

Документ подписан простой электронной подписью

Информация о владельце:

ФИО: Локтионова Оксана Геннадьевна

Должность: проректор по учебной работе

Дата подписания: 04.11.2024 22:21:12

Уникальный программный ключ:

0b817ca911e6668abb13a5d426d39e5f1c11eabbf73e943df4a4851fda56d089

МИНОБРАЗОВАНИЯ И НАУКИ РОССИИ

Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Юго-Западный государственный университет»
(ЮЗГУ)

Кафедра биомедицинской инженерии

УТВЕРЖДАЮ

Проректор по учебной работе

О.Г. Локтионова

« 04 » 11 2023 г.

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ КЛАССИФИКАЦИИ И РАСПОЗНАВАНИЯ ИЗОБРАЖЕНИЙ

Методические указания к курсовой работе по дисциплине
«Интеллектуальные системы классификации и распознавания
изображений» для студентов направления подготовки 12.04.04
«Биотехнические системы и технологии»

Курск 2023

УДК 004.93:61

Составители: С.А. Филист

Рецензент

Доктор технических наук, профессор Р.А. Томакова

Интеллектуальные системы классификации и распознавания изображений: методические указания к курсовой работе / Юго-Зап. гос. ун-т; сост.: С.А. Филист. - Курск, 2023. - 45 с.

Предназначено для студентов по дисциплине «Интеллектуальные системы классификации и распознавания изображений» направления подготовки 12.04.04 «Биотехнические системы и технологии».

Текст печатается в авторской редакции

Подписано в печать . Формат 60×84 1/16. Бумага офсетная.
Усл. печ. л. 2,8. Уч.-изд. л. 2,4. Тираж 100 экз. Заказ *610* .
Юго-Западный государственный университет.
305040, г. Курск, ул. 50 лет Октября, 94.

ВВЕДЕНИЕ

Задачи анализа компьютерной диагностики болезней молочной железы представляет собой интересные и важные задачи медицины. Некоторые болезни молочной железы тяжело диагностировать при отсутствии ярко выраженных симптомов или при низком качестве снятого изображения. Диагностика болезней молочной железы на ранней стадии позволяет назначить большему числу пациентов раннее лечение и тем самым предотвратить развитие болезни. Болезни молочной железы являются одними из самых распространенных онкологических заболеваний женщин среди населения Земли. По данным Всемирной Организации Здравоохранения, по состоянию на 2018г [1].

В данной работе используется нейронная сеть для обнаружения патологических участков молочной железы. В работу включены процесс формирования обучающих выборок, результаты обучения нейронной сети при обработке изображений молочной железы.

Нейронная сеть может быть использована для построения системы диагностики болезней. Для такой системы не требуется высокая точность распознавания элементов, важно их приблизительное расположение. Кроме того, компьютерное обнаружение патологий молочной железы может позволить обнаружить их не только врачу-профессионалу, но и, к примеру, обслуживающему персоналу лечебницы. Врач может применить нейронную сеть для обнаружения патологических элементов.

Целью работы является построение модели нейронной сети для диагностики патологии молочной железы.

1 АНАЛИЗ ПРОБЛЕМЫ ДИАГНОСТИКИ ЗАБОЛЕВАНИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

Многие направления науки, техники и производства в значительной степени ориентируются на развитие систем, в которых информации представлена в виде изображений. При обработке такой информации возникает ряд сложных научных, технических и технологических проблем.

На сегодняшний момент наиболее сложными являются анализ и распознавание изображений. О важности этой проблемы говорит тот факт, что исследования по распознаванию образов, анализу изображений и речи включены в перечень приоритетных направлений развития науки и техники и критических технологий федерального уровня [2].

В настоящее время интенсивно развиваются интеллектуальные системы, предназначенные для описания формы анализируемых изображений или выделения из них метрической или семантической информации. Анализ семантики является вершиной иерархической процедуры обработки изображений, сложность которой связана с тем, что изначально эта процедура решает нечеткую задачу [3].

Тем не менее, существует ряд проблем, связанных с классификацией изображений, которые не решены в настоящее время. Для успешной классификации изображений необходима априорная информация о структуре и свойствах мира. Однако многие факторы (деформация формы, перекрытие, переход от 3D-сцен к 2D-изображениям и т.п.) снижают ценность априорных данных и затрудняют семантическую сегментацию изображения, при которой каждый сегмент рассматривается как объект определенного класса.

В итоге изображение имеет альтернативные структуры, решение по выбору одной из которых не может быть принято однозначно, основываясь на принятой картине мира. Определим этот класс изображений как сложноструктурируемые. Следовательно, если изображение является сложноструктурируемым, то это ведет к значительному снижению качества его классификации или классификации его сегментов посредством обучаемых классификаторов [4].

Сложноструктурируемому изображению характерно искажение границ сегментов и появление ложных сегментов, а также наличие древовидных структур. Поэтому использование известных локальных градиентных операторов выделения границ и оконтуривающих морфологических операторов не дает ожидаемого эффекта в связи с тем, что они привязываются к априорно заданной картине мира и не анализируют локальные результаты принятого решения и многоальтернативные решения.

В настоящее время научно-техническое направление классификации сложноструктурируемых изображений активно развивается. В последнее десятилетие предложены методы определения дескрипторов изображений и их сегментов, позволяющие построить признаковые пространства, устойчивые к ряду аффинных преобразований, шуму, изменению в освещении: SIFT (Scale Invariant Feature Transform), SURF (Speeded Up Robust Features), PCA-SIFT (PCA - Principal Component Analysis) и т.д. Но эти дескрипторы предназначены для работы в интеллектуальных системах поиска аналогичных подобных изображений, не в системах классификации. В настоящее время для классификации успешно применяются алгоритмы, такие как Bagging и Boosting, основанные на использовании множества базовых классификаторов с последующей агрегацией их решений, направленной на снижение ошибок первого и второго рода. Использование этих алгоритмов предполагает наличие больших объемов выборок, позволяющих осуществить настройку множества классификаторов. Однако существует достаточно большой класс сложноструктурируемых изображений, для которых обеспечить необходимый объем обучающей выборки принципиально невозможно. Это, в частности, относится к медицинским изображениям, где эти ограничения обусловлены наличием сочетанной патологии и сложностью экспериментов на живых объектах. В этом случае для классификации целесообразно использовать методы и алгоритмы, основанные на различных парадигмах, что позволяет построить гибридные модели классификации, которые применяют как методы обучаемых систем распознавания образов, так и методы экспертного оценивания. Гибридные модели целесообразно использовать и в случае

иерархической семантической классификации, когда для окончательной классификации необходимо учитывать не только класс сегмента, но и его геометрические характеристики и масштаб [5,6].

В случае классификации сложноструктурируемых изображений использование этих методов не приводит к приемлемому результату из-за того, что методология нечеткого вывода адаптирована под задачи классификации. Поэтому отсутствие методов и алгоритмов разработки гибридных классификаторов сложноструктурируемых изображений является серьезной проблемой, затрудняющей и замедляющей разработку новых приложений и практических систем в области компьютерного зрения [7].

2 ТЕОРЕТИЧЕСКАЯ ЧАСТЬ. ФОРМИРОВАНИЕ ОБУЧАЕМОГО КЛАССИФИКАТОРА ПРИ ДИАГНОСТИКЕ ПАТОЛОГИЙ МОЛОЧНОЙ ЖЕЛЕЗЫ

В связи с тенденцией увеличения сложности математических моделей реальных систем и процессов управления, связанной с необходимостью повышения их адекватности и учета все большего числа различных факторов, оказывающих влияние на процессы принятия решений, растет актуальность разработки информационных технологий, позволяющих выполнять моделирование ситуаций максимально близких к реальным условиям.

В биомедицинских приложениях очень часто используют обобщенные экспертные оценки той или иной предметной области, поэтому нередки ситуации неточности или недостаточности исходного описания подлежащей решению задачи. Нечеткая логика, которая служит основой при моделировании таких ситуаций, более естественно описывает характер человеческого мышления и ход его рассуждений, чем традиционные формально-логические системы, и потому является перспективным направлением системного моделирования. Но системы с нечеткой логикой принятия решений, в отличие от нейронных сетей, не могут автоматически приобретать знания в ходе их использования в механизмах вывода. Для объединения достоинств нейронных сетей и систем нечеткого вывода разрабатываются специальные гибридные системы, которые на одном или нескольких шагах построения нечеткого вывода используют принципы нейронных сетей. Такие системы получили название нечетких нейронных сетей [1].

Одним из способов создания гибридной структуры является использование нейронных сетей для решения частной подзадачи нечетких экспертных систем, а именно - настройки параметров функций принадлежности. В общем случае функции принадлежности можно сформировать двумя способами: методом экспертной оценки или на основе статистического анализа. Гибридные технологии предлагают третий способ: использование существующей выборки данных для определения параметров функций принадлежности, которые лучше всего соответствуют некоторой системе нечеткого

вывода. При этом для нахождения параметров функций принадлежности используются известные процедуры обучения нейронных сетей [2].

Альтернативным вариантом применения нейронных сетей в задачах нечеткого моделирования является их использование для подбора правил нечетких продукций. В данном случае сеть используется в качестве агрегатора нечеткой системы, позволяя выполнить подбор оптимального способа комбинирования функций принадлежности, образующих нечеткую продукцию. Как и в первом случае, нейронной сети требуется обучение с учителем. Примером указанного варианта гибридных сетей нейро-нечеткого вывода может служить адаптивная система ANFIS, реализованная в программном пакете Matlab. Эта сеть представляет собой систему нечеткого вывода FIS типа Сугено нулевого или первого порядка, в которой каждое из правил нечетких продукций имеет постоянный вес. В этом случае гибридная сеть представляет собой нейронную сеть с единственным выходом и несколькими входами, которые представляют собой нечеткие лингвистические переменные [3].

Следует отметить, что комбинированное использование вышеуказанных технологий представляет собой достаточно трудоемкую задачу, так как необходимо удостовериться, что объединение данных методов не приведет к ухудшению качества работы системы в целом. В качестве примера рассмотрим задачу классификации образов, как одну из наиболее часто возникающих в биомедицинских приложениях.

В данной работе необходимо проанализирована целесообразность использования нейронной сети в качестве дефuzziфикатора нечеткой системы, т.е. этапа преобразования нечетких коэффициентов уверенности $Ku_i(\bar{x})$ в четкие номера классов \bar{y}_i . Для оценки эффективности данной структуры необходимо построить соответствующую модель в среде Matlab.

Необходимость применения гибридных систем особенно остро возникает в тех случаях, когда классы $C_1 \dots C_n$, (n – количество классов) имеют множество пересечений в пространстве признаков,

или же топология этих классов в пространстве информативных признаков отличается от эллипсоида.

Рассмотрим ситуацию, когда классы C_2 , C_3 , C_4 находятся в центре области, образованной классом C_1 (см. рис. 1). Проведем сравнительный анализ применения распространенных методов классификации объектов, основанных на технологиях нейронных сетей и нечеткой логики:

- а) создание и обучение нейронной сети на основе исходных данных;
- б) построение нечеткого логического вывода на базе экспертной оценки пространства признаков;
- в) использование нейронной сети в качестве дефuzziфикатора в системе нечеткого вывода.

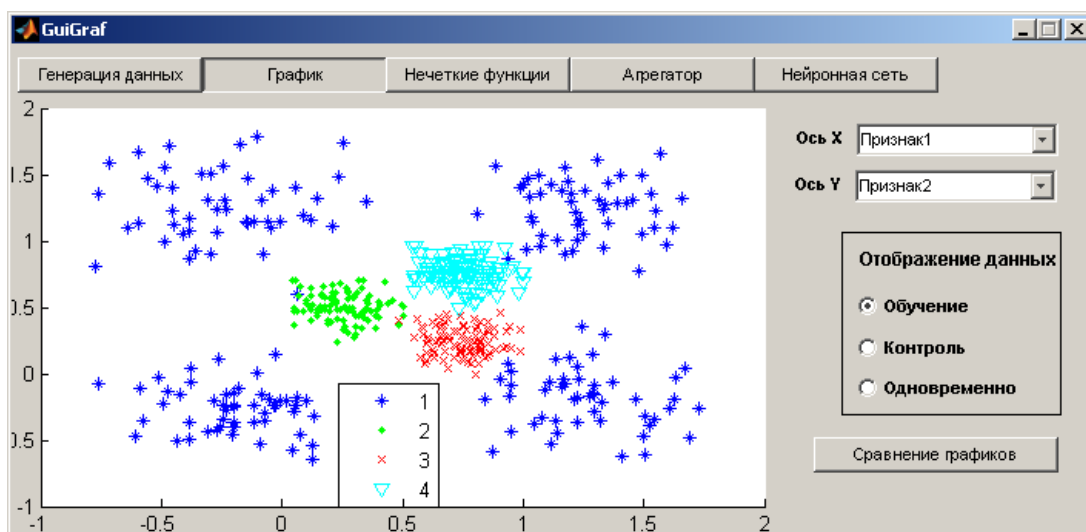


Рисунок 2.1 - Распределение объектов в двумерном пространстве признаков

Классификация на основе нейронной сети выполняется посредством ее обучения. Для этого формируется обучающая выборка, представляющая собой множество векторов ($\{P_1 \dots P_m\}_{1 \dots}$), где m – количество признаков. При применении данного способа первый слой нейронной сети содержит m нейронов, а последний – n (см. рис. 2.2). Значения векторов признаков поочередно подаются в качестве входных сигналов на нейроны первого слоя сети В качестве целевых значений выходов нейронной сети алгоритму обучения

устанавливается значение «1» для выхода, соответствующего действительному классу объекта. Остальные выходы инициализируются значением «0»

Процесс обучения заключается в последовательной подаче имеющихся объектов на вход нейронной сети, считывании результата с нейронов последнего слоя нейронной сети и последующей подстройке весов нейронов в каждом слое, в соответствии со значением отклонения полученных значений от целевых.

Настройка параметров сети выполняется с помощью одного из самых распространенных алгоритмов обучения - алгоритма обратного распространения ошибки (back propagation). Этот алгоритм представляет собой итеративный градиентный алгоритм минимизации среднеквадратичного отклонения значений выхода от желаемых значений (минимизации ошибки) в многослойных нейронных сетях (2.1).

$$E = \frac{1}{sn} \sum_{i=1}^s \sum_{j=1}^n (y_j^i - d_j^i)^2 \quad (2.1)$$

где s – число обучающих пар, n - размерность выходного вектора.

Задача обучения нейронной сети сводится к поиску таких значений весовых коэффициентов $w_{ij}^{(k)}$, чтобы ошибка обучения E стала меньше некоторого значения ε . В ходе обучения методом обратного распространения ошибки выполняется подбор управляющих коэффициентов для каждого слоя сети [4].




Рисунок 2.2 - Пример структуры полносвязной многослойной нейронной сети для классификации объектов

После завершения процесса обучения, на входы нейронной сети поочередно подаются значения признаков объектов, подлежащих классификации, и считываются значения, образующиеся на нейронах выходного слоя. В данном случае, по результатам классификации, объект будет отнесен к тому классу, для которого значение на соответствующем ему нейроне будет наиболее близким к 1.

Для выполнения разделения объектов с помощью методов нечеткой логики необходимо предварительно провести оценку вида и параметров функций принадлежности $\mu_{11} \dots \mu_{nm}$ для каждого признака объектов в каждом классе (рисунок 2.3).

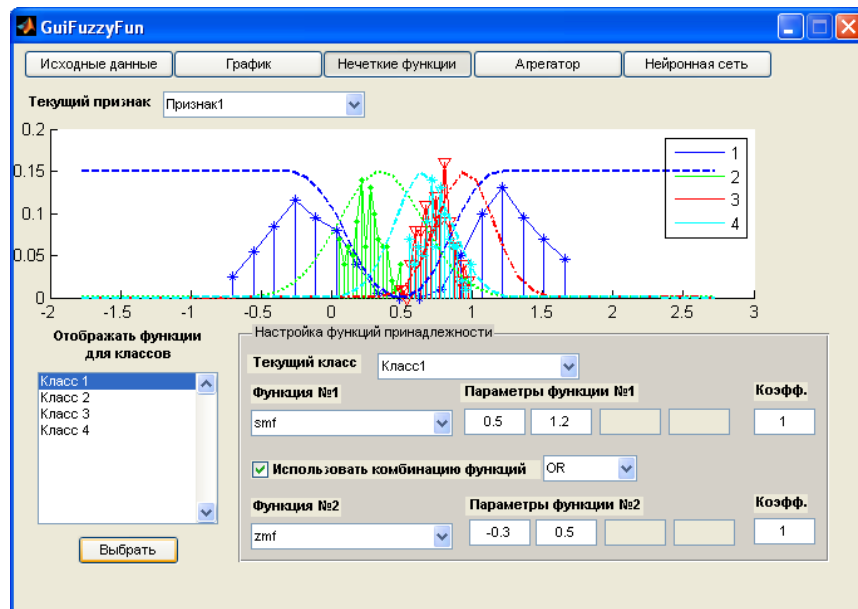


Рисунок 2.3 - Выбор формы и параметров нечетких функций принадлежности

Синтез функций принадлежности не связан напрямую с существующей обучающей выборкой и может основываться только лишь на экспертных оценках в данном пространстве признаков. В том случае, если значения одного из признаков объектов не могут быть корректно описаны унимодальной функцией принадлежности, используются алгоритмы пересечения и объединения нечетких функций. Пересечение функций принадлежности μ_a и μ_b вычисляется по формуле (2.2). Объединение нечетких функций μ_a и μ_b вычисляется по формуле (2.3)

$$\mu_c = \mu_a \cap \mu_b = \min(\mu_a(x), \mu_b(x)) \quad (2.2)$$

$$\mu_c = \mu_a \cup \mu_b = \max(\mu_a(x), \mu_b(x)) \quad (2.3)$$

Значения функций принадлежности изменяются в диапазоне [0 1]. Однако при определении вида функций принадлежности для объектов разных классов появляется необходимость, чтобы максимальное значение функции принадлежности не превышало заданного значения. Например, если по какому-либо из признаков один класс значительно пересекается с другим, имеет смысл ограничить функции принадлежности обоих классов в диапазоне пересечения максимальным значением 0.5, чтобы они имели меньшее влияние на результат классификации. Для этого после вычисления значений функций принадлежности выполняется умножение результата на коэффициент значимости $kf_{i,j}$ ($0 \leq kf_{i,j} \leq 1$), задаваемый для каждой функции принадлежности в отдельности. По умолчанию коэффициент $kf_{i,j}$ равен 1.

После подбора функций принадлежности выполняется переход к этапу построения агрегатора [5], т.е. выбор порядка и способа комбинирования функций принадлежности по признакам объектов (рисунок 2.4). Каждый агрегатор A_i , ($i=1..n$) представляет собой набор из $(m-1)$ нечетких операций.

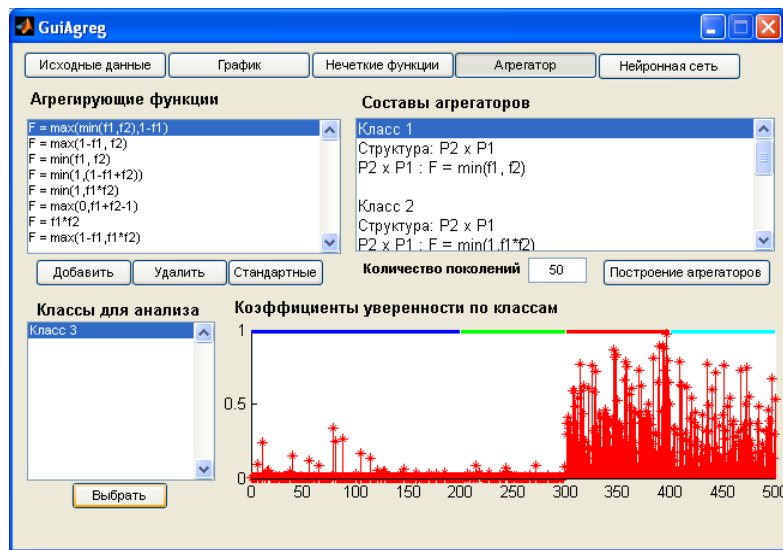


Рисунок 2.4 - Построение агрегаторов для функций принадлежности

Агрегаторы предназначены для выполнения преобразования значений функций принадлежности по признакам класса в обобщенное значение коэффициента уверенности Ku_i принадлежности объекта к i -му классу. После завершения этапа агрегирования мы получаем набор коэффициентов уверенности $Ku_i(\bar{x})$, $i = 1..n$. После этого необходимо выполнить процесс дефuzziфикации для получения номеров классов, к которым будут отнесены предъявленные к классификации объекты, т.е. составить функцию (2.4)

$$y(\bar{x}) = f(K(u_1)..K(u_n)) \quad (2.4)$$

В качестве данной функции наиболее часто используется максимум из всех $Ku_i(\bar{x})$ для одного объекта (2.5).

$$f(K(u_1)..K(u_n)) = \arg(\max(K(u_1)..K(u_n))) \quad (2.5)$$

Однако данный подход обладает рядом существенных недостатков. В частности, при определении номера класса принимается во внимание только один из коэффициентов уверенности, вне зависимости от того, насколько велики значения остальных. Например, при классификации объектов по трем классам – ситуации $K(u) = (0.9; 0.1; 0.14)$ и $K(u) = (0.9; 0.88; 0.89)$ будут признаны равнозначными, несмотря на то, что во втором случае правильность отнесения объекта к первому классу должна вызвать большие сомнения, нежели в первом. Очевидно, что для повышения точности классификации необходимо применять алгоритм, анализирующий значения всех коэффициентов уверенности для одного объекта.

В результате анализа вышеуказанных способов классификации предложен алгоритм разделения образов на классы, объединяющий достоинства первого и второго методов и устраняющий отмеченные недостатки. В нем вместо решающего правила (5) предлагается использовать нейронную сеть. Алгоритм заключается в построении и обучении нейронной сети, принимающей на вход значения

коэффициентов уверенности, а на выходе дающей номер класса объекта, согласно решающему правилу (2.6).

$$f(K(u_1)..K(u_n)) = \max_{i=1,n} (NET_{i,k}(K(u_1)..K(u_n))) \quad (2.6)$$

где $NET_{i,k}$ – выходы k -го слоя нейронной сети (рисунок 2.5). В данном случае структура нейронной сети содержит одинаковое количество нейронов в первом и последнем слоях, равное n – количеству классов, что делает ее независимой от первоначального числа признаков объектов.

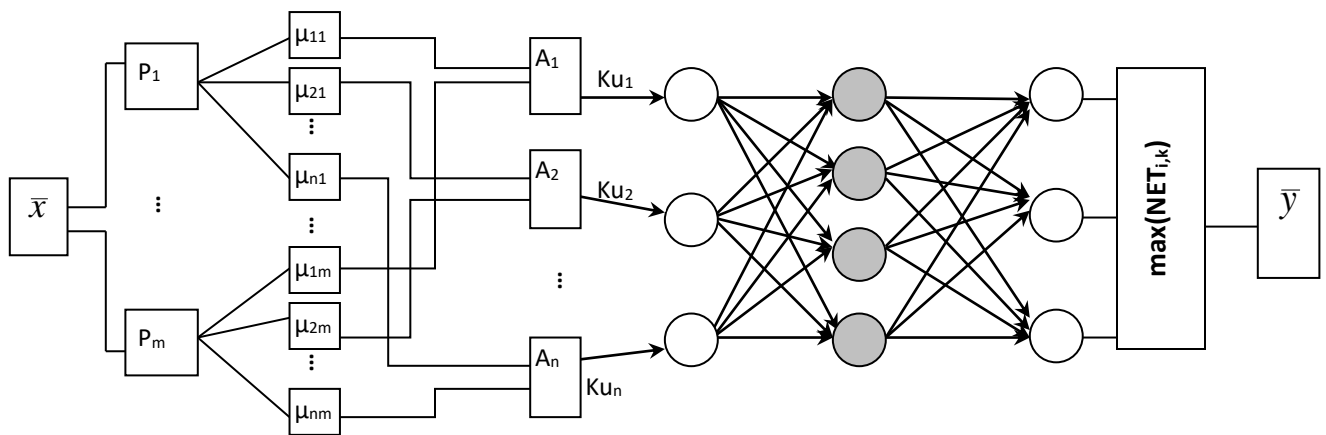


Рисунок 2.5 - Структура нечеткой нейросетевой модели, использующей нейронную сеть в качестве дефuzziфикатора

3 ПЛАН ВЫПОЛНЕНИЯ КУРСОВОЙ РАБОТЫ

3.1 Структура пояснительной записки

Курсовая работа должна состоять из пояснительной записки объемом не менее 20 листов машинописного текста, выполненного на листах белой бумаги формата А4 без нанесения рамки и основной надписи, и графической части, включающей в себя не менее 2-х листов формата А1. Оформление чертежей и пояснительной записки должно соответствовать стандартам ГОСТ, ЕСКД, а также другим отраслевым стандартам.

Пояснительная записка должна содержать в себе следующие пункты:

1. Титульный лист
2. Задание на курсовую работу
3. Техническое задание (при необходимости оформляется согласно госту на ПО)
4. Содержание
5. Введение
6. Материалы «Состояние вопроса»
7. Основные разделы проекта (в зависимости от темы)
8. Заключение
9. Список используемых источников
10. Приложения (в случае необходимости)

Во введении дается укрупненное технико-экономическое обоснование разработки, ее актуальность, формулируется цель работы, вытекающая из актуальности решаемой задачи.

Раздел «Состояние вопроса» содержит современное состояние в данной области с позиций литературных источников. Кроме того, в данном разделе следует перечислить методы и способы анализа исходных данных. Данный раздел следует заканчивать формулировками задач работы, т.е. формулировками последовательности действий, которые должны привести к достижению поставленной цели.

Основные разделы проекта определяются решаемыми проблемами и задачами. Здесь может быть множество разделов, например аналитический, расчетный, экспериментальный и другие.

Каждый из разделов должен иметь заголовок, отражающий конкретное содержание раздела, например «предварительная обработка таблиц экспериментальных данных». Записи «Аналитический раздел» и прочие не допускаются.

В заключении приводится развернутая последовательность действий, которая была проделана для достижения поставленной цели. Иными словами, следует привести последовательности расчета и синтеза, начиная от предварительного анализа данных и заканчивая конечной математической моделью или ПО.

3.2 Формирование базы данных обучающих и контрольных выборок

В курсовой работе обучающие выборки формируются по окнам размерами 16x16, 32x32 и 64x64 пикселя. Соответственно, для каждого размера окна формируются свои базы данных обучающих и контрольных выборок. Также, для каждого размера окна обучаются свои классификаторы. В итоге, мы должны иметь три классификатора, решения которых агрегируются классификатором верхнего иерархического уровня. Если классификаторы на нижнем иерархическом уровне построены на основе нейронных сетей, то в них необходимо использовать линейную функцию активации.

Для формирования обучающих и контрольных выборок используем обработанные изображения патологии молочной железы, представленные на тематических сайтах. Например, *Цифровая база данных скрининга маммографии* (Digital Database for Screening Mammography – DDSM). Доступ: <http://marathon.csee.usf.edu/Mammography/Database.html>. Этот ресурс создан сообществом исследований маммографических изображений. Интерфейсное окно с каталогом этих исследований показано на рисунке 3.1.

Цифровая база данных для скрининга маммографии организована по «случаям» и «объемам». «Случай» - это набор изображений и информации, соответствующих одному маммографическому обследованию одного пациента. «Том» - это просто набор дел, собранных вместе для удобства распространения. Все объемы доступны на 8-миллиметровой ленте. Обычно все (или почти все) тома также доступны в режиме онлайн. [README](#) файл объяснение «все» о базе данных доступен, и многие ответы на вопросы о базе данных перечислены ниже.

- **Какая информация включена в дело?**

Дело состоит из 6-10 файлов. Это файл "ics", обзорный файл "16-битный PGM", четыре файла изображений, сжатых с кодированием JPEG без потерь, и файлы с наложением от нуля до четырех. В обычных случаях не будет никаких оверлейных файлов. [Нажмите здесь](#) для получения более подробной информации о файлах, содержащихся в деле.

- **В чем разница между нормальным, раковым, доброкачественным и доброкачественным без объема обратного вызова?**

Каждый том представляет собой сборник дел соответствующего типа. Нормальные случаи формируются из предыдущего обычного скринингового обследования (взятого из файла) для пациента с нормальным обследованием, по крайней мере, четыре года спустя. Обычный скрининговый экзамен - это тот, в котором больше не требуется «проработка». Случай рака формируется в результате скрининговых экзаменов, в которых был обнаружен хотя бы один патологически подтвержденный рак. Доброкачественные случаи формируются в результате скрининговых исследований, в которых было обнаружено что-то подозрительное, но было установлено, что оно не является злокачественным (патология, УЗИ или некоторые другие средства) Термин «доброкачественный без обратного вызова» используется для определения доброкачественных случаев, в которых не было никаких дополнительных фильмов или биопсии, чтобы сделать доброкачественное обнаружение. Эти случаи, однако, содержали кое-что достаточно интересное для радиолога, чтобы отметить. Небольшое количество случаев рака может содержать, в дополнение к одному или нескольким регионам, для которых доказано наличие злокачественных новообразований, к одному или нескольким регионам, которые не доказаны Это подозрительные регионы, для которых нет пути к результату. (Нажмите [здесь](#) для большей информации о наземной правде.) Информация о лексиконе BI-RADS, используемой для кодирования описаний, содержится в файлах наземной правды DDSM на [веб-сайте ACR](#).

- **Как я могу искать в базе данных?**

DDSM имеет возможность поиска, предназначенную для того, чтобы вы могли выявлять случаи, которые соответствуют указанным критериям, таким как нормальный / рак / доброкачественный, рейтинг плотности грудной клетки ACR и описание ключевого слова аномалии ACR. Нажмите [здесь](#), чтобы попробовать средство поиска.

- **Если я использую данные из DDSM в публикациях ...**

Пожалуйста, укажите источник данных в проекте DDSM и укажите:

- [Цифровая база данных для скрининга маммографии](#), Майкл Хит, Кевин Бойер, Даниэль Копанс, Ричард Мур и У. Филип Кегельмейер, в *материалах пятого международного семинара по цифровой маммографии*, M J Yaffe, изд., 212-218, Издание медицинской физики, 2001 ISBN 1-930524-00-5.
- [Текущее состояние Цифровой базы данных для скрининговой маммографии](#), Майкл Хит, Кевин Бойер, Даниэль Копанс, В. Филип Кегельмейер, Ричард Мур, Кен Чанг и С. Мунш Кумаран, в *Цифровой маммографии*, 457-460, Kluwer Academic Publishers, 1998; Материалы четвертого международного семинара по цифровой маммографии.

Также, пожалуйста, отправьте копию своей публикации профессору Кевину Бойеру / Информатика и вычислительная техника / Университет Нотр-Дам / Notre Dame, Indiana 46530.

- **Какие объемы доступны?**

У нас есть 2620 дел в 43 томах. Таблица ниже суммирует содержание каждого тома.

>>

ОБЪЕМ	СЛУЧАЙ	РАЗМЕР	СКАНЕР	BITS	РАЗРЕШАЮЩАЯ СПОСОБНОСТЬ	THUMBNAILS	ПРИМЕЧАНИЯ	ДОСТУПНОСТЬ
normal_01	111	5,8 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP
normal_02	117	6,6 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP
normal_03	38	4,1 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP
normal_04	57	5,1 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP
normal_05	47	4,3 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP
normal_06	60	5,5 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP
normal_07	78	6,2 ГБ	HOWTEK	12	43,5 мкм	эскизы	Примечания	FTP
normal_08	27	2,8 ГБ	HOWTEK	12	43,5 мкм	эскизы	Примечания	FTP
normal_09	59	4,9 ГБ	LUMYSIS	12	50 мкм	эскизы	Примечания	FTP
normal_10	23	2,1 ГБ	LUMYSIS	12	50 мкм	эскизы	Примечания	FTP
normal_11	58	6,1 ГБ	HOWTEK	12	43,5 мкм	эскизы	Примечания	FTP
normal_12	20	2,2 ГБ	HOWTEK	12	43,5 мкм	эскизы	Примечания	FTP
cancer_01	69	3,9 ГБ	LUMISYS	12	50 мкм	эскизы	Примечания	FTP
cancer_02	88	5,7 ГБ	LUMISYS	12	50 мкм	эскизы	Примечания	FTP
cancer_03	66	6,0 ГБ	администратор базы данных	16	42 мкм	эскизы	Примечания	FTP

Рисунок 3.1 – Интерфейсное окно с каталогом базы данных DDSM

Каждое исследование включает в себя два изображения каждой груди, а также некоторую связанную с этим информацию о пациенте (возраст во время исследования, рейтинг плотности сердечной деятельности ACR и т.д.) и информацию об изображении (сканер, пространственное разрешение и т.д.) (рисунок 3.2).




Рисунок 3.2 – Веб-страница, показывающая уменьшенную версию изображений для случая 1252 в DDSM

Граница области на каждом изображении отмечена большим размером, а ядро спекулятивной массы отмечено меньшей областью внутри границы. Нарушение представляет собой злокачественную игольчатую массу с кальцификацией. Изображения, содержащие подозрительные области, имеют связанную с «пикселем» информацию о местах и типах подозрительных областей. На сайте также предоставляются программное обеспечение как для доступа к

изображениям маммограммы, а также для расчета показателей эффективности для автоматизированных алгоритмов анализа изображений.

После выбора изображения и патологии приступаем к формированию вектора информативных признаков для каждого окна. В случае черно-белого изображения – это мода, СКО и среднее значение. На рисунке 3.3 изображена патология молочной железы [8,9,10].

Для выделения патологических сегментов на изображении молочной железы для каждого окна.

1. Запустить программу MATLAB.
2. Выбрать папку untitled и открыть файл untitled.mat рисунок 3.3.
3. В окне «Цифровая обработка изображений» открыть изображение.
4. Сформировать ТЭД: для патологии и здоровой области.

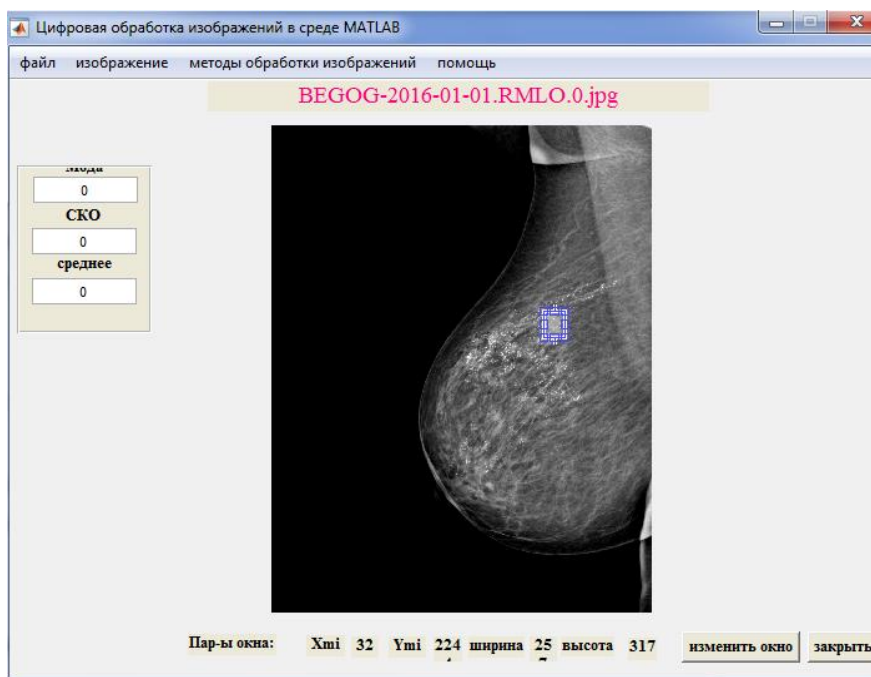


Рисунок 3.3 - Окно программы untitled

5. Занести в ТЭД данные о каждом выбранном окне для патологии и здоровой области.

3.3 Обучение и проверка работы нейронной сети на контрольных выборках для окна 16x16

В таблице 3.1 представлена выборка для окна 16x16.

Таблица 3.1 – Полученные данные

1 класс (патология)				2 класс (здоровые)		
№п/п	Мода	СКО	Среднее	Мода	СКО	Среднее
1	191	7,83	179	128	8,1	116
2	159	24,03	180	159	7,34	164
3	191	4,23	180	96	4,37	96
4	159	5,07	163	96	8,08	109
5	191	26,41	198	96	4,89	95
6	128	8,32	139	96	10,86	107

На рисунках 3.4 и 3.5 представлен фрагмент набора характеристик для 2-х классов: здоровые, больные, которые отображаются при нажатии клавиши «Отобразить числовые значения»

1	2	3
128	8.1	116
159	7.34	164
96	4.37	96
96	8.08	109
96	4.89	95
96	10.86	107
96	4.69	89
128	6.63	123
96	5.02	100
96	8.91	107
96	9.3	106
96	5.75	99
96	6.79	106
96	8.71	81
96	6.69	109
96	28.46	135
96	7.7	83
96	3.96	84
159	7.76	146
128	7.5	119
159	6.42	153
128	25.65	147
64	13.13	77
96	6.38	101

Рисунок 3.4 – Набор индикаторных характеристик для класса здоровых

1	2	3
191	7.83	179
159	24.03	180
191	4.23	180
159	5.07	163
191	26.41	198
128	8.32	139
159	6.66	164
159	6.37	159
159	5.3	163
128	7.14	141
159	5.58	162
96	7.56	155
128	9.26	130
159	6.65	155
128	9.26	130
159	9.89	159
191	23.72	192
159	9.1	145
128	9.48	120
120	9.8	130
128	5.27	143
191	24.38	189
128	15	139
96	6.51	100

Рисунок 3.5 - Набор характеристик для класса патологии молочной железы

Далее на рисунках 3.6 - 3.8 представлено распределение признаков мода, СКО, среднее значение, которые были выбраны из списка «Количество признаков».

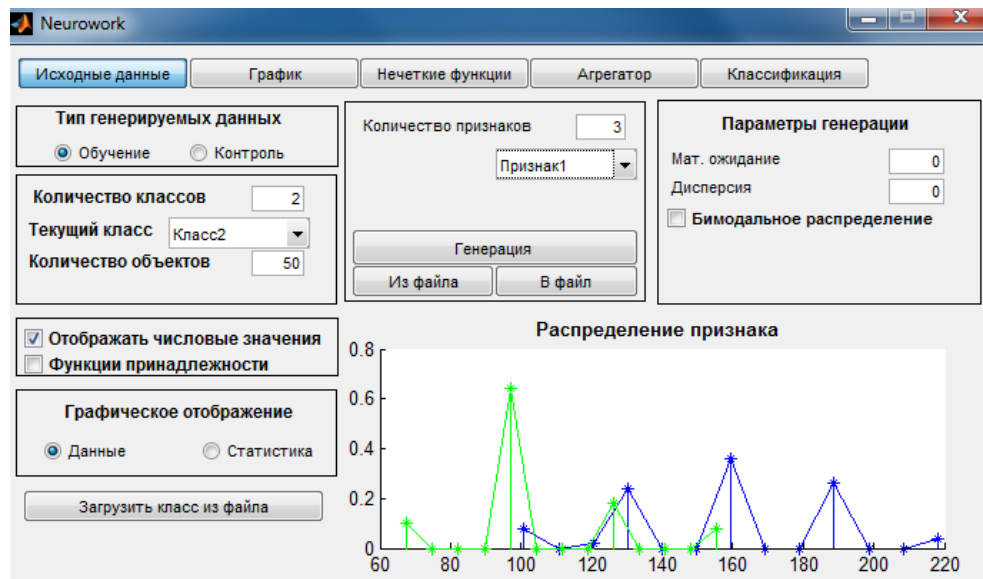


Рисунок 3.6 - Мода для двух классов

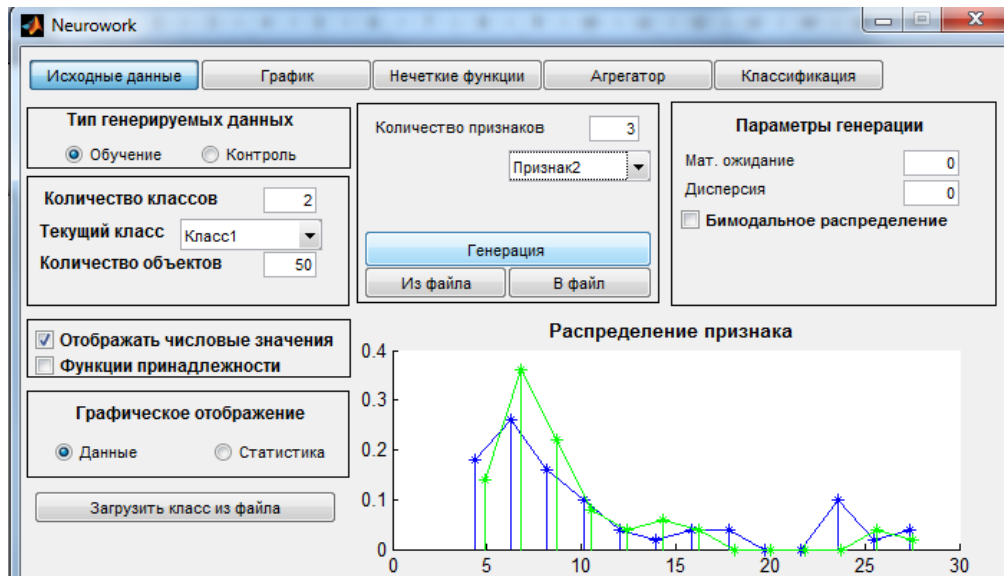


Рисунок 3.7 - СКО для двух классов

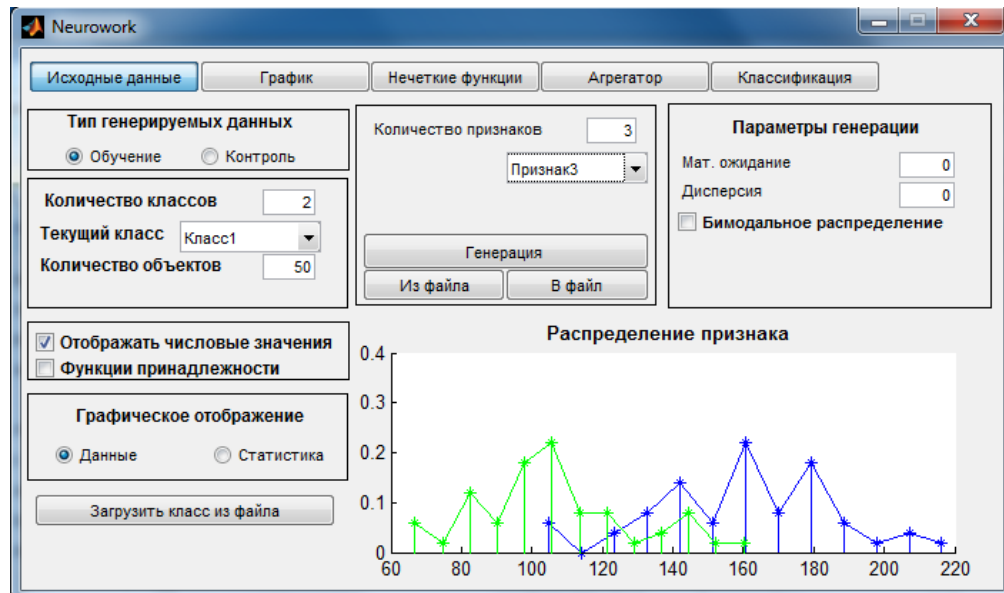


Рисунок 3.8 - Среднее для двух классов

На рисунке 3.9 представлена 3D модель распределения признаков

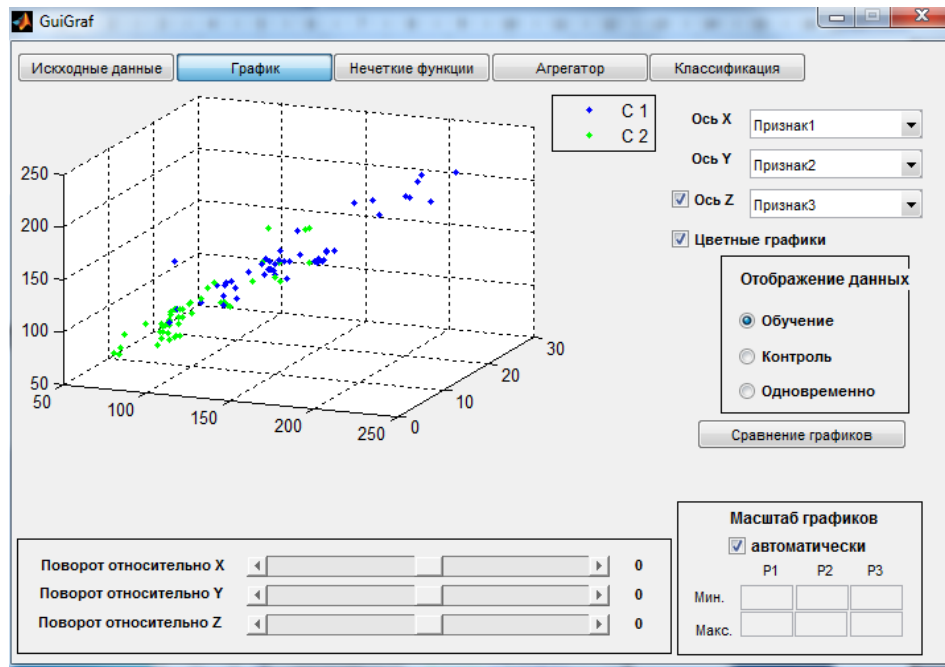


Рисунок 3.9 - График распределение признаков 3D модель

По данным выборок строится нейронная сеть, содержащая по n нейронов в слое. Обучение производится в 50 циклов при предельном значении критерия обучения 0.07. Примеры результатов обучения нейронной сети с помощью программы Neurowork приведен на рисунках 3.9-3.13.

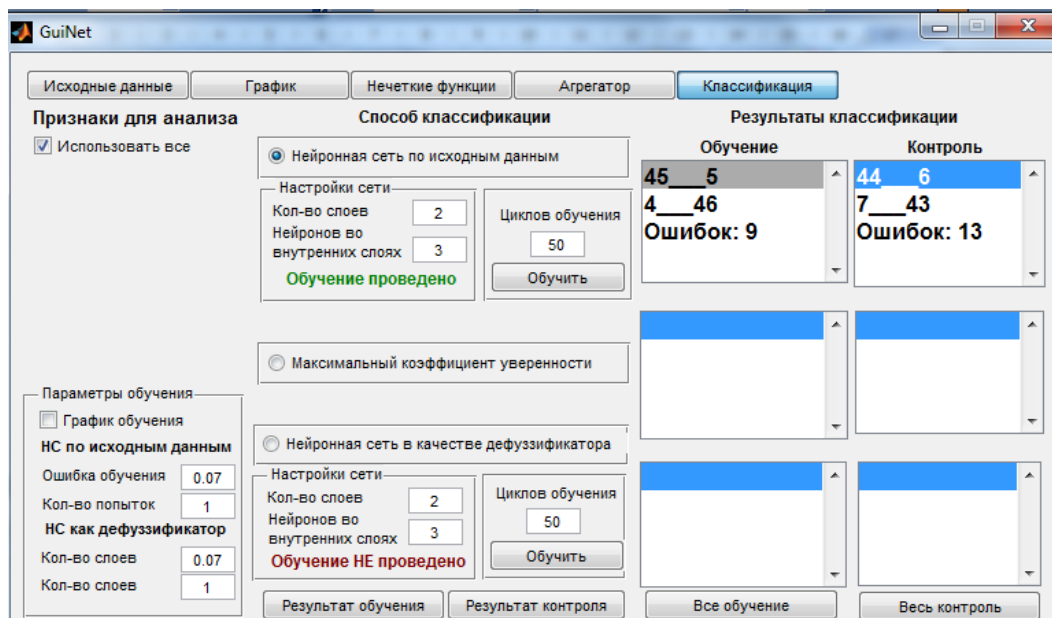


Рисунок 3.9 - Результаты обучения и контроля выборок двухслойной нейронной сети

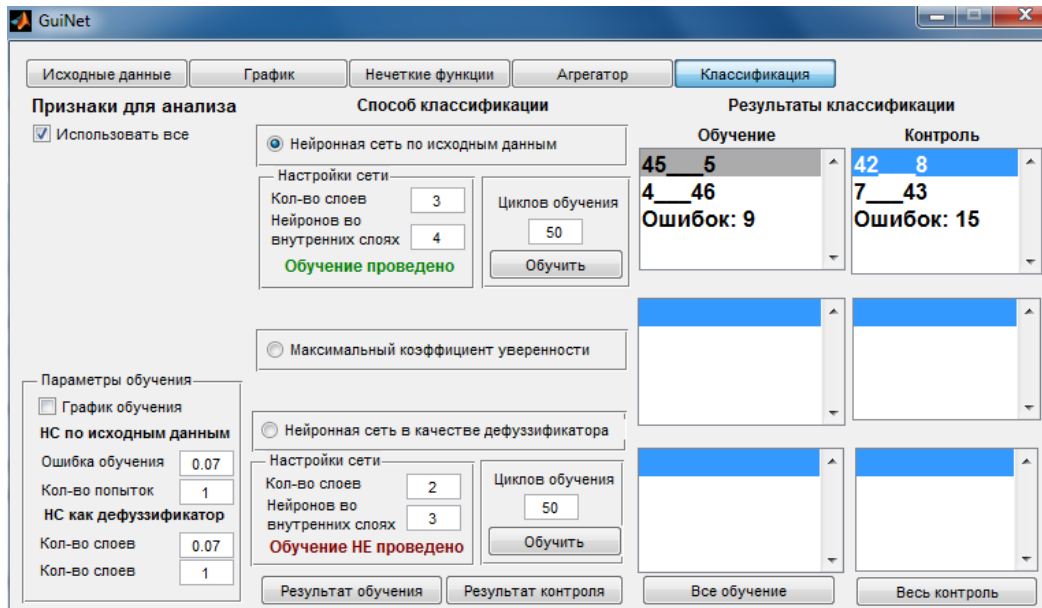


Рисунок 3.10 - Результаты обучения и контроля выборок трехслойной нейронной сети, содержащей по 4 слоя

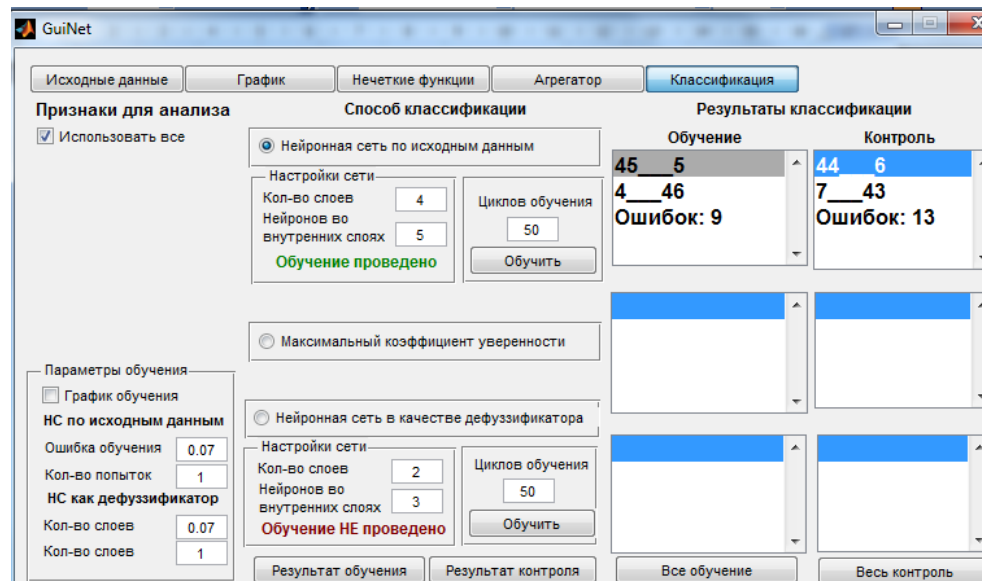


Рисунок 3.11 - Результаты обучения и контроля выборок четырехслойной нейронной сети, содержащей по 5 нейронов в слое

На рисунке 3.12 представлены результаты пятислойной нейронной сети.

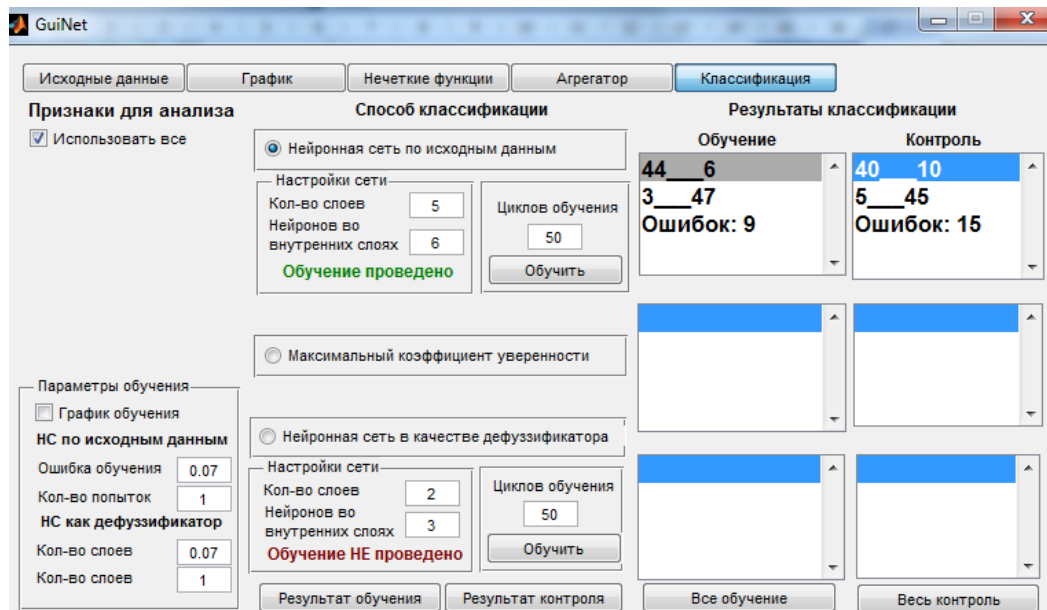


Рисунок 3.12- Результаты обучения и контроля выборок пятислойной нейронной сети, содержащей по 6 нейронов в слое

На рисунке 3.13 представлены результаты шестислойной нейронной сети.

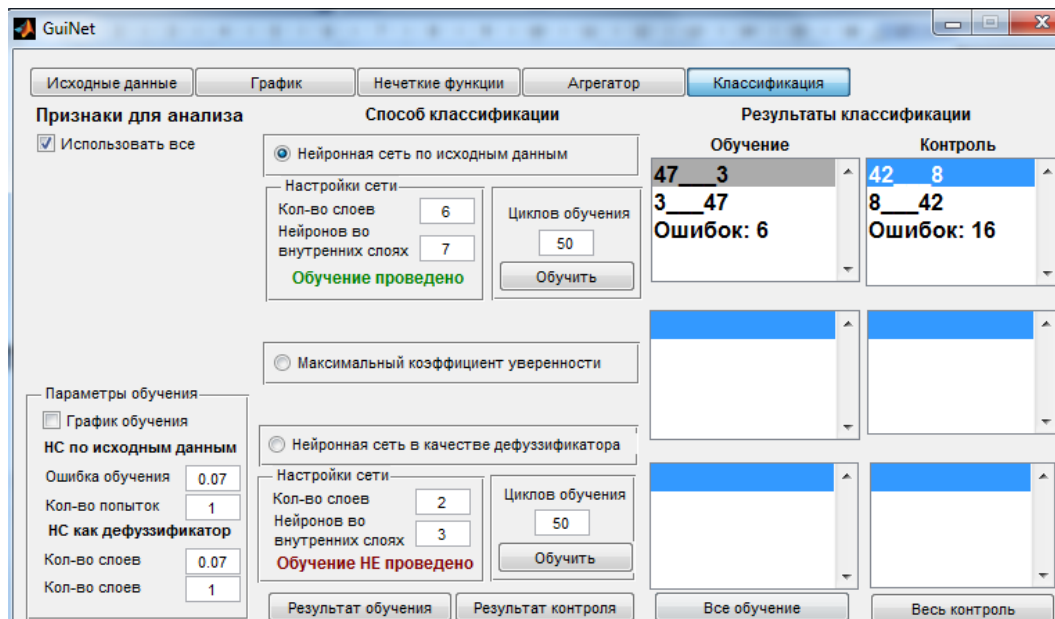


Рисунок 3.13 - Результаты обучения и контроля выборок шестислойной нейронной сети, содержащей по 7 нейронов в слое

В таблице 3.2 представлены показатели качества решающих правил для окна 16x16 обучающих и контрольных выборок

Таблица 3.2 – Показатели качества решающих правил для обучающих выборок

Кол-во слоев/нейронов во внутренних слоях	Обучающие выборки			Контрольные выборки		
	<i>ДЧ</i>	<i>ДС</i>	<i>ДЭ</i>	<i>ДЧ</i>	<i>ДС</i>	<i>ДЭ</i>
2/3	0,9	0,92	0,91	0,88	0,86	0,87
3/4	0,9	0,92	0,91	0,84	0,86	0,85
4/5	0,9	0,92	0,91	0,88	0,86	0,87
5/6	0,88	0,94	0,91	0,8	0,9	0,85
6/7	0,94	0,94	0,94	0,84	0,84	0,84

Таким образом, диагностическая чувствительность модели по контрольным выборкам окна 16x16 равняется в среднем 85%, диагностическая специфичность – 86%, диагностическая эффективность – 86%.

Наиболее лучший результат в данном примере показали двухслойная и четырехслойная нейронная сеть, диагностическая эффективность равна 87%

3.4 Обучение и проверка работы нейронной сети на контрольных выборках для окна 32x32

В таблице 3.3 представлена выборка для окна 32x32.

Таблица 3.3 – Полученные данные

№п/п	1 класс (патология)			2 класс (здоровые)		
	Мода	СКО	Среднее	Мода	СКО	Среднее
1	179	9,49	176	128	18,29	127
2	179	12,45	172	77	12,17	69
3	179	8,45	179	77	9,15	90
4	179	17,91	183	77	14,5	92
5	179	11,2	173	77	15,62	86

На рисунках 3.14 - 3.15 представлены примеры фрагментов набора дескрипторов для 2-х классов: здоровые, больные, которые отображаются при нажатии клавиши «Отобразить числовые значения»

1	2	3
128	18.29	127
77	12.17	69
77	9.15	90
77	14.5	92
77	15.62	86
77	8.41	89
128	17.34	134
102	11.17	108
102	10.52	113
128	27.95	133
128	13.96	117
128	35.92	102
128	30.17	135
102	27.55	129
128	16.53	140
128	23.94	146
128	21.59	130
102	8.88	101
128	47.54	168
77	9.19	82
102	10.11	92
128	29.62	134
128	18.55	135
102	8.36	103

Рисунок 3.14 – Набор дескрипторов для класса здоровых

1	2	3
179	9.49	176
179	12.45	172
179	8.45	179
179	17.91	183
179	11.2	173
153	6.4	165
179	10.7	175
153	22.21	165
153	11.96	151
128	11.89	139
128	7.71	134
128	23.17	154
128	13.45	137
128	10.8	129
128	21.33	145
179	11.32	175
179	9.47	179
179	8.86	170
153	7.1	164
179	22.38	191
153	13.69	147
153	18.97	165
179	8.06	179
179	10.5	172

Рисунок 3.15 - Набор дескрипторов для класса патологии молочной железы

На рисунках 3.16 - 3.18 представлено распределение признаков мода, СКО, среднее значение, которые были выбраны из списка «Количество признаков».

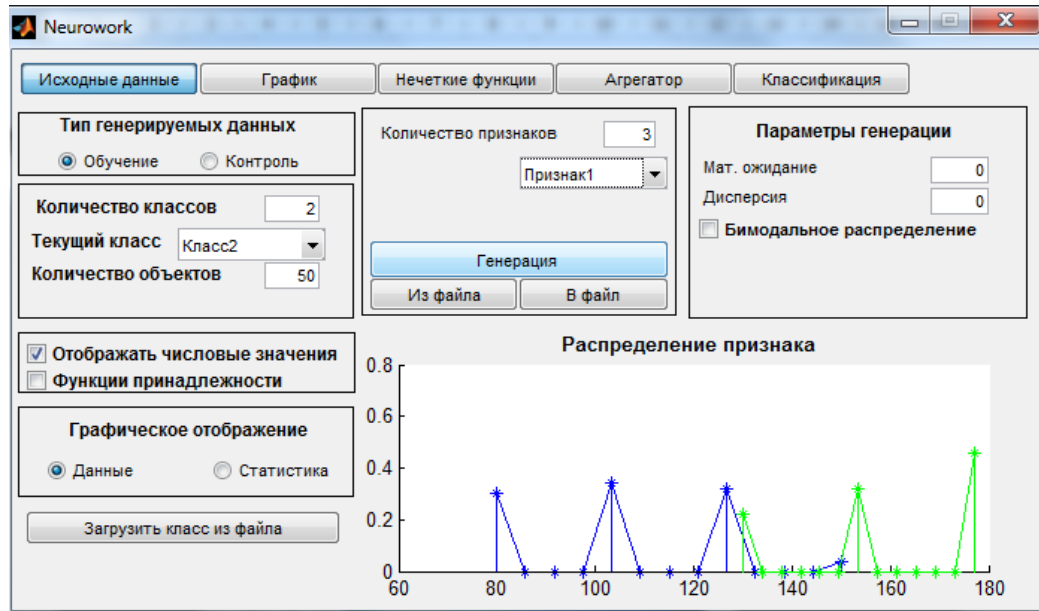


Рисунок 3.16 - Мода для двух классов

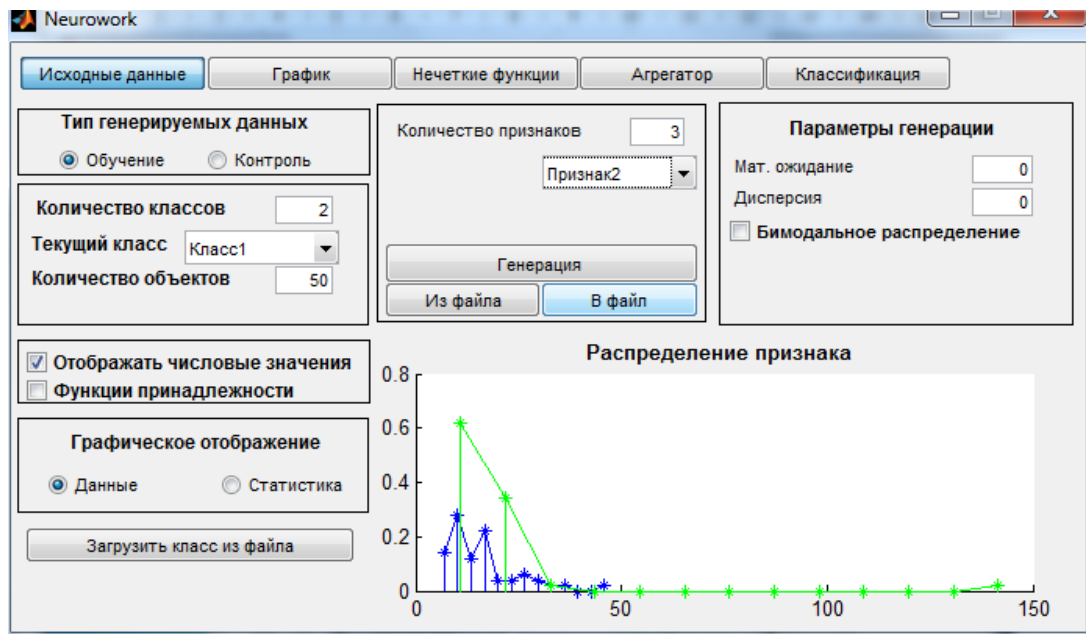


Рисунок 3.17 - СКО для двух классов

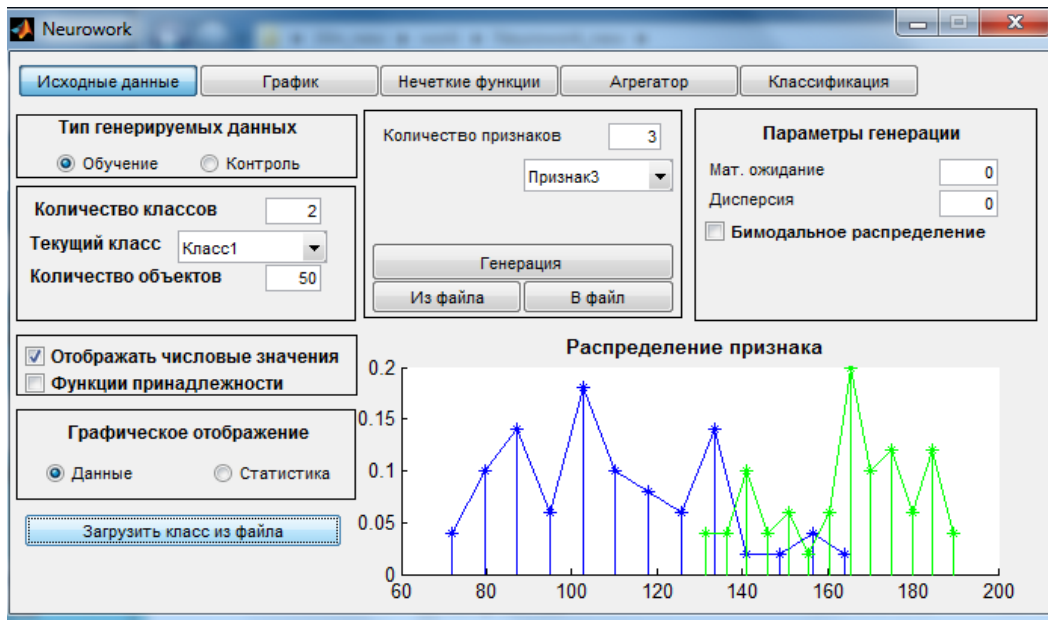


Рисунок 3.18 - Среднее для двух классов

На рисунке 3.19 представлена 3D модель распределения признаков

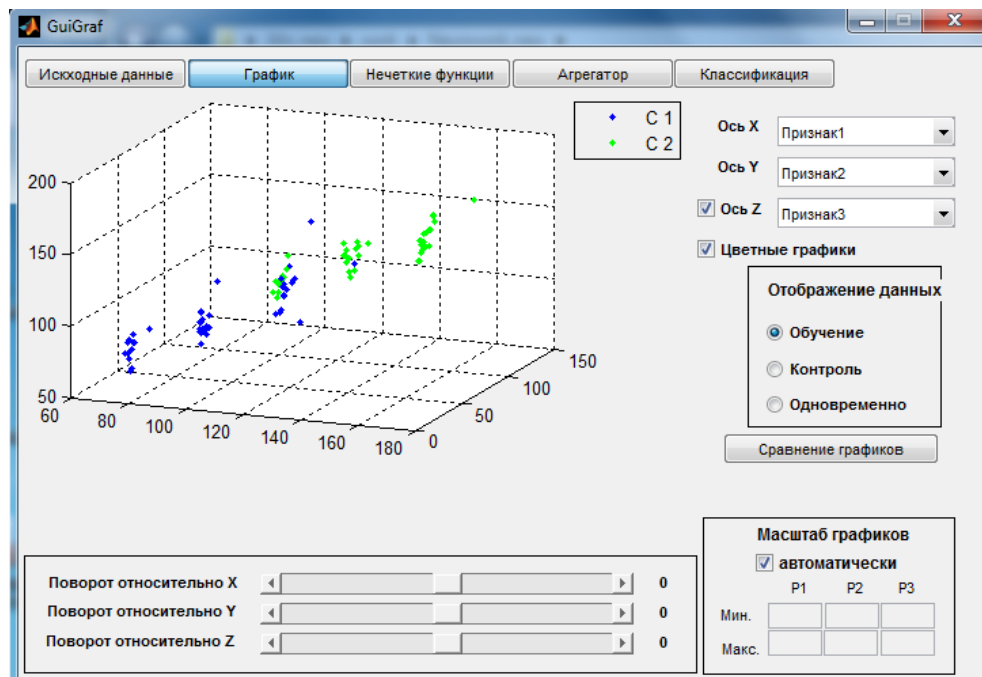


Рисунок 3.19- График распределение признаков 3D модель

По данным выборок строятся нейронные сети, содержащие по n нейронов в слое. Обучение производится в 50 циклов при предельном значении критерия обучения 0.07. Примеры результатов обучения

нейронной сети с помощью программы Neurowork приведены на рисунках 3.20 - 3.24.

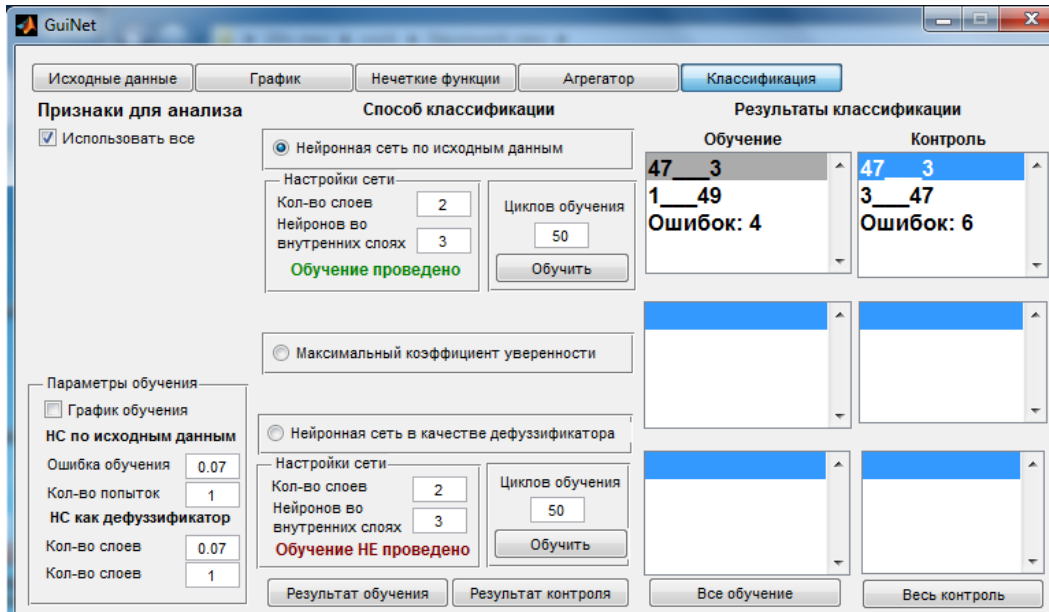


Рисунок 3.20 - Результаты обучения и контроля выборок двухслойной нейронной сети, содержащей по 3 нейрона в слое

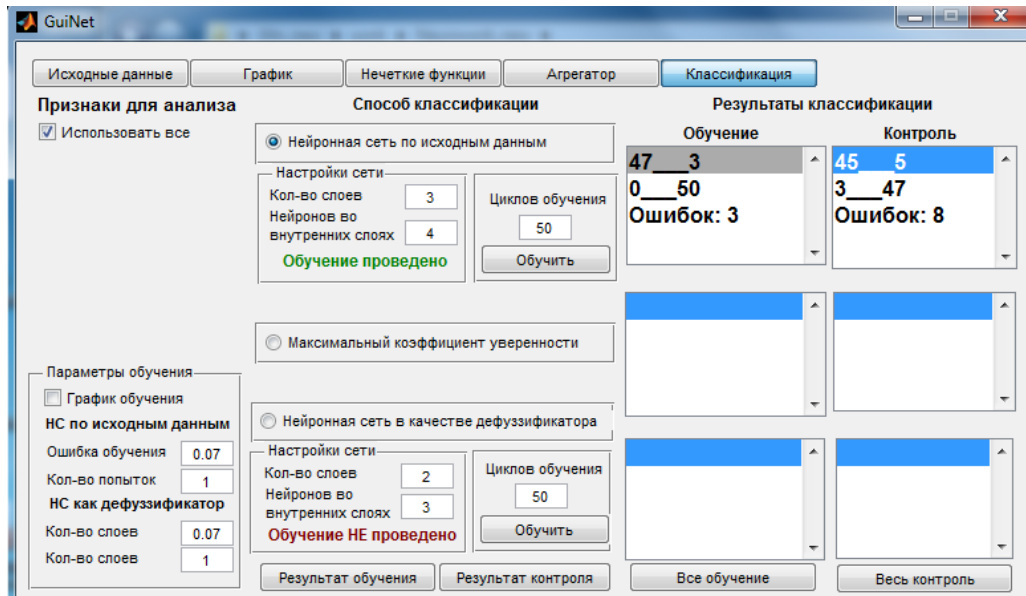


Рисунок 3.21 - Результаты обучения и контроля выборок трехслойной нейронной сети, содержащей по 4 нейрона в слое

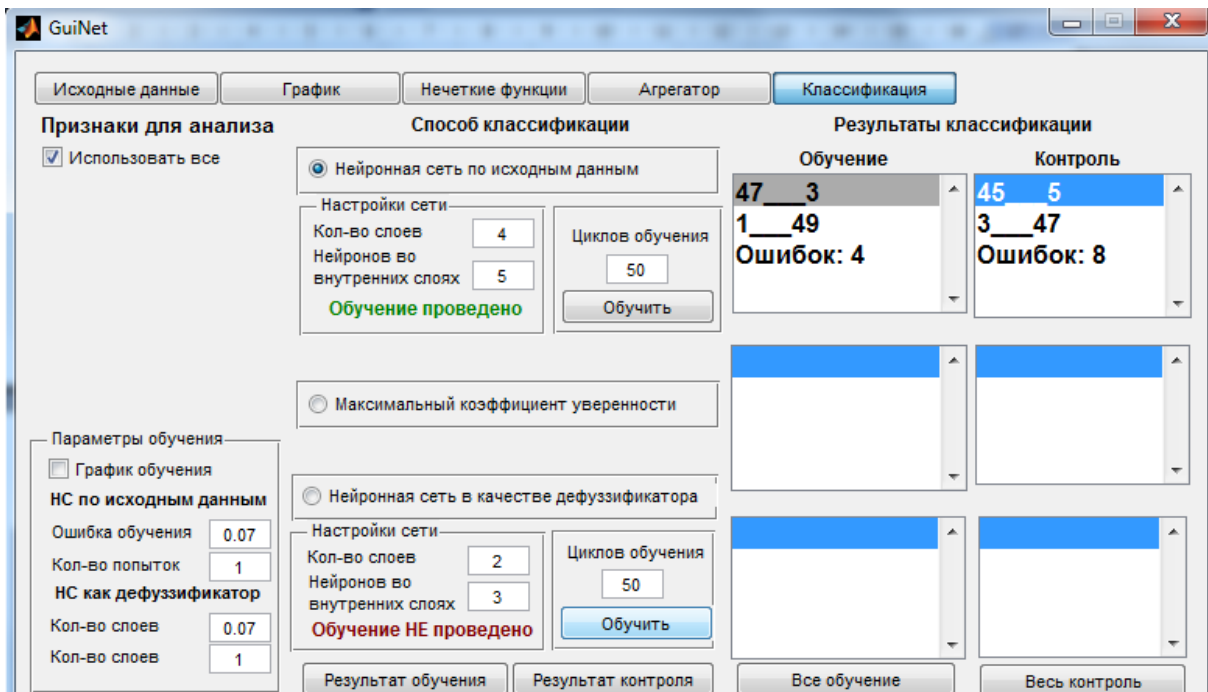


Рисунок 3.22 - Результаты обучения и контроля выборок четырехслойной нейронной сети, содержащей по 5 нейронов в слое

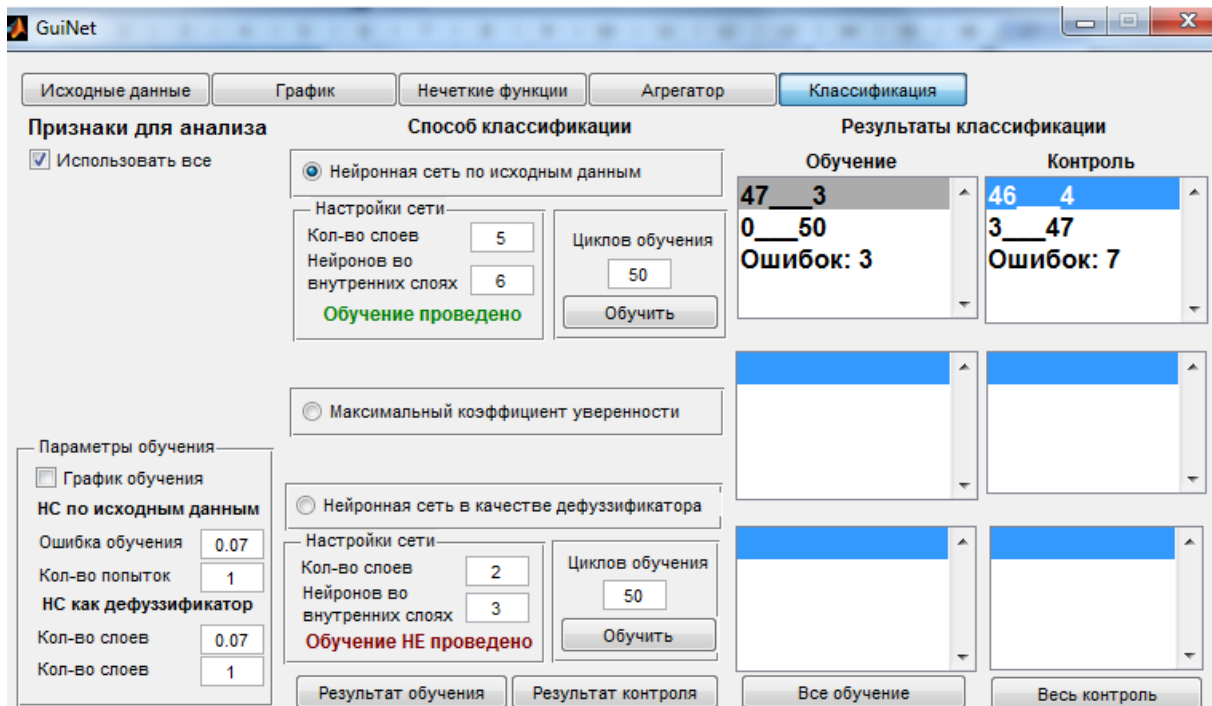


Рисунок 3.23 - Результаты обучения и контроля выборок пятислойной нейронной сети, содержащей по 6 нейронов в слое

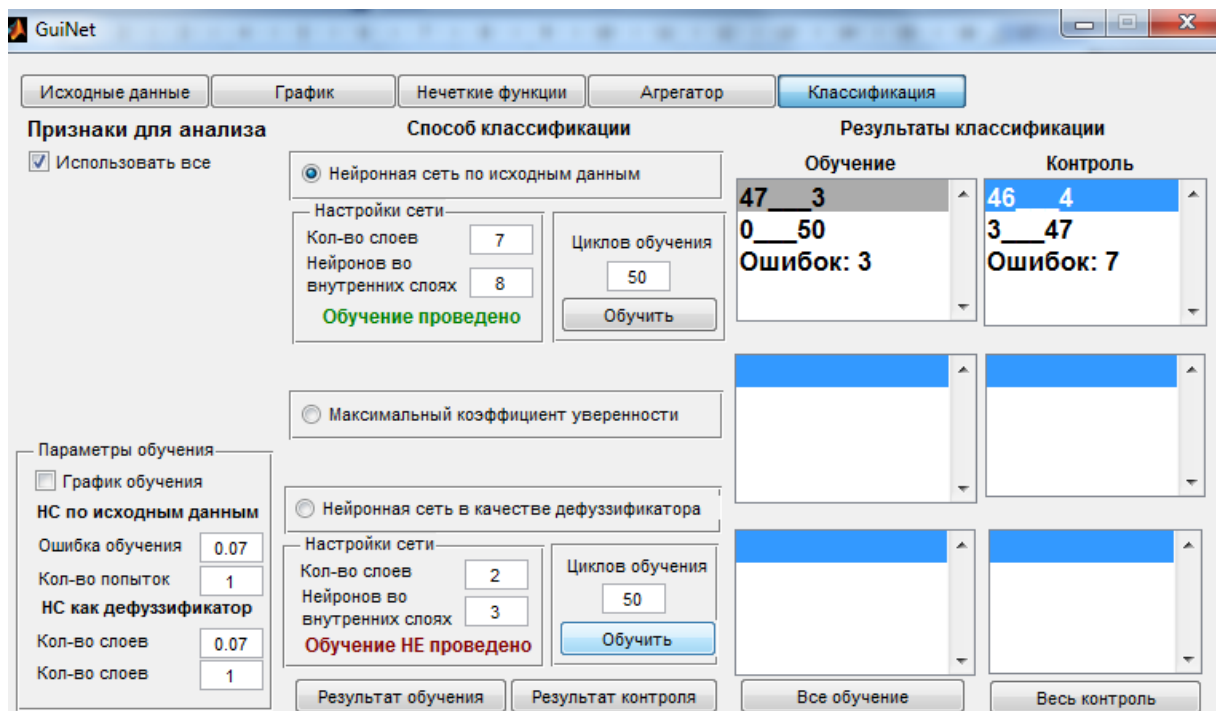


Рисунок 3.24 - Результаты обучения и контроля выборок шестислойной нейронной сети, содержащей по 7 нейронов в слое

В таблице 3.4 представлены показатели качества решающих правил для окна 16x16 обучающих и контрольных выборок

Таблица 3.4 – Показатели качества решающих правил для обучающих и контрольных выборок

Кол-во слоев/нейронов во внутренних слоях	Обучающие выборки			Контрольные выборки		
	<i>ДЧ</i>	<i>ДС</i>	<i>ДЭ</i>	<i>ДЧ</i>	<i>ДС</i>	<i>ДЭ</i>
2/3	0,98	0,94	0,96	0,94	0,94	0,94
3/4	1	0,94	0,97	0,94	0,9	0,92
4/5	0,98	0,94	0,96	0,94	0,9	0,92
5/6	1	0,94	0,97	0,94	0,92	0,93
7/8	1	0,94	0,97	0,94	0,92	0,93

Таким образом, диагностическая чувствительность модели по контрольным выборкам окна 32x32 равняется в среднем 94%,

диагностическая специфичность – 92%, диагностическая эффективность – 93%.

Наиболее лучший результат показали двухслойная нейронная сеть, диагностическая эффективность равна 94%.

3.5 Обучение и проверка работы нейронной сети на контрольных выборках для окна 64x64

В таблице 3.5 представлена выборка для окна 32x32.

Таблица 3.5 – Полученные данные

№п/п	1 класс (патология)			2 класс (здоровые)		
	Мода	СКО	Среднее	Мода	СКО	Среднее
1	170	15,32	172	128	20,28	136
2	170	12,53	178	106	11,73	102
3	170	13,81	173	106	23,11	123
4	170	8,62	167	106	35,68	123
5	170	8,41	167	106	18,6	100

На рисунках 3.25 - 3.26 представлен фрагмент набора характеристик для 2-х классов: здоровые, больные, которые отображаются при нажатии клавиши «Отобразить числовые значения»

1	2	3
128	20.28	136
106	11.73	102
106	23.11	123
106	35.68	123
106	18.6	100
85	9.05	90
106	39.15	145
128	19.84	133
106	50.86	139
106	18.27	101
106	19.3	103
85	14.26	93
64	33.48	89
191	36.35	174
128	33.71	135
170	29.51	151
106	23.23	116
85	35.31	98
85	9.06	94
85	10.09	90
106	15.48	103
85	14.72	86
85	11.56	87
85	10.34	87

Рисунок 3.25 – Набор индикаторных характеристик для класса здоровых

1	2	3
170	15.32	172
170	12.53	178
170	13.81	173
170	8.62	167
170	8.41	167
170	18.75	180
149	14.65	160
149	14.21	156
149	17.56	155
149	16.53	145
149	20.7	144
149	15.03	151
170	17.16	176
170	16	176
170	17.58	173
170	8.3	167
170	7.64	170
170	17.2	178
170	15.64	178
149	17.83	152
149	19.37	143
128	17.23	133
128	19.34	124
149	28.57	157

Рисунок 3.26 - Набор характеристик для класса патологии молочной железы

Далее на рисунках 3.27 - 3.29 представлено распределение признаков мода, СКО, среднее значение, которые были выбраны из списка «Количество признаков».

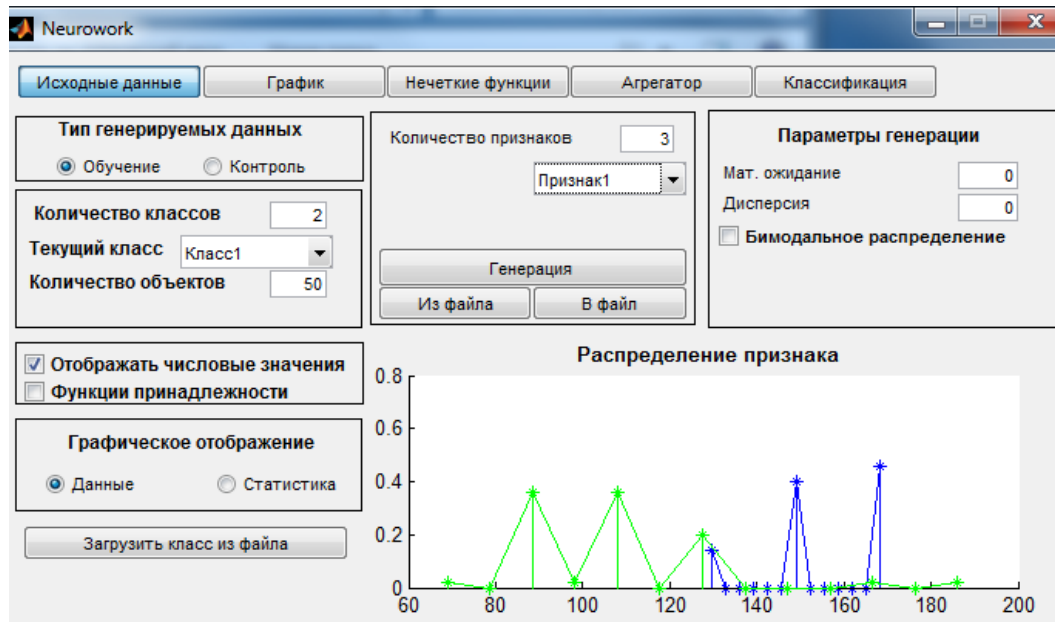


Рисунок 3.27 - Мода для двух классов

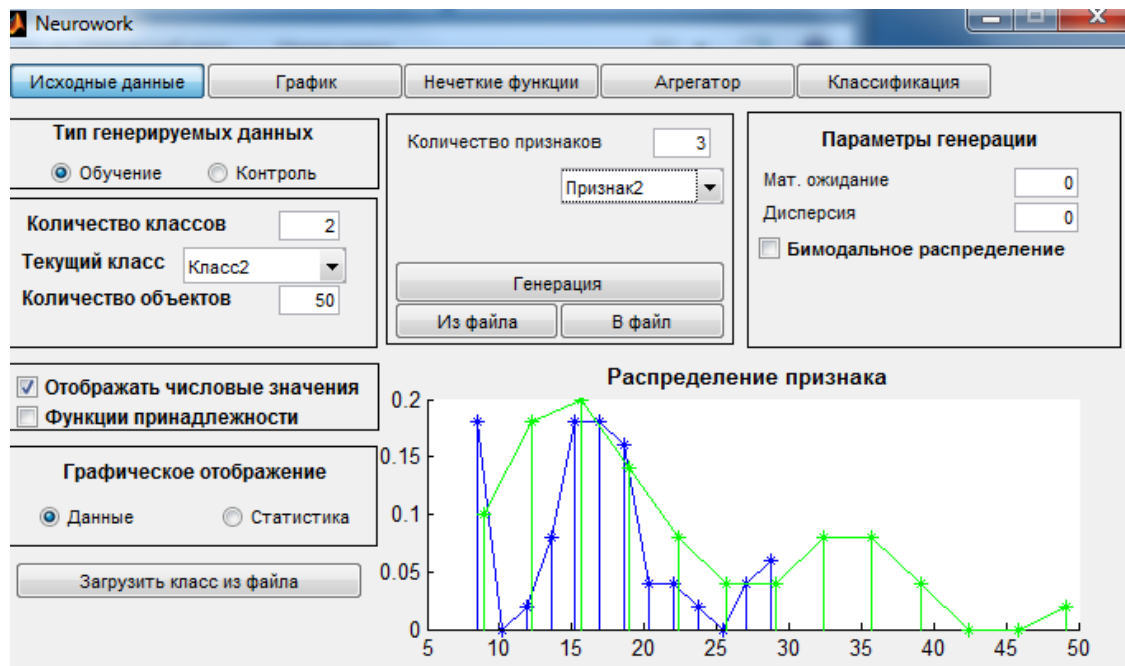


Рисунок 3.28 - СКО для двух классов

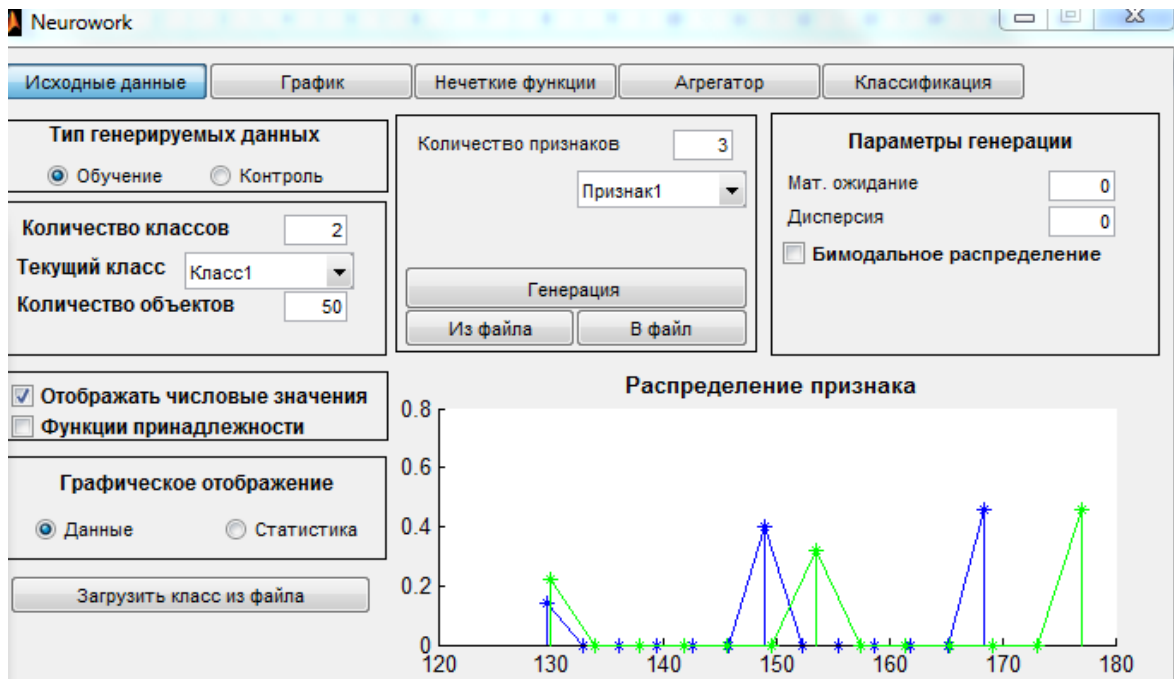


Рисунок 3.29 - Среднее для двух классов

На рисунке 3.30 представлена 3D модель распределения признаков

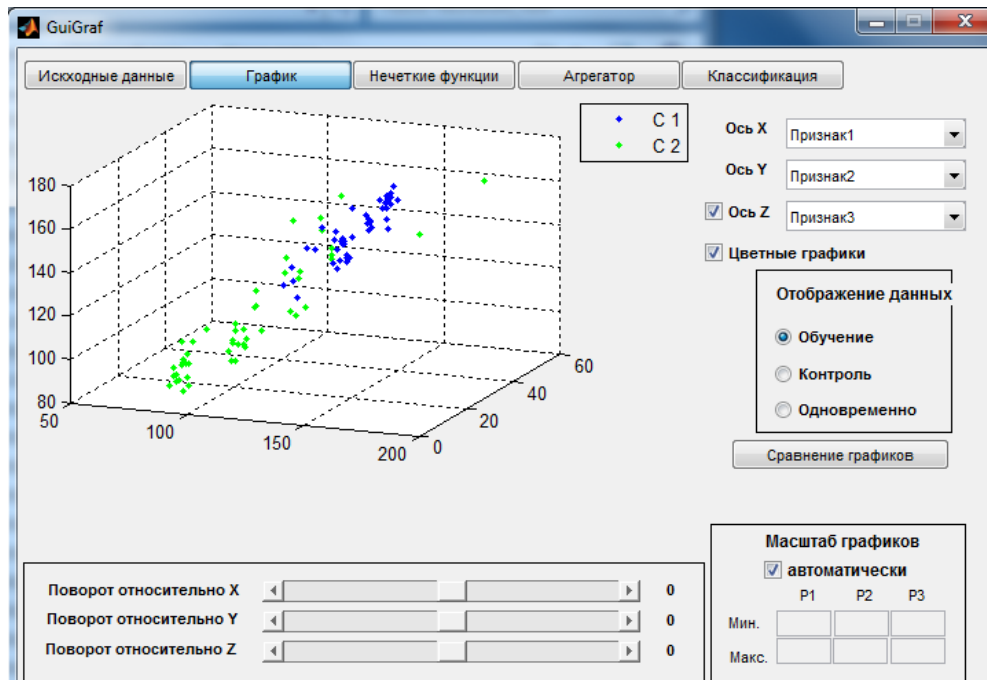


Рисунок 3.30- График распределение признаков 3D модель

По данным выборок строятся нейронные сети, содержащие по n нейронов в слое. Обучение производится в 50 циклов при предельном значении критерия обучения 0,07. Примеры результатов обучения нейронной сети с помощью программы Neuowork приведены на рисунках 3.31 - 3.35.

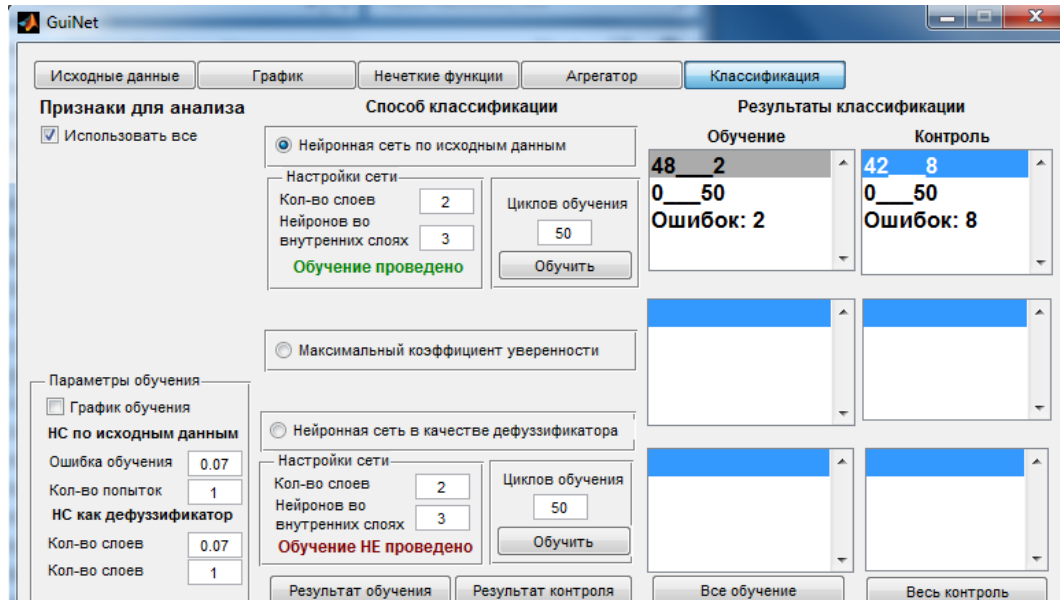


Рисунок 3.31 - Результаты обучения и контроля выборок двухслойной нейронной сети, содержащей по 3 нейрона в слое

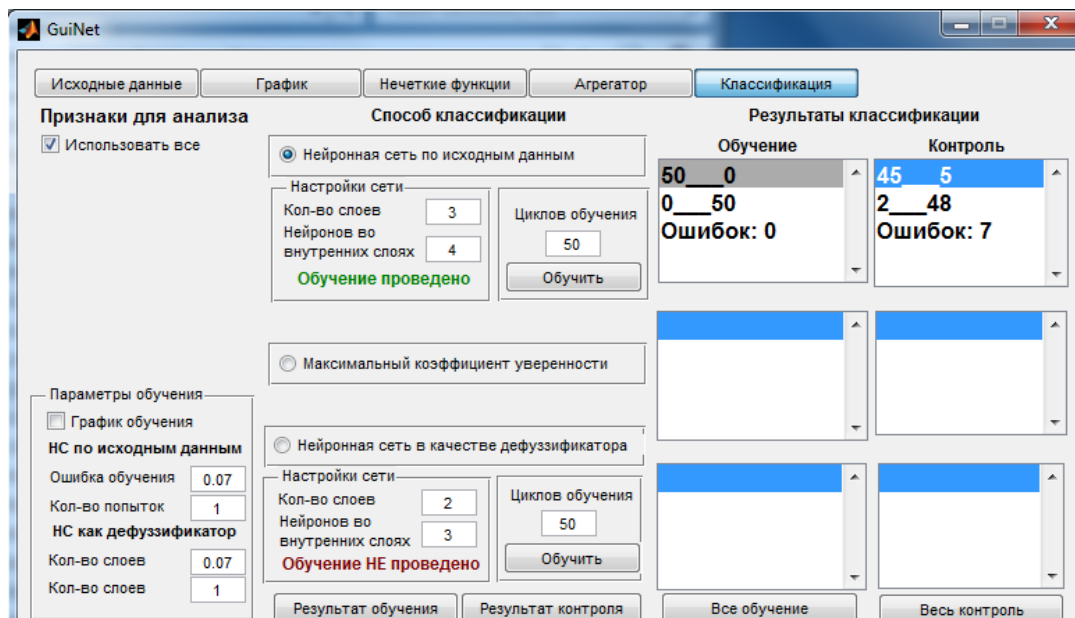


Рисунок 3.32 - Результаты обучения и контроля выборок трехслойной нейронной сети, содержащей по 4 нейрона в слое

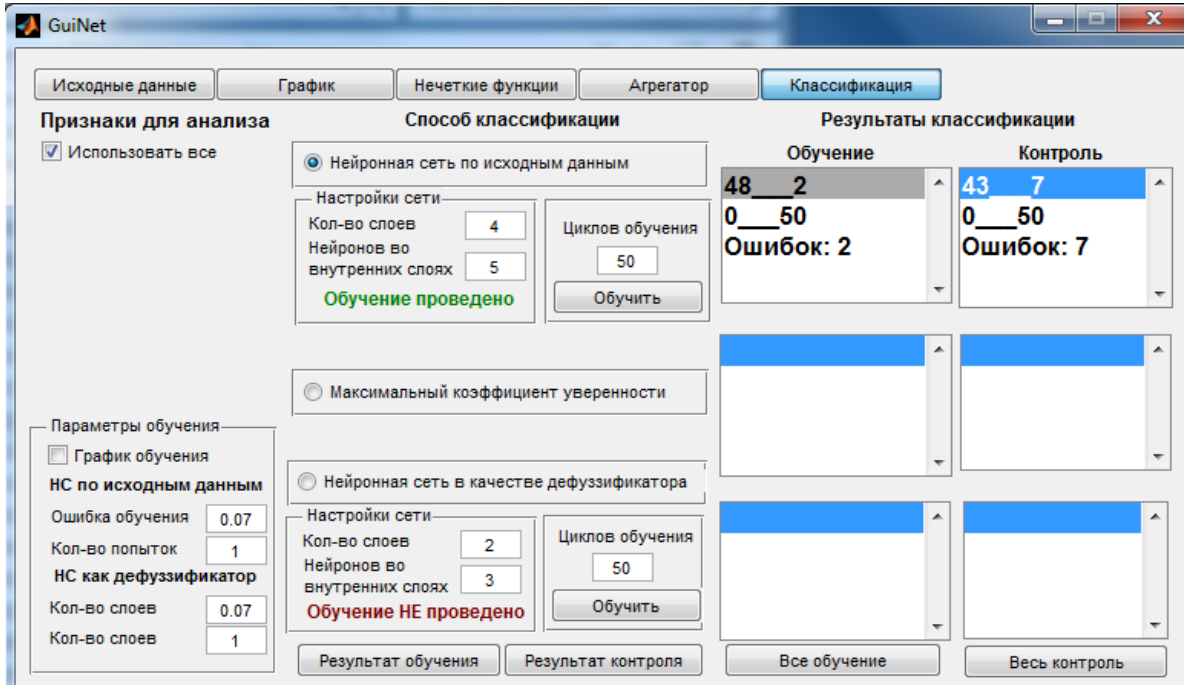


Рисунок 3.33 - Результаты обучения и контроля выборок четырехслойной нейронной сети, содержащей по 5 нейронов в слое

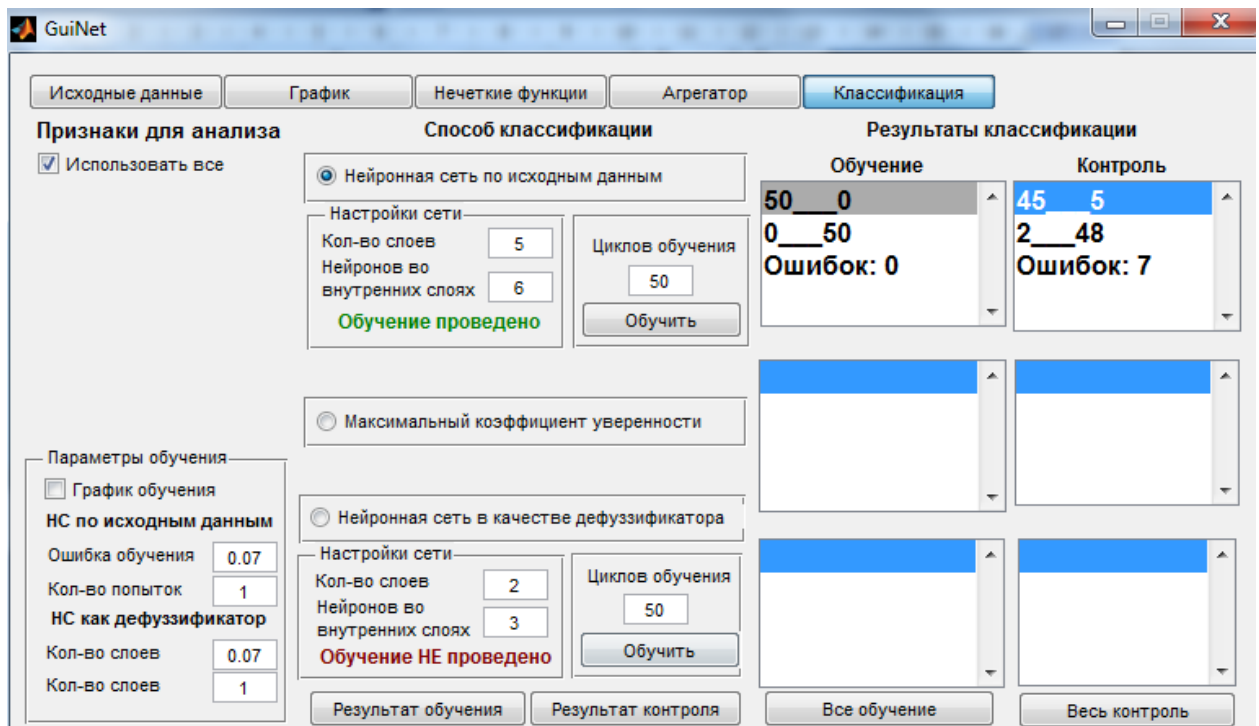


Рисунок 3.34 - Результаты обучения и контроля выборок пятислойной нейронной сети, содержащей по 6 нейронов в слое

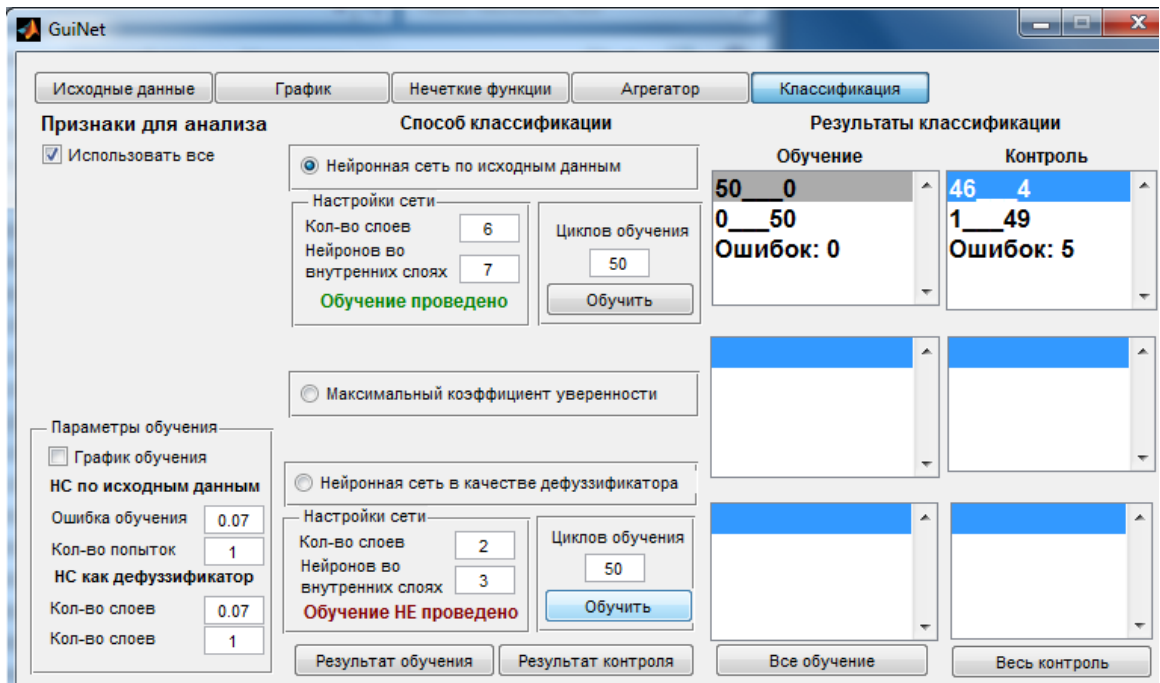


Рисунок 3.35 - Результаты обучения и контроля выборок шестислойной нейронной сети по 7 нейронов в слое

В таблице 3.6 представлены показатели качества решающих правил для окна 63x64 обучающих и контрольных выборок

Таблица 3.6 – Показатели качества решающих правил для обучающих и контрольных выборок

Кол-во слоев/нейронов во внутренних слоях	Обучающие выборки			Контрольные выборки		
	<i>ДЧ</i>	<i>ДС</i>	<i>ДЭ</i>	<i>ДЧ</i>	<i>ДС</i>	<i>ДЭ</i>
2/3	1	0,96	0,98	1	0,84	0,92
3/4	1	1	1	0,96	0,9	0,93
4/5	1	0,96	0,98	1	0,86	0,93
5/6	1	1	1	0,96	0,9	0,93
6/7	1	1	1	0,98	0,92	0,95

Таким образом, диагностическая чувствительность модели по контрольным выборкам окна 64x64 равняется в среднем 98%, диагностическая специфичность – 88%, диагностическая эффективность – 93%.

Наиболее лучший результат показали шестислойная нейронная сеть, диагностическая эффективность равна 95%.

Получены результаты, приемлемы для применения в клинических условиях при диагностике патологий молочной железы. Поскольку значение диагностических показателей качества превышают в среднем уровень 0,91.

3.6 Формирование агрегатора частных решений

На рисунке 3.36 представлены наилучшие результаты диагностических показателей по каждому из окон.




Рисунок 3.36 - Результаты диагностических показателей по каждому из окон

Полагаем, что результаты на выходах нейронных сетей определяют уверенность в принадлежности данного образца к определенному классу. Тогда лучшие результаты могут быть агрегированы по правилу агрегации нечетких решений. Такой этап называют дефузификацией. Преобразования нечетких коэффициентов уверенности K_{ij} в четкие номера классов \bar{u} в большинстве распространенных систем реализуется с использованием

критерия максимального коэффициента уверенности среди всех значений агрегаторов:

$$f(Ku_1..Ku_n) = \arg(\max(Ku_1..Ku_n)). \quad (3.1)$$

Однако в ходе исследований было выяснено, что данный подход обладает существенными недостатками. Наиболее существенным недостатком является тот факт, что при использовании данного принципа не учитывается величина разности между полученными коэффициентами уверенности для разных классов. Тогда как для принятия корректного решения о назначении терапии ситуация, когда коэффициент уверенности в патологии равен 0.8, а уверенность в ее отсутствии равна 0.4, далеко не равнозначна ситуации, когда $Ku_1 = 0.8$, а $Ku_2 = 0.79$. При использовании критерия (3.1) в обеих ситуациях результатом прогнозирования будет патология, тогда как в действительности второй случай вызывает значительно больше сомнений и требует более тщательного рассмотрения. На основании указанных фактов для повышения точности прогнозирования было принято решение использовать в качестве дефuzziфикатора обучаемую нейронную сеть, принимающую на вход коэффициенты уверенности, а на выходе дающую результат прогнозирования, где NET_k – выходы последнего слоя нейронной сети

$$f(Ku_1..Ku_n) = \max_{k=1..n}(NET_k(Ku_1..Ku_n)). \quad (3.2)$$

Преимуществом данного способа является тот факт, что при наличии ситуаций, в которых действительным классом являлся класс не с максимальным коэффициентом уверенности – подобные ситуации будут запомнены нейронной сетью в процессе обучения и эти сведения отразятся на принятии последующих решений на контрольных данных. Экспериментальные исследования, показывают, что для корректной работы сети в качестве дефuzziфикатора при необходимости разделения данных на два класса достаточно наличие двух внутренних слоев с четырьмя нейронами в каждом из них (рисунок 3.37).




Рисунок 3.37 - Структура нейронной сети, используемой в качестве дефuzziфикатора

После обучения всех нейронных сетей первого иерархического уровня формируется таблица "объект - признак" для нейронной сети дефuzziфикатора (рисунок 3.37). Формат данных в этой таблице представлен в таблице 3.7.

Таблица 3.7 - Формат данных для обучения нейронной сети второго иерархического уровня

NN образцов	Вход 1 NET-16x16	Вход 2 NET-32x32	Вход 3 NET-64x64	Цель
1	$(\omega_1^*)_1$	$(\omega_2^*)_1$	$(\omega_3^*)_1$	0
2	$(\omega_1^*)_2$	$(\omega_2^*)_2$	$(\omega_3^*)_2$	1
·	·	·	·	·
·	·	·	·	·
·	·	·	·	·
m	$(\omega_1^*)_m$	$(\omega_2^*)_m$	$(\omega_3^*)_m$	1

Строки в ней, как и в таблицах 3.1-3.3, являются сегменты рентгеновских маммограмм с патологией и без нее. В качестве независимых переменных в этой таблице выступают выходы нейронных сетей первого иерархического уровня. При этом выбираются архитектуры нейронных сетей с лучшими диагностическими показателями.

ЗАКЛЮЧЕНИЕ

Компьютерное исследование молочной железы – это достаточно перспективное направление исследований, которое может существенно повысить уровень медицинской диагностики болезней молочной железы.

При построении модели нейронной сети в целом программа должна определять патологические сегменты.

Результат обучения программы зависит от составления выборок, а также от их объема. При достаточно большом объеме выборок программа выполнит обучение с более высокой диагностической эффективностью.

В курсовой работе необходимо привести результаты классификации патологических участков молочной железы и показать, что используемый метод диагностики патологий молочной железы обладает достаточно высокой точностью. Используемую нейронную сеть можно в дальнейшем улучшать.

Использование методов и алгоритмов, основанных на различных парадигмах, позволило построить гибридные модели классификации, которые применяют как методы обучаемых систем распознавания образов, так и методы экспертного оценивания.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Шальнова, С.А Анализ смертности от болезней молочной железы / С.А Шальнова, А.О Конради, Ю.А. Карпов, А.В. Концевая, А.Д. Деев, А.В, Капустина М.Б. Худяков, Е.В. Шляхто, С.А. Бойцов // Российский журнал. -2012. -Т. 17. № 5. -С. 6-11.
2. Джорупбекова, К.Ш. Оценка распространенности основных факторов риска патологий молочной железы/ К.Ш. Джорупбекова, Р.Б. Кыдыралиева, А.Т. Алтымышева// International Scientific Review. - 2016. -№ 20 (30). -С. 84-90.
3. Дюжиков, А.А. Современные методы диагностики и лечения патологий молочной железы / А.А. Дюжиков// Главный врач Юга России. -2015. -№ 1 (42).-С. 6-9.
4. Семенова, Л.В. Патологии молочной железы базы данных/ Л.В. Семенова, В.И. Гагарин, Е.С. Прокопьев// Международный журнал прикладных и фундаментальных исследований. -2013. -№ 2. -С. 24-25.
5. Иванов, К.М. Патологии молочной железы / К.М. Иванов, Ю.А. Юдаева, М.В Баталина, И.А Баталина// Учебное пособие Оренбург, -2013. -№ 4. -С. 240-250.
6. Трунов, В.Г. Молочная железа анализ методов диагностики/ В.Г. Трунов, Э.А. Айду, Е.В. Блинова, Т.А. Сахнова// Медицинский алфавит. -2017. -Т. 1.№ 14 (311). -С. 16-21.
7. Хамидов, Н.Х. Патологии молочной железы методы и алгоритмы диагностики/ Н.Х. Хамидов, Н.М. Хурсанов, К.Р. Воронцов, Н.Д. Шарифова// Здравоохранение Таджикистана. -2013. -№ 4 (319). -С. 79-84.
8. Зарецкий, А.П. Алгоритм предварительной обработки и анализа изображений молочной железы/ А.П. Зарецкий А.П, В.С. Тарасов В, К.С. Митягин, А.С. Куралева // Молодежный научный вестник. -2018. -№ 12 (37). -С. 240-247.
9. Чипунгу, М.Г. Разработка алгоритма сегментации изображений при заболевании молочной железы/ М.Г. Чипунгу // В книге: Радиоэлектроника. Проблемы и перспективы развития тезисы докладов третьей всероссийской молодежной научной конференции. - 2018. -С. 156-157.

10. Анциперов, В.Е. Сегментация изображений / В.Е. Анциперов, И.В. Забросаев, Д.В. Растягаев // Молодежный научный вестник. - 2015. -№ 12. -С. 16.