dBase, FoxBase, FoxPro, Clipper) или db (Paradox);
3. Редактирование файла данных – изменение существующих значений и добавление новых записей в базу данных; сохранение файла данных в другом формате;
4. Добавление в проект нейронной сети слоистой архитектуры с числом слоев нейронов от 1 до 10, числом нейронов в слое – до 100;
5. Обучение нейронной сети решению задачи прогнозирования или классификации. Нейронная сеть может одновременно решать как несколько задач прогнозирования (прогнозирование нескольких чисел), так и несколько

задач классификации, а также одновременно задач и прогнозирования, и классификации.

6. Тестирование нейронной сети на файле данных, получение статистической информации о точности решения задачи;

7. Вычисление показателей значимости входных сигналов сети, сохранение значений показателей значимости в текстовом файле на диске;

8. Упрощение нейронной сети;

9. Генерация и визуализация вербального описания нейронной сети, сохранение вербального описания в текстовом файле на диске;

10. Выбор алгоритма обучения, назначение требуемой точности прогноза, настройка нейронной сети.

Обучение производится на некотором задачнике градиентными методами оптимизации, градиент вычисляется по принципу двойственности. В программе реализованы четыре алгоритма оптимизации: градиентный спуск, модифицированный ParTan, метод сопряженных градиентов, квазиньютоновский BFGS-метод. При создании нейропроекта в качестве алгоритма по умолчанию принимается ParTan. Изменение алгоритма осуществляется через пункты меню «Настройка» — «Метод оптимизации». Каждому примеру задачника соответствует запись (строка) файла данных. Для включения записи файла данных в задачник в записи должны присутствовать данные для всех полей, используемых нейронной сетью в качестве входных и выходных. Обучение прекращается при достижении заданной точности решения задачи либо при невозможности дальнейшей оптимизации.

Число входных и выходных сигналов сети ограничено максимальным числом полей в файле данных и не может в сумме превышать 255 или 511 (в зависимости от файла данных) сигналов. Каждому входному и выходному сигналу соответствует поле в файле данных. Однако при обработке качественных признаков каждому входному или выходному полю могут соответствовать несколько входных или выходных сигналов сети.

Нейронная сеть может обрабатывать только те поля в файле данных, которые содержат числовые значения. Из всего набора полей в файле данных можно выбрать отдельные поля для обработки нейросетью. Обрабатываемые поля могут быть непрерывными (количественными) и дискретными (качественными).

Каждое количественное поле в файле данных будет соответствовать одному входному или выходному сигналу сети. Перед подачей количественных входных полей нейронной сети происходит их нормировка в диапазон значений  $[-1,1]$  по каждому полю. Выходные сигналы сети нормируются в диапазон истинных значений.

От имеющихся в настоящее время нейросетевых программных продуктов данный продукт отличает наличие возможностей целенаправленного упрощения нейронной сети для последующей генерации вербального описания. При упрощении нейронной сети возможно выполнение следующих операций:

1. Сокращение числа входных сигналов нейронной сети путем удаления входных сигналов, наименее значимых для принятия сетью решения.
2. Сокращение числа нейронов сети путем удаления нейронов, наименее значимых для принятия сетью решения.
3. Комплексное равномерное упрощение нейронной сети. Для каждого нейрона сети выполняется сокращение числа приходящих на него сигналов до максимально возможного числа, задаваемого пользователем.
4. Сокращение числа связей в нейронной сети путем удаления связей, наименее значимых для принятия сетью решения.
5. Бинаризация связей в нейронной сети – приведение весов синапсов к значениям  $-1$  и  $1$  или значениям из более широкого набора выделенных значений.

Именно наличие развитых возможностей по упрощению сети в совокупности с построением ее вербального описания и придает

предлагаемому продукту новые потребительские свойства – возможность порождения знаний из таблицы данных. Под знаниями здесь понимается текст, объясняющий процесс решения нейронной сетью задачи. А поскольку одним из преимуществ нейронных сетей является возможность решения неформализованных задач классификации и прогноза (тех задач, явный алгоритм решения которых не известен), то данный текст предложит один из алгоритмов решения такой задачи.

Применение данного программного продукта возможно в тех областях, где нейронные сети традиционно и с успехом применяются, а именно, в медицине, экологии/климатологии/метеорологии, при построении моделей технических объектов и их идентификации, в экономике (прогнозирование курсов валют, акций и т.д.) и вообще для решения любой задачи классификации или прогноза, которая решается при наличии выборки данных и для решения которой ранее использовались традиционные математические методы (регрессионный анализ, непараметрическая статистика и другие), однако не была достигнута требуемая точность прогноза. Поскольку на основе одной таблицы данных может быть получено нескольких полуэмпирических теорий (нескольких нейронных сетей минимальной структуры, правильно решающих одну и ту же задачу), то возможно решение некоторых задач когнитологии и планирование оптимизирующего эксперимента.

В данной программе реализованы только сети слоистой архитектуры. В слоистой сети все нейроны сгруппированы в несколько слоев, нейроны внутри одного слоя могут работать параллельно. Каждый нейрон в слое принимает все выходные сигналы нейронов предыдущего слоя, а его выходной сигнал рассылается всем нейронам следующего слоя. Каждый нейрон сети имеет адаптивный сумматор, вычисляющий взвешенную сумму приходящих на нейрон сигналов, и следующий за ним нелинейный элемент. Веса адаптивных связей при создании сети принимают случайные значения и при обучении сети могут изменяться в диапазоне  $[-1,1]$ . В качестве

нелинейного элемента нейрона используется нелинейный сигмоидный преобразователь  $F(A)=A/(C+|A|)$ , где  $A$  – выход сумматора нейрона, а константа  $C$  – параметр крутизны сигмоиды. Число слоев в сети задается пользователем. Обычно не стоит задавать больше трех слоев нейронов. Число нейронов в слоях может быть различным и не зависеть от числа входных и выходных сигналов сети.

Каждый входной сигнал сети подается всем нейронам первого слоя. В данной программе после нейронов выходного слоя строится слой адаптивных сумматоров с числом сумматоров, равным числу выходных сигналов, и с этих сумматоров снимаются выходные сигналы сети. Перед подачей сети все входные сигналы нормируются в диапазон  $[-1,1]$ , а сигналы выходных сумматоров нормируются в диапазон истинных значений выходных сигналов.

### **Нейроимитатор NeuroGenesis [25].**

В программе Neurogenesis реализованы следующие основные функции: создание проекта ИНС, заполнение задачника примерами, инициация процесса создания ИНС, вычисление выхода ИНС.

Neurogenesis обладает двумя важными свойствами: использует эволюционную оптимизацию структур ИНС и параллельные вычисления.

Программный комплекс состоит из следующих модулей верхнего уровня декомпозиции: клиент, обработчик запросов, база примеров, база моделей, планировщик заданий, исполнитель заданий, нейронная сеть, предобработчик.

Neurogenesis функционирует в режиме сервера, что позволяет использовать его функциональность в прикладном программном обеспечении. Программное обеспечение способно автоматически подбирать структуру ИНС с учителем. Для синтеза ИНС, наряду с традиционными методами обучения, используются эволюционные алгоритмы. Осуществляется автоматическая декомпозиция задачи обучения. Реализованы механизмы распараллеливания вычислений. При использовании

программы пользователь должен определить предположительно значимые показатели, собрать данные и поставить задачу в виде задачи синтеза классификатора по примерам.

Связь с нейроимитатором осуществляется путем обмена сообщениями по протоколу TCP/IP. Все сообщения представлены в формате XML. Реализован клиент нейроимитатора по технологии ActiveX. Клиент скрывает детали сетевого обмена и формата XML. Он позволяет обращаться к нейроимитатору из документов MS Excel, MS Word и множества других сред, поддерживающих технологию ActiveX. Все модули нейроимитатора могут исполняться с низким приоритетом. В этом случае на компьютерах могут без проблем выполняться другие задачи. Например, офисные приложения, системы управления базами данных и т.п.

Модуль «Исполнитель заданий» может быть установлен на нескольких компьютерах, объединенных в сеть, в том числе на том, где установлен сервер программы. Это могут быть компьютеры, подключенные к локальной сети или Internet. Нейроимитатор не вводит ограничений на количество используемых компьютеров. При переборе вариантов ИНС все компьютеры параллельно выполняют генерацию новых структур и обучение ИНС. Здесь используется свойство параллельности эволюционных вычислений. При решении реальных задач затраты на передачу данных по сети намного меньше, чем затраты на создание ИНС. Увеличение количества задействованных компьютеров ведет к улучшению результатов моделирования, так как может быть перебрано большее количество вариантов ИНС.

Используются средства поддержки симметричной многопроцессорности (SMP), предоставляемые операционной системой. Компонент «Исполнитель заданий» позволяет создавать и оценивать одновременно несколько вариантов ИНС в параллельных вычислительных потоках.

**Нейроимитатор Сигнейро [26].**

Сигнейро - нейроимитатор, позволяющий обучить нейронную сеть обработке изображений. Он предназначен для быстрого конструирования алгоритмов преобразования изображений. От пользователя требуется предоставить программе исходные изображения и результаты, которые должны получиться после их обработки. Обучение происходит на основе формируемых локальных признаков изображения, вычисляемых для каждой точки. Для обучения нейронной сети используется генетический алгоритм. После обучения автоматически создается динамическая библиотека с функцией преобразования (либо сегментации) изображения. Данную библиотеку с готовым алгоритмом можно подключить к собственным разработкам. Имеются примеры ее подключения к тестовым программам, написанным на разных системах программирования.

Дополнительно программа включает в себя два вспомогательных инструмента: “Обработка изображений” с основными функциями обработки изображений и “Разметка изображений” для формирования обучающей выборки. Программа окажет большую помощь при разработке программ преобразования различного класса изображений. В разработке использовались методы обработки изображений, искусственного интеллекта, теории алгоритмов и эвристики.

#### Системные требования

- Windows 2000, XP, Vista, 7.
- Процессор с тактовой частотой 1,5 ГГц или выше.
- 1 Гб ОЗУ (данный параметр сильно зависит от размеров и количества обрабатываемых изображений, приведенное значение рассчитано для обучения на 10 изображениях размера 800 на 600 точек.).
- 512 Мб свободного места на жестком диске.
- Цветной монитор с разрешением не менее 800 на 600 пикселей с глубиной цвета 16 бит.

Общий порядок работы в программе:

После запуска программы нужно создать новый проект. По умолчанию он имеет название “Project1”, но его легко можно переименовать. Далее необходимо установить параметры проекта. Рекомендуется это выполнять в следующей последовательности:

1. Устанавливается путь к папке с обучающей выборкой (параметр “Исходные изображения”).

2. Задаются параметры обучения. В программе реализован генетический алгоритм обучения, поэтому параметры “количество особей” и “процент мутаций” являются параметрами генетического алгоритма. Если вы не знакомы с теорией генетических алгоритмов, используйте эти параметры по умолчанию. Параметр “Точность/скорость” указывает программе процент точек на исходных изображениях, которые будут учитываться при обучении. Чем меньше эта величина, тем быстрее будет происходить обучение, но может уменьшиться точность оценки качества обучения.

3. Указывается вид выходных данных.

4. Задаются признаки, которые будут участвовать в процессе сегментации. Выбор признаков реализуется на вкладке “признаки”. Пункт «Признак» – выбирается сам признак (названия признаков отображаются при раскрытии списков в соответствующем столбце). Пункт «Размер» – устанавливается размер квадратной окрестности, по которой формируется значение локального признака для каждой точки. Если использовать число  $A$ , то локальный признак вычисляется в окрестности  $(2A+1) * (2A+1)$  точек. Если использовать запись  $1/A$ , то сторона окрестности в  $A$  раз меньше средней длины сторон изображения. Пункт «Компонента» – Выбирается  $Y$ ,  $R$ ,  $G$  или  $B$ .  $Y$ -для формирования признака используется яркостная компонента изображения. Если исходные изображения полутоновые (в градациях серого), используйте только компоненту  $Y$ . Выбирая  $R$ ,  $G$ ,  $B$  – используете, соответственно, красную, зеленую или синюю компоненту изображения. Для профессиональной работы рекомендуется подбирать признаки самостоятельно, однако, в программе реализована функция

автоподбора признаков, которая автоматически составит весь набор, исключив признаки, практически не влияющие на результат обучения.

5. Обучение обработке/сегментации изображений. Для обучения нажмите на кнопку “Начать обучение”. Важным параметром, который представляет интерес на этом этапе, является “Достигнутый результат”. Его величина прямо пропорциональна степени обученности и обновляется каждое поколение генетического алгоритма. Динамика изменения величина отображена на графике нижней части окна. Нулевому значению соответствует начальный уровень (не выделено ни одного объекта). Значению 100 соответствует результат обучения, полностью идентичный обучающей выборке. В процессе обучения видно, как эта величина постепенно растет, следовательно, алгоритм действительно обучается. Как только вы решите завершить процесс (целесообразно это сделать тогда, когда улучшений уже не наблюдается), нажмите на кнопку “Закончить обучение”.

6. Визуализация результатов обучения. Визуально посмотреть на результат обучения можно как в процессе обучения, так и после его завершения (остановки). Для этого перейдите на вкладку “Визуализация”. Кнопками со стрелками влево и вправо выполняется переход от одного изображения к другому. При нажатии на кнопку “Крупным планом” выполняется переход на форму, отображающей результаты обучения в увеличенном виде. При желании, используя инструменты верхней панели, можно изменить параметры визуализации: цвет выделяемых объектов, прозрачность. Можно выделять объекты по контуру.

В программе Сигнейро реализованы различные операторы преобразования изображений, которые доступны пользователю. В их число входят: средняя яркость по окрестности, среднеквадратическое отклонение по окрестности, медиана окрестности, негатив изображения, пороговая бинаризация, выравнивание гистограммы, средний градиент по горизонтали и по вертикали, контрастирование границ, скелетизация и другие. Комбинируя их, можно построить алгоритмы обработки изображений

различного класса. Рассмотрим пример построения алгоритма для получения линий контуров объектов. Запустите программу и выполните пункт меню “Инструменты/Обработка изображений”. Перед Вами появится инструмент программы, с помощью которого можно выполнять различные операции над изображениями, создавая таким образом требуемый сценарий. Данный сценарий как алгоритм обработки изображений несложно подключить к собственным разработкам. Для этого, прежде всего, необходимо его сохранить (кнопка на панели инструментов). Весь сценарий записывается в один файл с названием `gendata.xml`. Инструкции по включению сценария в собственные разработки даны в следующих разделах этой главы. Генерация кода. Код, который реализует логику обученного алгоритма, можно сгенерировать, перейдя на вкладку “Программный код” окна результатов обучения нейронной сети. Код генерируется для языков программирования C#, C++, Pascal, Java, VBasic, Matlab, PHP.

Формирование обучающей выборки является первым этапом к решению задачи конструирования алгоритма обработки изображений. Данный этап является обязательным и оказывает значительное влияние на результат обучения, то есть на качество сконструированного алгоритма. Обучающая выборка представляет собой набор пар изображений. Первое изображение в паре является исходным, а второе – тем изображением, которое должно получиться в процессе его преобразования. При формировании выборки необходимо руководствоваться следующими особенностями:

1. Необходимо правильно именовать файлы с изображениями выборки: «исходное изображение» – «требуемое изображение» (первая пара: `1.bmp` и `1n.bmp`; вторая пара: `2.bmp` и `2n.bmp`; и так далее).

2. Чем больше изображений входит в обучающую выборку, тем дольше будет выполняться обучение, но тем более адаптивным по отношению к исходным изображениям будет выходной алгоритм.

3. Как правило, изображения, которые входили в обучающую выборку, после обучения будут обрабатываться лучше, чем изображения, которые в нее не входили.

Когда задача поставлена и обучающая выборка сформирована, следует переходить к подбору признаков, по которым программа будет обучаться обрабатывать изображения. Важно правильно подобрать признаки для достижения наилучшего показателя точность результата/скорость обработки. Однако следует заметить, что задача оптимального формирования набора признаков сложна и точных рекомендаций для нее не существует. Ее следует решать эмпирически. Возможно, что подбор признаков лучше всего будет выполнять опытным путем, проводя ряд экспериментов с обучением.

Советы при формировании набора признаков:

1. Чем больше признаков Вы используете, тем на более хороший результат можете претендовать, но тем большее количество времени будет проходить обучение и тем более затратным по времени будет выходной алгоритм.

2. Необходимо отдавать предпочтение признакам, имеющим меньшую временную сложность для большей скорости работы выходного алгоритма.

3. Если обрабатываются полутоновые изображения, рекомендуется использовать для всех признаков одинаковую компоненту (например, Y).

4. Можно использовать один и тот же признак в одном цикле обучения, но с разным размером окрестности.

### **Выводы по главе**

В ходе анализа принципов построения и работы имитационных средств ИНС были получены следующие результаты:

- Основными этапами создания искусственных нейронных сетей являются: сбор репрезентативных данных для ее обучения, нормализация данных (при необходимости), выбор архитектуры

ИНС, выбор функции активации, построение архитектуры (программное или аппаратное), обучение, проверка качества обучения.

- Наиболее используемые функции активации: пороговая, кусочно-линейная, сигмоидальная.
- Есть две базовые схемы обучения: с учителем и без учителя.
- Основные шаги процесса обучения (независимо от схемы): выбор тестового объекта, вычисление ответа нейросети, оценка полученного ответа, коррекция весов связей.
- Существуют следующие методы коррекции веса связей: метод коррекции ошибки (и основанный на нем метод обратного распространения ошибки), обучение на основе опыта, правило Хебба, конкурентное обучение.
- Нейронные сети для обработки изображений отличаются от ИНС другого предназначения увеличенной сложностью топологии, что дает возможность сократить размерность обрабатываемых данных путем выделения в них характерных признаков либо обеспечить параллельную работу с данными, если важно минимизировать потери информации.
- Разработаны специализированные программные средства, позволяющие самостоятельно проектировать и реализовывать искусственные нейронные сети, которые после прохождения обучения можно преобразовать в автономные модули с целью использования в сторонних разработках - нейроимитаторы. Примерами таких программ могут служить NeuroIterator, NeuroPro, NeuroGenesis, Сигнейро.
- Основные возможности нейроимитаторов: формирование любых типов нейросетей; наличие нескольких вариаций функции активации, настроечных параметров для нее, встроенный

анализатор качества построения нейросети, развитые средства управления процессом моделирования (пошаговое, остановка по условию, возврат); оптимизация сформированной нейросети; экспорт обученной нейросети в виде самостоятельного модуля для подключения к сторонним программным проектам.

### **3 ИССЛЕДОВАНИЕ ВОЗМОЖНОСТЕЙ НЕЙРОИМИТАЦИОННЫХ СРЕДСТВ ПО ОБРАБОТКЕ ИЗОБРАЖЕНИЙ**

#### **3.1 Исследование возможностей ассоциативной сети Хопфилда**

Ассоциативная сеть Хопфилда является одним из вариантов реализации специального класса искусственных нейронных сетей под названием «автоассоциативная память», представителям которого присуща характерная особенность – способность запоминать поданные на вход образы в их исходном виде [12].

Структурную схему ИНС Хопфилда можно увидеть на рисунке 1.6.

С формальной точки зрения ассоциативная сеть Хопфилда – это полносвязная (выход каждого нейрона связан с входами всех нейронов сети, кроме самого себя) рекуррентная (присутствует обратная связь) однослойная нейронная сеть, рассчитанная на обучение по фиксированной формуле за одну итерацию. Число нейронов в слое соответствует количеству параметров классифицируемого объекта (образа).

Свойство запоминания входящих образов в ассоциативных сетях проявляется как следствие рекуррентности – ответ нейросети по мере прохождения итераций сходится к некоторому устойчивому состоянию, называемому аттрактором, а набор исходных образов, обработка которых приводит к нему – сферой притяжения аттрактора. Именно достижение аттрактора свидетельствует об окончании работы ИНС и наличии у ее готового ответа. Вместе с тем, если входящие данные таковы, что нейросеть не может выявить их однозначного соответствия только одному из хранящихся в ней образов, возможно формирование не статического, а динамического аттрактора, когда образ на выходе ИНС совершает периодические колебания между наиболее похожими на исходные данные аттракторами.

Нейросеть Хопфилда может использоваться в задачах классификации, в качестве фильтра данных, для нахождения экстремумов сложных функций.

Данный тип нейросети оперирует только бинарными значениями, собранными в вектор, поэтому исходные данные должны быть соответствующим образом подготовлены: во-первых, переведены в двоичную форму (используются пары «-1» и «1» или же «0» и «1»), во-вторых, при обработке образов с размерностью два и более они сводятся к одномерному вектору.

Жизненный цикл ассоциативной сети Хопфилда включает в себя две четко разграниченные стадии – обучение и практическое использование.

На стадии обучения, которая проводится за один проход, вычисляются все веса связей между нейронами сети по формуле (3.1), после чего сеть считается готовой к работе.

$$w_{ij} = \begin{cases} \frac{1}{M} \sum_{d=1}^N X_{id} X_{jd} & , \text{ если } i \neq j, \\ 0 & \text{ иначе} \end{cases} \quad (3.1)$$

где:  $M$  – размерность входного вектора,  $N$  – количество запоминаемых векторов,  $d$  – номер запоминаемого вектора,  $X_{ij}$  –  $i$ -й элемент  $j$ -го выходного вектора.

На стадии практического применения для получения ответа нейросети используется следующий алгоритм:

1. Весовая матрица  $W$  умножается на входной вектор  $X$  (3.2), после чего к полученному вектору применяется пороговая функция активации (3.3).

$$Y = WX = \sum_{i=1}^M w_{ij} x_i \quad (3.2)$$

$$Y' = F(Y) \quad (3.3)$$

2. Во входном векторе  $X$  один из элементов, начиная с первого, заменяется на соответствующий элемент выходного вектора  $Y'$ ,

давая в результате вектор  $X'$ . Если достигнут конец вектора, то замена начинается снова с первого элемента.

3. Если вектор  $X$  равен вектору  $X'$ , то принять вектор  $Y'$  как ответ нейросети и завершить выполнение, иначе повторить пункт 1 с использованием в качестве входного вектор  $X'$ .

Данный алгоритм предполагает абсолютную сходимость нейросети к одному статическому аттрактору, однако возможна ситуация, когда возникнет динамический аттрактор, то есть вектор  $Y'$  будет периодически повторять последние  $k$  своих значений ( $k \in [1; \infty)$ , при  $k = 1$  происходит вырождение в статический аттрактор). На практике принимают  $k = 2$ , отслеживая ситуацию  $Y'(t - 3) = Y'(t - 1) \cap Y'(t - 2) = Y'(t)$ , где  $t$  – номер эпохи обучения, для выхода из цикла. Ответом нейросети будет запомненный на стадии обучения эталонный вектор, наиболее соответствующий входному образу.

Преимуществами ассоциативной сети Хопфилда являются ее быстроедействие и простота реализации, в том числе на аппаратных компонентах, недостатком – низкое по отношению к числу связей между нейронами количество запоминаемых векторов-образов, вычисляемое по формуле (3.4) – для распознавания 10 цифр требуется около 340 нейронов и около 115600 связей между ними.

$$N \leq \frac{M}{4 \log_2 M} \quad (3.4)$$

Возможности данного типа нейросетей по обработке изображений ограничены тем, что, во-первых, она может проводить операции только над бинаризованными векторами, в то время как реальные изображения являются полноцветными либо монохромными, и, во-вторых, их большая площадь (414720 точек для стандартного разрешения 720 на 576) в сочетании с низким КПД ИНС делает бесперспективной обработку всей поверхности картинки за один проход. Выйти из этого положения можно при помощи разбиения изображения на небольшие участки, например, квадраты с длиной

стороны в 8, 10, 16 пикселей, и отдельной обработки каждого возможного значения компонент цвета. Разумеется, такое разделение означает, что для обработки полной палитры из  $16777216^1$  цветов потребуется 8388608 отдельных нейросетей, при условии, что каждая ИНС будет отвечать за свою пару цветов. Данное количество можно уменьшить, если допустимо использование ограниченной цветовой палитры, например, 256-цветной либо 16-битной – это уменьшит число вариаций цвета и, соответственно, требуемое количество экземпляров нейросети. В случае использования процессоров с высокой производительности даже такое количество ИНС, работающих одновременно, не должно испытывать сильную потерю скорости выполнения операций из-за простоты архитектуры, однако низкая емкость памяти нейросети Хопфилда является сильным препятствием на пути ее использования в высоконагруженных проектах.

### **3.2 Исследование возможностей ассоциативной сети Хэмминга**

Ассоциативная сеть Хэмминга является результатом развития идей, лежащих в основе ассоциативной сети Хопфилда, вследствие чего она имеет сходные функциональные признаки и область применения – классификация данных. Особенность данной искусственной нейронной сети – это использование в качестве средства оценки близости двух объектов расстояния Хэмминга, то есть числа различающихся значений параметров этих объектов [13].

Структурную схему ИНС Хэмминга можно увидеть на рисунке 1.4.

От своего предшественника, ассоциативной сети Хопфилда, она унаследовала два режима работы – обучение и практическое использование, тип обрабатываемых данных – бинарные вектора (и, как следствие, необходимость предварительной подготовки информации), полносвязную

---

<sup>1</sup> Диапазон значений каждого компонента в цветовом пространстве RGB – от 0 до 255, следовательно, общее число комбинаций для трех компонентов равно  $256^3$  в кубе – 16777216.

архитектуру и свойство рекуррентности, а также длительность обучения в одну итерацию.

Вместе с тем есть и отличия, среди которых можно отметить:

- Добавление перед полносвязным слоем еще одного, который должен провести начальную обработку параметров входящего объекта, после чего их можно передавать на второй слой;
- Изменение функций для вычисления весов;
- Число нейронов в обоих слоях одинаково и равно количеству эталонных образов (классов);
- Ответ сети теперь представляет собой индекс результирующего образа вместо него самого.

Обучение проводится по следующему алгоритму:

1. Формируется матрица эталонных векторов  $X(NM)$ , где  $N$  – количество векторов,  $M$  – число признаков объекта.
2. Формируется матрица коэффициентов первого слоя согласно формуле (3.5):

$$w_{ij} = \frac{x_{ij}}{2} \quad (3.5)$$

3. Вычисляются параметры функции активации (3.6):

$$F(x) = \begin{cases} 0 & , x \leq 0 \\ x & , 0 < x \leq T, \\ T & x > T \end{cases} \quad (3.6)$$

где  $T = \frac{M}{2}$

4. Формируется матрица коэффициентов второго слоя путем применения формулы (3.7):

$$\varepsilon_{ij} = \begin{cases} 1 & , i = j \\ -\varepsilon & , i \neq j \end{cases} \quad (3.7)$$

где  $\varepsilon = (0; \frac{1}{N}]$ .

5. Устанавливается критерий оценки сходимости решения  $E_{max}$  в виде максимальной разницы ответа сети в двух последовательных итерациях.

Для классификации неизвестного вектора  $x^*$  при практическом использовании нейросети Хэмминга требуется выполнить следующие действия:

1. Рассчитать состояния нейронов первого слоя по формуле (3.8), затем применить к ним функцию активации (3.6), получив в результате вектор входных значений для второго слоя  $y$ :

$$x_j = \sum_{i=1}^M w_{ji} x_i^* + T \quad (3.8)$$

2. Принять первоначальные выходные значения для второго слоя равными вектору  $y$  и начать циклический процесс, используя для вычисления состояний нейронов функцию (3.9) и применяя к полученным данным функцию активации (3.6) для нахождения очередного ответа сети.

$$y'_j = y_j - \varepsilon \sum_{\substack{i=1 \\ i \neq j}}^N y_i \quad (3.9)$$

3. Цикл в пункте 2 продолжается до выполнения условия схождения (3.10):

$$\|y' - y\| \leq E_{max} \quad (3.10)$$

После схождения нейросети в нормальной ситуации ее ответом должен быть вектор с единственным положительным элементом (остальные отрицательные или нулевые), индекс которого будет указывать на искомый класс. Если положительных элементов несколько, это означает, что ИНС затруднилась с определением конкретного класса и показывает лишь наиболее подходящие для классифицируемого объекта.

Нейросеть Хэмминга отличается от нейросети Хопфилда в лучшую сторону тем, что в результате итераций на полносвязном слое она всегда сходится к статическому аттрактору, давая таким образом однозначный ответ о принадлежности тестируемого объекта к некоторому классу.

К преимуществам данной нейросети можно отнести низкий расход памяти, высокое быстродействие, простоту создания, независимость емкости сети (числа запоминаемых образов) от количества характеризующих их параметров. Основной недостаток – ответ сети в виде индекса образа вместо него самого, что не всегда приемлемо.

Применение ИНС Хэмминга для обработки изображений более выгодно, чем нейросети Хопфилда, за счет отсутствия ограничений на количество эталонных образов, однако в ней наиболее узким местом становится неспособность работать со значениями, не принадлежащими множеству  $\{-1; 1\}$ , как целыми, так и вещественными, что является серьезным недостатком в случае обработки полноцветных изображений, когда в результате требуется получить весь набор цветов, присутствовавший на исходной картинке. Здесь, как и для нейросети Хопфилда, потребуется разделить входящее изображение на некоторое количество «слоев», каждый из которых содержит только два цвета, таким образом, их общее число определяется как число используемых в изображении цветов, деленное на два, с округлением до целого числа в большую сторону – если не проводить индивидуальную оценку каждой картинке, а создавать универсальную систему, данная величина будет иметь значение в 8388608 отдельных экземпляров нейросети. Такой метод достаточно прост в реализации, хотя и требует последующей синхронизации результатов, полученных от каждой ИНС для формирования выходного изображения, однако он весьма ресурсоемок, особенно по отношению к требуемой памяти, но без его применения круг задач, которые способна решать нейросеть Хэмминга в приложении к графическим данным, резко сужается – остаются только те, которые не требуют результат в виде готового изображения, например, классификация или распознавание образов. Что касается размеров обрабатываемой области – теоретически препятствий для одновременной работы со всей исходной картинкой нет, но на практике данный подход может быть неприменим из-за аппаратных ограничений на количество

оперативной памяти, поэтому обычно используются так называемые «окна» в виде квадрата, длина стороны которых подбирается эмпирически.

### 3.3 Исследование возможностей нейронной сети Кохонена

Нейронная сеть Кохонена – однослойная искусственная нейронная сеть, основанная на разработанном в 80-х годах 20 века Т. Кохоненом слое адаптивных линейных сумматоров. Данная ИНС обучается без учителя.

Структурную схему ИНС Кохонена можно увидеть на рисунке 1.8.

Существует две вариации нейросети Кохонена:

- С фиксированной структурой – количество нейронов в активном слое определяется ожидаемым числом кластеров в обучающей выборке, общее количество связей между нейронами вычисляется из произведения числа значимых признаков исследуемого объекта на число нейронов слоя Кохонена.
- С динамической структурой – изначально нейросеть не содержит нейронов в активном слое, новые нейроны (и соответственно межнейронные связи) формируются самостоятельно в процессе обучения ИНС.

Нейросеть Кохонена оперирует с вещественными числами, но требует нормализации входных значений в пределы  $[-1; 1]$  либо  $[0; 1]$ , по выбору пользователя.

Жизненный цикл исследуемой нейросети состоит из трех этапов – обучения, кластерного анализа и практического использования.

На первом этапе, в зависимости от типа структуры, используются различающиеся алгоритмы обучения, а также следующие формулы [10]:

$$\left\{ \begin{array}{ll} w_{ij} \leq \frac{1}{\sqrt{M}} & \text{– для предела нормализации } [-1; 1] \\ 0.5 - \frac{1}{\sqrt{M}} \leq w_{ij} \leq 0.5 + \frac{1}{\sqrt{M}} & \text{– для предела нормализации } [0; 1] \end{array} \right. \quad (3.5)$$

где  $M$  – число входных значений сети.

$$R_j = \sqrt{\sum_{i=1}^M (\tilde{x}_i - w_{ij})^2} \quad (3.6)$$

$$w_{ij}^{(q+1)} = w_{ij}^{(q)} + v(\tilde{x}_i - w_{ij}^{(q)}) \quad (3.7)$$

В случае статической нейросети алгоритм обучения включает в себя:

1. На основе априорной информации о предметной области выбирается число результирующих кластеров.
2. Выполняется начальная инициализация весов случайными значениями согласно правилу (3.5).
3. Выбрать следующий элемент обучающей выборки и для каждого нейрона рассчитать меру близости по формуле (3.6):
4. Провести по формуле (3.7) коррекцию только тех весов, которые относятся к нейрону с наименьшим значением  $R_j$ .
5. Повторять пункты 3 и 4 до выполнения хотя бы одного из следующих условий: превышено число эпох обучения; за время тестирования последней эпохи веса сети изменились меньше, чем некоторая заранее заданная величина точности; прошло больше времени, чем было отведено на обучение.

В случае самоорганизующейся нейросети действия несколько отличаются:

1. Выбор порогового значения меры близости  $R_{kr}$ , при превышении которого входящий объект уже не считается принадлежащим тестируемому кластеру.
2. Выбирается очередной объект из обучающей выборки, после чего для каждого уже известного кластера по формуле (3.6) вычисляется мера близости.

3. По формуле (3.7) выполняется коррекция весов, принадлежащих кластеру с наименьшим значением  $R_j$ , не превышающим  $R_{кр}$ . Если таковых не обнаружено, создается новый кластер, чьи веса численно равны параметрам объекта на входе сети.
4. Повторяются пункты 2 и 3, но после завершения эпохи обучения неиспользованные за это время кластеры и соответствующие им нейроны удаляются из структуры нейросети.
5. Условия завершения обучения аналогичны предыдущему варианту.

Второй этап – кластерный анализ – представляет собой количественное и качественное описание каждого кластера из полученного набора.

Третий этап – практическое применение – наиболее прост: объект, который требуется классифицировать, подается на вход нейросети, после чего она сравнивает его характеристики со всеми имеющимися кластерами и делает заключение о принадлежности объекта к тому или иному классу либо о невозможности определить класс объекта.

С точки зрения применимости ИНС Кохонена к графической информации она выглядит намного перспективнее, чем две ранее рассмотренные нейросети: во-первых, может обрабатывать вещественные входные данные, что позволяет охватить весь используемый диапазон цветов и свести предварительную подготовку данных к обычной нормализации в отрезок  $[0; 1]$ ; во-вторых, архитектура самоорганизующегося варианта рассматриваемой нейросети не ставит ограничений на количество кластеров, следовательно, теоретически поддерживается возможность однозначного соответствия каждой комбинации на входе отдельному классу и полная идентичность выходных данных оригиналу, на практике же, как правило, устанавливается точность в один процент от исходного диапазона цветов. Данные преимущества позволяют применить нейросеть Кохонена во множестве различных задач, к числу которых относятся: восстановление изображения, распознавание образов (в более расширенном варианте, чем «бинарные» нейросети), устранение шума и другие. Также, в реальных

задачах используются «окна», от размера которых зависит точность результата – чем меньше «окно», тем выше точность. Однако в список решаемых проблем будет сложно включить такие, где нужно игнорировать аффинные преобразования, наподобие сдвига или поворота – каждое изменение исходного образа, превышающее порог кластеризации, будет считаться отдельным классом и для их обобщения с целью получения одного и того же результата потребуются дополнительные усилия.

### **3.4 Исследование возможностей сверточной нейронной сети**

Сверточная нейронная сеть – специальный вид многослойного перцептрона, в котором применяется совместное использование весов связей, предназначенного для распознавания образов на двумерной плоскости с высоким уровнем инвариантности к аффинным преобразованиям (сдвиг, поворот, масштабирование) и наличию зашумленности [2].

Структурную схему сверточной нейросети можно увидеть на рис. 1.10.

Принцип работы сверточных ИНС заключается в том, что поданный на вход нейросети двумерный образ, обычно изображение, анализируется на предмет наличия некоторого набора признаков и по их наличию или отсутствию делается заключение о содержимом образа.

Внутренняя структура сверточных нейросетей отличается высокой сложностью и содержит как минимум три слоя: первый – слой свертки (карты признаков), второй – слой подвыборки, третий – выходной слой. Размерность первого слоя зависит от размерности входящего образа, последующие слои, из-за специфики архитектуры данного типа нейросетей, всегда меньше него.

Сверточные нейронные сети рассчитаны на обучение с учителем, коррекция весов осуществляется при помощи алгоритма обратного распространения ошибки.

Как и в других случаях, когда используется этот алгоритм, в нейросети присутствует прямой ход и обратный ход – во время первого генерируется ответ ИНС, во время второго в процессе обучения корректируются веса связей.

Во время работы нейросеть использует так называемые ядра свертки – квадратные матрицы размером 3 на 3, 5 на 5, 7 на 7, в которых закодирован тот или иной признак объекта, размер зависит от возможности обнаружить искомый признак.

Прямой ход:

1. Выбирается ядро свертки, содержащее требуемый признак, и накладывается непосредственно на матрицу входящего образа,
2. Проводится операция свертки, определяемая как сумма произведений соответствующих элементов матрицы и ядра,
3. Результат записывается в первый слой нейросети, который имеет размерность входящего образа за вычетом ширины ядра.
4. Пункты 1 – 3 повторяются до тех пор, пока не будут рассмотрены все значимые признаки объекта, после чего первый слой будет представлять собой многовариантную карту наличия признаков, характеризующую их распределение во входящем образе
5. Проводится операция подвыборки, ставящая целью сокращение объема обрабатываемых данных – первый слой разбивается на области 2 на 2, затем на основе максимального (или усредненного) значения элементов каждой области формируется первый слой подвыборки. Потерей информации о расположении признаков можно пренебречь, важен лишь факт их наличия.
6. Пункты 1 – 5 повторяются, при каждом повторении создается новая пара слоев карты признаков и подвыборки на основе информации в слое подвыборки, полученной на предыдущей итерации цикла. Окончание цикла – сокращение размера этого слоя до размера самого ядра – в результате свертки такого слоя получится вектор.

Как можно заметить, с каждым последующим слоем карты признаков становятся все более вариативными и абстрагированными от исходного образа, они уже содержат информацию о наличии не одного признака, а комбинации нескольких, то есть делают вывод о содержимом входного образа в целом.

Обратный ход используется только при обучении нейросети, во время его выполнения происходит распространение ошибки сети от выхода ко входу, вызывая соответствующую коррекцию весов межнейронных связей. Веса связей в ядрах свертки также подвергаются коррекции, величина которой определяется как среднее значение по всем нейронам соответствующего слоя.

Основным преимуществом сверточных нейронных сетей является их инвариантность к аффинным преобразованиям, что позволяет использовать их для распознавания образов, в частности, в оптическом распознавании текста, в классификации объектов со сложной структурой, в управлении (на вход поступает информация о состоянии системы, в ответе сети находится требуемое управляющее воздействие). Второе преимущество – сокращение числа настраиваемых связей за счет их совместного использования, что упрощает и ускоряет обучение. Третьим преимуществом можно назвать широкие возможности по распараллеливанию вычислений и, соответственно, использованию для вычислений более производительных графических процессоров вместо универсальных. Кроме того, для их обучения не требуется специализированная методика, используется классический метод обратного распространения ошибки.

Главные же недостатки – высокая сложность построения нейросети и трудоемкость поиска эффективной конфигурации для новых областей применения.

В области обработки изображений сверточные нейросети, благодаря тому, что по архитектуре и принципу работы они наилучшим образом моделируют межнейронные связи и поведение зрительной коры головного

мозга, успешно применяются при распознавании текста, в компьютерном зрении, для генерации словесного описания картинки, создании объектов по набору признаков и других задачах, где базовым действием является распознавание образов. Кроме того, они могут использоваться для расцвечивания изображения.

### **3.5 Выработка рекомендаций по использованию нейросетевых технологий в цифровом телевидении, интеллектуальном видеонаблюдении и управлении подвижными объектами**

Первым шагом в определении применимости искусственных нейронных сетей в цифровом телевидении, интеллектуальном видеонаблюдении и управлении подвижными объектами являются изучение предметной области и постановка задачи. Рассмотрим перечисленные сферы деятельности подробнее.

Цифровое телевидение – один из вариантов реализации телевизионного вещания, использующий цифровые средства обработки информации и каналы связи и широко применяющий достижения компьютерных технологий. Здесь наиболее актуальная задача – увеличение четкости и размера кадра.

Интеллектуальное видеонаблюдение – тип видеонаблюдения, отличающийся от классического наличием средств анализа изображения: траекторного, по присутствию или отсутствию объекта в кадре, распознавания объекта и других. В этом случае наибольшей проблемой является именно проведение анализа.

Управление подвижными объектами – дисциплина, изучающая и решающая задачу перемещения от одной точки до другой некоторого объекта, имеющего способность автономного движения. Здесь основная задача – увеличение скорости реакции и адекватности управляющего воздействия.

Входные данные в первом и втором случае представляют собой поток данных, содержащих последовательные изображения – кадры, в то время как при управлении это может быть как видеoinформация, так и более абстрактные значения, например, показания датчиков. Важным пунктом является скорость обновления данных, которая определяет необходимое быстродействие нейросети: для телевидения она составляет 24-25 кадров в секунду, видеонаблюдение менее требовательно, там скорость может настраиваться в пределах от одного-двух до двадцати пяти кадров в секунду, при управлении же все зависит от его характера и скорости применения управляющего воздействия. Кроме того, существенное влияние на быстродействие оказывают размеры обрабатываемых кадров.

Для всесторонней оценки и выработки наиболее точных рекомендаций по использованию искусственных нейронных сетей был проведен ряд экспериментов, нацеленных на поиск наиболее эффективной в каждом конкретном случае конфигурации и типа ИНС. Были протестированы следующие типы нейросетей: многослойный перцептрон, нейронная сеть Хэмминга, нейросеть Кохонена и сверточная нейронная сеть.

Основные характеристики нейросетей, оцениваемые в ходе этих экспериментов:

- Быстродействие;
- Сложность реализации;
- Возможность создания аппаратной версии;
- Длительность обучения;
- Точность обработки (классификации, локализации признаков, четкости при увеличении и т. д., в соответствии с задачей).

Тестовые задания для экспериментов индивидуальны для каждой предметной области:

- Цифровое телевидение – провести увеличение линейных размеров изображения в два раза с одновременным повышением четкости. Обучающая выборка: полноцветные изображения размером 720 на 406

пикселей в количестве 7312 штук и такое же количество идентичных по содержанию изображений, но размером 1440 на 812 пикселей для обучения с учителем, тестовая выборка – 98 аналогичных изображений. Примеры изображений можно увидеть на рис. 3.1.



Рис. 3.1 Примеры изображений для предметной области «цифровое телевидение»

- Интеллектуальное видеонаблюдение – провести анализ кадра на наличие в нем автомобильного номера, локализовать его. Обучающая выборка: бинаризованные черно-белые изображения размером 704 на 576 пикселей в количестве 10 124 штук и соответствующее количество изображений с размеченной областью, где присутствует номерной знак, тестовая выборка – 110 аналогичных изображений. Примеры изображений можно увидеть на рис. 3.2.




Рис. 3.2. Примеры изображений для предметной области «интеллектуальное видеонаблюдение»

- Управление подвижными объектами – принять, что входящая информация является видеопотоком и содержит данные с фронтальной камеры, расположенной на капоте автомобиля, требуется определить отклонение от центра дороги и наличие перед машиной препятствий на расстоянии менее 10 метров. Обучающая выборка: изображения в оттенках серого размером 648 на 448 пикселей в количестве 8 243 штуки, такое же количество векторов выходных данных, тестовая выборка – 101 аналогичное изображение. Результатом работы должен быть вектор, содержащий значение поворота руля в градусах и величину ускорения в пределах [-1; 1]. Примеры изображений можно увидеть на рис. 3.3.



Рис. 3.3. Пример изображений для предметной области «управление подвижными объектами»

Для выполнения экспериментов был использован нейроимитатор Сигнейро версии 1.2, в котором была построена модель многослойного перцептрона, а также отдельно разработанные модели сверточной нейросети, ИНС Хэмминга и Кохонена в виде самостоятельных программ.

По результатам серии экспериментов были получены следующие данные, сведенные в таблицы 3.1, 3.2 и 3.3:

Таблица 3.1.

Результаты решения задачи по увеличению изображений при помощи ИНС

Тип ИНС Параметр	Многослойный перцептрон	Нейросеть Хэмминга	Нейросеть Кохонена	Сверточная нейросеть
Быстродействие	Среднее $119,4 \frac{\text{сек}}{\text{изобр}}$	Высокое $54,1 \frac{\text{сек}}{\text{изобр}}$	Среднее $325,4 \frac{\text{сек}}{\text{изобр}}$	Низкое $1833,6 \frac{\text{сек}}{\text{изобр}}$
Сложность реализации	Низкая	Низкая	Средняя	Высокая
Возможность создания аппаратной версии	После обучения	Да	После обучения	После обучения
Длительность обучения	Средняя 2348 итераций	Одна итерация	Средняя 3976 итераций	Высокая 14034 итерации
Точность обработки*	11,05	12,34	12,40	10,77

\* - для данной задачи выражается в виде СКО целевого и увеличенного изображения:  $S_0 = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{x})^2}$ ,  $\hat{x} = \frac{1}{n} \sum_{i=1}^n x_i$ .

Таблица 3.2.

Результаты решения задачи по локализации номера автомобиля при помощи ИНС

Тип ИНС Параметр	Многослойный перцептрон	Нейросеть Хэмминга	Нейросеть Кохонена	Сверточная нейросеть
Быстродействие	Среднее $170,8 \frac{\text{сек}}{\text{изобр}}$	Высокое $50,6 \frac{\text{сек}}{\text{изобр}}$	Среднее $140,1 \frac{\text{сек}}{\text{изобр}}$	Низкое $225,4 \frac{\text{сек}}{\text{изобр}}$
Сложность реализации	Низкая	Низкая	Средняя	Высокая
Возможность создания аппаратной версии	После обучения	Да	После обучения	После обучения
Длительность обучения	Средняя 2534 итерации	Одна итерация	Средняя 2596 итераций	Высокая 13824 итерации
Точность обработки*	2,8	4,1	5,4	2,3

\* - для данной задачи выражается в виде средней ошибки определения координат:  $\langle D \rangle = \frac{1}{n} \sum_{i=1}^n \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$ .

Таблица 3.3.

Результаты решения задачи по управлению автомобилем при помощи ИНС

Тип ИНС Параметр	Многослойный перцептрон	Нейросеть Хэмминга	Нейросеть Кохонена	Сверточная нейросеть
Быстродействие	Среднее $250,2 \frac{\text{сек}}{\text{изобр}}$	Высокое $114,2 \frac{\text{сек}}{\text{изобр}}$	Среднее $234,7 \frac{\text{сек}}{\text{изобр}}$	Низкое $936,1 \frac{\text{сек}}{\text{изобр}}$
Сложность реализации	Низкая	Низкая	Средняя	Высокая
Возможность создания аппаратной версии	После обучения	Да	После обучения	После обучения
Длительность обучения	Средняя 2249 итераций	Одна итерация	Средняя 4216 итераций	Высокая 12843 итерации
Точность обработки*	84%	80%	89%	90%

\* - для данной задачи выражается в виде процента верных управляющих команд.

Из полученных эмпирических результатов следует, что универсальные высокоэффективные нейросети, имеющие сложную структуру, такие, как сверточная, в настоящий момент не могут использоваться в системах реального времени, так как их программные реализации имеют слишком низкое быстродействие. В то же время более простые и производительные нейросети, например, нейросеть Кохонена, не обладают свойством инвариантности к масштабу, сдвигу и другим изменениям целевого объекта, поэтому они пригодны только для ограниченного круга задач либо требуется дополнительная подготовка изображения.

На основании вышеизложенного, а также результатов практической апробации можно сделать вывод о том, что в системах реального времени, к которым относится цифровое телевидение и управление подвижными объектами, могут применяться лишь искусственные нейронные сети с высоким быстродействием, на данный момент неспособные обрабатывать слишком большое количество видов объектов. В то же время им доступны

более простые операции, наподобие автопилота или же автоматического поиска лиц на изображении. Однако, если нет ограничений по времени, например, при работе с архивными записями, можно широко использовать наиболее эффективные виды нейросетей – даже если затраты времени будут велики, полученный результат это окупит.

### **Выводы по главе**

В ходе исследования возможностей нейроимитационных средств по обработке изображений были получены следующие результаты:

- Рассмотрены технические характеристики и возможности применения для обработки изображений таких типов нейросетей, как ассоциативная нейросеть Хопфилда, ассоциативная нейросеть Хэмминга, нейронная сеть Кохонена, сверточная нейронная сеть.
- Проведены эксперименты по сравнению быстродействия, сложности реализации, возможности создания аппаратной версии, объема памяти, длительности обучения, точности распознавания символов для следующих предметных областей: цифровое телевидение, интеллектуальное видеонаблюдение, управление подвижными объектами. Из полученных эмпирических результатов следует, что универсальные высокоэффективные нейросети, имеющие сложную структуру, такие, как сверточная, в настоящий момент не могут использоваться в системах реального времени, так как их программные реализации имеют слишком низкое быстродействие. В то же время более простые и производительные нейросети, например, нейросеть Кохонена, не обладают свойством инвариантности к масштабу, сдвигу и другим изменениям целевого объекта, поэтому они пригодны только для ограниченного круга задач либо требуется дополнительная подготовка изображения.
- На основании полученных эмпирических данных даны рекомендации по практическому использованию ИНС: в системах

реального времени, к которым относится цифровое телевидение и управление подвижными объектами, могут применяться лишь искусственные нейронные сети с высоким быстродействием, на данный момент неспособные обрабатывать слишком большое количество видов объектов. В то же время им доступны более простые операции, например автопилота или же автоматического поиска лиц на изображении. Однако, если нет ограничений по времени, например, при работе с архивными записями, можно широко использовать наиболее эффективные виды нейросетей – даже если затраты времени будут велики, полученный результат это окупит.

## Заключение

За время написания диссертации был проведен большой объем исследовательских работ; изучено более сорока научных трудов, статей периодической печати, отчетов об экспериментах; опубликовано две статьи для научных конференций; проведен ряд практических опытов.

В результате обзора современных нейросетевых технологий для обработки изображений было установлено следующее:

- Нейросетевые технологии – это совокупность аппаратных и/или программных методов и средств обработки информации, использующих искусственные нейронные сети (ИНС). ИНС состоит из набора связанных в соответствии с определенным пространственным шаблоном искусственных нейронов, которые представляют собой элементарные вычислительные ячейки, функционирующие в соответствии с математической моделью работы реального биологического нейрона, базирующейся на следующих принципах: нейрон имеет несколько входов и только один выход, входы нейрона воздействуют на проходящий по ним сигнал, нейрон суммирует приходящие к нему сигналы и затем генерирует исходящий сигнал при помощи специальной функции (функции активации), которая определяет, как множество входных сигналов будут преобразованы в одиночный сигнал на выходе.

- Существуют три основных топологии нейросетей – полносвязная, многослойная и слабосвязная, различающиеся плотностью и характером соединений между отдельными нейронами.

- Функция активации служит для нормализации выходного сигнала. В качестве таковой может использоваться любая функция, удовлетворяющая критерию непрерывности на всей области определения, наиболее часто применяется сигмоид  $Y = \frac{1}{1+e^{-aS}}$ .

- В ходе жизненного цикла ИНС есть уникальная стадия, присущая только нейросетям – обучение. Данный этап представляет собой коррекцию

весов связей между нейронами и, если это предусмотрено архитектурой нейросети, изменение ее топологии, с целью минимизации результирующей ошибки сети.

- Одним из наиболее широко используемых вариантов применения искусственных нейронных сетей в сфере обработки изображений является технология распознавания образов, суть которой заключается в формировании на основе входящих графических данных некоторого набора критериев и последующее сравнение полученного набора с эталонными образцами, характеризующими тот или иной класс объектов предметной области.

- Нейросети могут быть реализованы на практике в трех вариантах – как программные, аппаратные или гибридные. В первом случае все элементы и характеристики ИНС, такие, как функция активации, веса связей между нейронами и их пространственная структура, представляют собой структурированные данные, хранящиеся в оперативной памяти компьютера, а сама нейросеть является обычной исполняемой программой. Во втором – большинство или все составляющие части искусственной нейронной сети выполнены в виде дискретных или интегрированных компонентов, а ИНС в целом – это печатная плата и элементы на ней, как правило, нейропроцессор и периферийные устройства, которые могут быть реализованы в цифровом или аналоговом исполнении. Третий вариант предполагает совмещение первых двух, при этом обычно неизменные свойства ИНС, например, функция активации или пространственная структура, реализуются аппаратно, в то время как изменяющиеся характеристики наподобие весовых коэффициентов размещаются в оперативной памяти.

В ходе анализа принципов построения и работы имитационных средств ИНС были получены следующие результаты:

- Основными этапами создания искусственных нейронных сетей являются: сбор репрезентативных данных для ее обучения, нормализация данных (при необходимости), выбор архитектуры ИНС, выбор функции

активации, построение архитектуры (программное или аппаратное), обучение, проверка качества обучения.

- Наиболее используемые функции активации: пороговая, кусочно-линейная, сигмоидальная.

- Есть две базовые схемы обучения: с учителем и без учителя.

- Основные шаги процесса обучения (независимо от схемы): выбор тестового объекта, вычисление ответа нейросети, оценка полученного ответа, коррекция весов связей.

- Существуют следующие методы коррекции веса связей: метод коррекции ошибки (и основанный на нем метод обратного распространения ошибки), обучение на основе опыта, правило Хебба, конкурентное обучение.

- Нейронные сети для обработки изображений отличаются от ИНС другого предназначения увеличенной сложностью топологии, что дает возможность сократить размерность обрабатываемых данных путем выделения в них характерных признаков либо обеспечить параллельную работу с данными, если важно минимизировать потери информации.

- Разработаны специализированные программные средства, позволяющие самостоятельно проектировать и реализовывать искусственные нейронные сети, которые после прохождения обучения можно преобразовать в автономные модули с целью использования в сторонних разработках - нейроимитаторы. Примерами таких программ могут служить NeuroIterator, NeuroPro, NeuroGenesis, Сигнейро.

- Основные возможности нейроимитаторов: формирование любых типов нейросетей; наличие нескольких вариаций функции активации, настроечных параметров для нее, встроенный анализатор качества построения нейросети, развитые средства управления процессом моделирования (пошаговое, остановка по условию, возврат); оптимизация сформированной нейросети; экспорт обученной нейросети в виде

самостоятельного модуля для подключения к сторонним программным проектам.

В ходе исследования возможностей нейроимитационных средств по обработке изображений были получены следующие результаты:

- Рассмотрены технические характеристики и возможности применения для обработки изображений таких типов нейросетей, как ассоциативная нейросеть Хопфилда, ассоциативная нейросеть Хэмминга, нейронная сеть Кохонена, сверточная нейронная сеть.

- Проведены эксперименты по сравнению быстродействия, сложности реализации, возможности создания аппаратной версии, объема памяти, длительности обучения, точности распознавания символов для следующих предметных областей: цифровое телевидение, интеллектуальное видеонаблюдение, управление подвижными объектами. Из полученных эмпирических результатов следует, что универсальные высокоэффективные нейросети, имеющие сложную структуру, такие, как сверточная, в настоящий момент не могут использоваться в системах реального времени, так как их программные реализации имеют слишком низкое быстродействие. В то же время более простые и производительные нейросети, например, нейросеть Кохонена, не обладают свойством инвариантности к масштабу, сдвигу и другим изменениям целевого объекта, поэтому они пригодны только для ограниченного круга задач либо требуется дополнительная подготовка изображения.

- На основании полученных эмпирических данных даны рекомендации по практическому использованию ИНС: в системах реального времени, к которым относится цифровое телевидение и управление подвижными объектами, могут применяться лишь искусственные нейронные сети с высоким быстродействием, на данный момент неспособные обрабатывать слишком большое количество видов объектов. В то же время им доступны более простые операции, наподобие автопилота или же автоматического поиска лиц на изображении. Однако, если нет ограничений

по времени, например, при работе с архивными записями, можно широко использовать наиболее эффективные виды нейросетей – даже если затраты времени будут велики, полученный результат это окупит.

## Список литературы

1. Постановление Кабинета Министров Республики Узбекистан «О дальнейших мерах по переходу на цифровое телевидение и прекращению наземного аналогового телевидения» № 502 от 17 июля 2017 г.
2. Хайкин С., Нейронные сети: полный курс, 2-е издание. – М.: Изд. дом «Вильямс», 2006 – 1104 с, илл.
3. Бабаян Р. И., Сжатие изображений при помощи нейросетей, Республиканская научно-техническая конференция «Значение информационно-коммуникационных технологий в инновационном развитии реальных отраслей экономики», том 2, стр. 315-317, г. Ташкент, 6-7 апреля 2017 г.;
4. Круглов В.В., Борисов В. В. Искусственные нейронные сети. Теория и практика. - 2-е изд., стереотип. - М.: Горячая линия-Телеком, 2002. - 382 с.
5. Круг П.Г., Нейронные сети и нейрокомпьютеры: Учебное пособие по курсу «Микропроцессоры». – М.: Издательство МЭИ, 2002. – 176 с.
6. Статья «Искусственная нейронная сеть», Википедия ([https://ru.wikipedia.org/wiki/%D0%98%D1%81%D0%BA%D1%83%D1%81%D1%81%D1%82%D0%B2%D0%B5%D0%BD%D0%BD%D0%B0%D1%8F\\_%D0%BD%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B0%D1%8F\\_%D1%81%D0%B5%D1%82%D1%8C](https://ru.wikipedia.org/wiki/%D0%98%D1%81%D0%BA%D1%83%D1%81%D1%81%D1%82%D0%B2%D0%B5%D0%BD%D0%BD%D0%B0%D1%8F_%D0%BD%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B0%D1%8F_%D1%81%D0%B5%D1%82%D1%8C))
7. Статья «Однослойные перцептроны», Портал искусственного интеллекта, 24.04.2015 (<http://neuronus.com/theory/958-odnoslojnyepertseptrony.html>)
8. Статья «Многослойные перцептроны», Портал искусственного интеллекта, 10.05.2015 (<http://neuronus.com/theory/958-odnoslojnyepertseptrony.html>)

9. Статья «Нейронные сети на основе радиально-симметричных функций», Портал искусственного интеллекта, 24.05.2015 (<http://neuronus.com/theory/960-nejronnye-seti-na-osnove-radialno-simmetrichnykh-funktsij.html>)
- 10.Статья «Нейронные сети Кохонена», Портал искусственного интеллекта, 05.06.2015 (<http://neuronus.com/theory/961-nejronnye-seti-kokhonena.html>)
- 11.Статья «Нейронные сети адаптивного резонанса», Портал искусственного интеллекта, 05.06.2015 (<http://neuronus.com/theory/962-nejronnye-seti-adaptivnogo-rezonansa.html>)
- 12.Статья «Автоассоциативная память», Портал искусственного интеллекта, 12.06.2015 (<http://neuronus.com/theory/963-avtoassotsiativnaya-pamyat.html>)
- 13.Статья «Нейронные сети Хэмминга», Портал искусственного интеллекта, 04.07.2015 (<http://neuronus.com/theory/971-nejronnye-seti-khemminga.html>)
- 14.Статья «Нейронная сеть Ворда», Википедия ([https://ru.wikipedia.org/wiki/%D0%9D%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B0%D1%8F\\_%D1%81%D0%B5%D1%82%D1%8C\\_%D0%92%D0%BE%D1%80%D0%B4%D0%B0](https://ru.wikipedia.org/wiki/%D0%9D%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D0%B0%D1%8F_%D1%81%D0%B5%D1%82%D1%8C_%D0%92%D0%BE%D1%80%D0%B4%D0%B0))
- 15.Уоссермен, Ф. Нейрокомпьютерная техника: Теория и практика = Neural Computing. Theory and Practice. — М.: Мир, 1992. (<http://evrika.tsi.lv/index.php?name=texts&file=show&f=410>)
- 16.Сервис Ostagram (<https://www.ostagram.me/about?locale=ru>)
- 17.Проект Colorful Image Colorization, главная страница (<http://richzhang.github.io/colorization/>)
- 18.Зиновьев И. И., Программно-аппаратные эмуляторы нейронных сетей на процессоре PowerXCell™ 8i ([http://hpc-education.unn.ru/files/conference\\_hpc/2009/files/183.pdf](http://hpc-education.unn.ru/files/conference_hpc/2009/files/183.pdf))

- 19.Статья «Нейросетевое программное обеспечение»  
(<https://bookflow.ru/nejrosetevoe-programmnoe-obespechenie/>)
- 20.Статья «Элементная база нейровычислителей»  
(<https://intellect.ml/chast-2-2-elementnaya-baza-nejrovychislitelej-626>)
- 21.Бабаян Р. И., Анализ современного состояния аппаратно-программного обеспечения для моделирования работы искусственных нейронных сетей. Международная конференция «Роль информационно-коммуникационных технологий в инновационном развитии реальных отраслей экономики», стр. 687-690, г. Ташкент, 5-6 апреля 2018 г.
- 22.Винокуров И. В., Нейроимитатор NeuroIterator, международный научный журнал «Инновационная наука», №3/2016.  
(<https://cyberleninka.ru/article/n/neuroimitator-neuroiterator>)
- 23.Справочная система программы NeuroPro.
- 24.Статья «Нейроимитатор NEUROPRO 0.25»  
(<http://osvita.mpedagog.ru/nejroimitator-neuropro-25.html>)
- 25.Хомич А. В., Структурные методы снижения ошибки обобщения и ускорения обучения нейронных сетей с учителем (автореферат диссертации), Красноярск, Сибирский государственный технологический университет — 2006 г.
- 26.Руководство пользователя программы Сигнейро.
- 27.Гаврилов И.А., Пузий А.Н., Бабаян Р.И.. Увеличение коэффициента сжатия видеоданных на основе изменения размеров ТВ изображений. Статья в журнале Вестник ТУИТ, №1, 2016 г. с.46-54.