

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РЕСПУБЛИКИ КАЗАХСТАН

Казахский национальный исследовательский технический университет имени
К.И. Сатпаева

Институт промышленной автоматизации и цифровизации имени
А. Буркитбаева

Кафедра электроники, телекоммуникации и космических технологии

Сатыбалдиев Ақжол Абдікерұлы

Исследование методов сжатия телеметрической информации

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

Специальность 6М074600 – «Космическая техника и технологии»

Алматы 2020

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РЕСПУБЛИКИ КАЗАХСТАН

Казахский национальный исследовательский технический университет имени
К.И. Сатпаева

Институт промышленной автоматизации и цифровизации имени
А. Буркитбаева

УДК 681.3.053

На правах рукописи

Сатыбалдиев Ақжол Абдікерұлы


МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

На соискание академической степени магистра

Название диссертации «Исследование методов сжатия телеметрической информации»

Направление подготовки 6М074600 «Космическая техника и технологии»

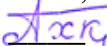
Научный руководитель
Профессор, кандидат технических наук


Таштай Е. Т.
«29» июля 2020 г.

Рецензент

Дтн., доцент


Исаков К. А.
«28» июля 2020 г.

Нормоконтроллер
PhD, сениор-лектор

Хабай А.
«29» июля 2020 г.

ДОПУЩЕН К ЗАЩИТЕ
Заведующий кафедрой
И. Сыргабаев
« ____ » _____ 2020 г.

Алматы 2020

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РЕСПУБЛИКИ КАЗАХСТАН

Казахский национальный исследовательский технический университет имени
К.И. Сатпаева

Институт промышленной автоматизации и цифровизации имени
А. Буркитбаева

Кафедра Электроники, телекоммуникации и космических технологий
6М074600 – «Космическая техника и технологии»

УТВЕРЖДАЮ
Зав.кафедрой ЭТиКТ
_____ И.Сыргабаев
« ____ » _____ 2020 г.

ЗАДАНИЕ
на выполнение магистерской диссертации

Магистрант Сатыбалдиев Акжол Абдикерулы

Тема диссертационной работы: «Исследование методов сжатия телеметрической информации»

Утверждена приказом Ректора Университета №1194-М от «29» октября 2018 года.

Срок сдачи законченной работы «29» июля 2020 года

Исходные данные к дипломной работе: Коэффициент сжатия не менее 3-х; Допустимо потери при сжатии телеметрических данных; Алгоритмы сжатия и восстановления требуют приблизительно равных вычислительных ресурсов.

Перечень подлежащих разработке в магистерской диссертации вопросов:

- а) Исследование методов сжатия телеметрической информации;*
- б) Анализ возможностей искусственных нейронных сетей;*
- в) Программная реализация сжатия снимков искусственных нейронных сетей;*

Перечень графического материала (с точным указанием обязательных чертежей): представлены 24 слайдов презентации работы.

Рекомендуемая основная литература:

1. Ватолин Д., Ратушняк А., Смирнов М. Методы сжатия данных. Устройство архиваторов, сжатие изображений и видео. – Диалог-МИФИ, 2002. – С. 384. – ISBN 5-86404-170-X
2. Ватолин Д. Алгоритмы сжатия изображений: Методическое пособие. – М.: Издат отдел факультета ВМиК МГУ им. Ломоносова 1999 – 76 с.


3. Баранов Г. Обзор методов сжатия данных -
<http://www.compression.ru/arctest/descript/methods.htm>

ГРАФИК
подготовки магистерской диссертации

Наименование разделов, перечень разрабатываемых вопросов	Сроки представления научному руководителю	Примечание
Исследовать методы сжатия телеметрической информации	1.09.2018 – 1.03.2019	Выполнено
Исследовать возможности искусственных нейронных сетей	1.03.2019 – 1.04.2019	Выполнено
Разработка алгоритма программной реализации сжатия снимков искусственных нейронных сетей	1.04.2019 – 1.11.2019	Выполнено

Подписи

консультантов и нормоконтролера на законченную магистерскую диссертацию с указанием относящихся к ним разделов диссертации

Наименования разделов	Консультанты, И.О.Ф. (уч. степень, звание)	Дата подписания	Подпись
Теоретическая часть	Профессор, кандидат технических наук Таштай Е.Т.	20 января 2020 г.	
Экспериментальная часть	Профессор, кандидат технических наук Таштай Е.Т.	01 апреля 2020 г.	
Результаты и их обсуждение	Профессор, кандидат технических наук Таштай Е.Т.	8 июня 2020 г.	
Нормоконтролер	PhD, А.Хабай	29 июля 2020 г.	

Научный руководитель  _____ Таштай Е.

Магистрант  _____ Сатыбалдиев А.А.

«28» июля 2020 г.

АННОТАЦИЯ

В магистерской диссертации исследовались перспективы развития нейронных сетей на основе метода прямого решения (МПР) для сжатия цифровых изображений. Предлагаемая методика включает в себя этапы разбивки больших изображений на меньшие окна и устранения избыточной информации и может широко использоваться для дистанционного зондирования Земли. Отмечается важность использования в этой методике инструментов нейронной сети обученная методом прямого решения.

Алгоритм обратного распространения ошибок также используется для обучения нейронной сети, и сравниваются оба алгоритма обучения. Расчетные результаты, такие как степень сжатия и время передачи сжатых изображений показывает актуальность развития метода сжатия данных.

В ходе исследований предложено разработать методы обработки телеметрических данных и создать единую систему обработки телеметрической информации для централизованного управления полетом космического аппарата.

АНДАТПА

Бұл магистрлік диссертацияда цифрлық бейнелерді қысу үшін тікелей шешім әдісі негізінде нейрондық желілердің даму перспективалары зерттелді. Ұсынылып отырған әдістеме үлкен суреттерді кіші терезелерге бөлу және артық ақпаратты жою кезеңдерін қамтиды және жерді қашықтықтан зондтау үшін кеңінен пайдаланылуы мүмкін. Бұл әдістемеді тікелей шешім әдісімен оқытылған нейрондық желі құралдарын пайдаланудың маңыздылығы байқалады.

Кері тарату алгоритмі қателерін, сондай-ақ пайдаланылатын нейронды оқыту және де екі алгоритмін оқыту салыстырылады. Қысу дәрежесі және қысылған кескіндерді беру уақыты сияқты есептік нәтижелер деректерді қысу әдісінің өзектілігін көрсетеді.

Зерттеу барысында телеметриялық деректерді өңдеу әдістерін әзірлеу және ғарыш аппаратының ұшуын орталықтандырылған басқару үшін телеметриялық ақпаратты өңдеудің бірыңғай жүйесін құру ұсынылды.

ABSTRACT

The master's thesis explored the prospects for the development of neural networks based on the direct solution method for digital image compression. The proposed technique includes the steps of splitting large images into smaller Windows and eliminating redundant information, and can be widely used for remote sensing of the Earth. The importance of using the tools of the neural network trained by the direct solution method in this method is noted.

The importance of using the tools of the neural network trained by the direct solution method in this method is noted. The reverse error propagation algorithm is also used for neural network training, and both training algorithms are compared. The calculated results, such as the compression rate and transmission time of compressed images, show the relevance of the development of the data compression method.

In the course of research, it is proposed to develop methods for processing telemetric data and create a unified system for processing telemetric information for centralized flight control of the spacecraft.

СОДЕРЖАНИЕ

Введение	9
1 Исследование методов сжатия телеметрической информации	10
1.1 Сжатия информации с потерями	10
1.2 Методы сжатия информации	11
1.3 Алгоритмы сжатия информации с потерями	20
1.4 Международные стандарты ISO 15887-2010	22
Выводы	
2 Анализ возможностей искусственных нейронных сетей	24
2.1 Перспективы использования нейронных сетей для сжатия данных	24
2.2 Метод прямого решения на основе нейронной сети	25
2.3 Архитектура нейронных сетей	25
2.4 Алгоритм сжатия и распаковки изображений	27
2.5 Анализ практического применения нейросжатия для телеметрических задач космического назначения	29
Выводы	
3 Программная реализация сжатия снимков искусственных нейронных сетей	33
3.1 Автоматизированные нейронные сети <i>STATISTICA (SANN)</i>	36
3.2 Математические модели	39
3.3 Модель Розентблата	41
3.4 Data Mining - Добыча данных	52
Выводы	
Заключение	63
Перечень сокращений	64
Список использованной литературы	65
Приложение А. Оттиски опубликованных статей	67

ВВЕДЕНИЕ

В данной диссертационной работе рассматривается исследование эффективных нейросетевых алгоритмов для сжатия телеметрических информации, обеспечивающих повышение эффективности процесса.

В силу особой практической и теоретической значимости, так же популярны универсальные методы кодирования источника с памятью были исследованы в соответствующих отдельных главах. Представлены не только ключевые версии алгоритмов, но и большое количество специфических техник развития сжатия, а именно малоизвестных. Информации этих глав могут приносить пользу не только для начинающего читателя, но и для специалиста.

«Методы сжатия без потерь» представлены главные подходы, использующиеся при кодировании источников без памяти, источников вида «аналоговый сигнал» и источников с памятью, так же методы предобработки характерных данных, представляющие улучшение сжатия для распространенных алгоритмов.

Научная новизна основана на использовании обучаемого метода нейросетей для существенного уменьшения объема и анализа потоков информации, передаваемой по спутниковому каналу. Более 90% ее количества передаваемых космических данных составляют данные геофизических исследований, и уменьшение объема этих данных используя нейросети, позволит существенно сократить расходы на передачу.

Актуальностью данной магистерской диссертации является рассмотрение возможности использования искусственных нейронных сетей для сжатия телеметрической информации.

Целью магистерской диссертации является исследование эффективных нейросетевых алгоритмов для сжатия телеметрических информации, обеспечивающих повышение эффективности процесса.

Для достижения поставленных целей необходимо было решить следующие задачи:

- Исследование методов сжатия телеметрической информации;
- Анализ возможностей искусственных нейронных сетей;
- Программная реализация сжатия снимков ИНС;
- Провести экспериментальные исследования разработанных алгоритмов на реальной информации.

Практическая значимость заключается в изыскании оптимального метода сжатия телеметрической информации с коэффициентом сжатия не менее 3-х.

1 Исследование методов сжатия телеметрической информации

1.1 Сжатие информации с потерями

Когда речь идет о сжатии, проводится различие между терминами «сжатие без потерь» и «сжатие с потерями». При работе с такой информацией, как «номер телефона», сжатие такой записи, очевидно, не приносит никакой пользы, поскольку некоторые символы теряются. Однако можно представить ряд ситуаций, когда потеря некоторой информации не приводит к потере полезности остальной информации. Сжатие с потерями в основном используется для графики (JPEG), аудио (MP3), видео (MPEG), то есть из-за большого размера файла коэффициент сжатия очень важен, а детали, которые не имеют отношения к этому восприятию можно пожертвовать. Существуют специальные опции для сжатия информации в видео формате. В некоторых случаях большая часть изображения неизменно изменяется от изображения к изображению, что может создавать алгоритмы сжатия, которые выборочно отслеживают только часть «изображения».

Во многих случаях сжатие графики с потерями, которое приводит к очень высоким коэффициентам сжатия, почти незаметно для человека. Из трех следующих изображений первое отображается в формате TIFF (без потерь), второе - в формате JPEG с наименьшим сжатием, а третье - с максимальным сжатием. Вы заметите, что последняя картинка почти на два порядка меньше первой. Однако методы сжатия с потерями имеют ряд недостатков.

Во-первых, сжатие с потерями не распространяется на весь графический анализ информации. Например, если сжатие изображения на лице изменяет форму родинки (но лицо остается полностью узнаваемым), эту фотографию можно будет отправить друзьям по почте, но если фотография легких отправляется на медицинское обследование для затемнения формы анализ, это совсем другое дело. Кроме того, в случае машинных методов анализа графической информации результаты кодирования с потерями (невидимые для глаз) могут быть "видимыми" для машинного анализатора.

Во-вторых, причина заключается в том, что повторное сжатие и декомпрессия с потерями вызывают накопление ошибок. Конечно, когда мы говорим о степени применимости формата JPEG, полезно, если важна большая степень сжатия при сохранении исходной глубины цвета. Именно это свойство привело к широкому использованию этого формата при отображении графической информации в Интернете, причем скорость отображения файла (его размер) имеет первостепенное значение. Негативной особенностью формата JPEG является ухудшение качества изображения, что делает практически невозможным его использование в полиграфической промышленности, где этот параметр является критическим.

Теперь давайте перейдем к разговору о сжатии информации без потерь и рассмотрим, какие алгоритмы и программы позволяют выполнять эту операцию.

Сжатие без потерь. Сжатие без потерь или кодирование можно использовать для сжатия любой информации, поскольку она обеспечивает абсолютно точное восстановление данных после кодирования и декодирования. Сжатие без потерь основано на простом принципе преобразования данных из одной группы символов в другую, более компактной.

Наиболее известны два алгоритма сжатия без потерь: кодирование Хаффмана и LZW, которые являются основными подходами к сжатию информации. Кодирование Хаффмана появилось в начале 1950-х годов; его принцип заключается в уменьшении количества битов, используемых для представления общих символов, и, следовательно, в увеличении количества битов, используемых для редких символов. Метод LZW кодирует строки символов, анализируя входной поток, чтобы создать расширенный алфавит на основе строк, которые он обрабатывает. Оба подхода уменьшают избыточную входную информацию

1.2 Методы сжатия информации

Для сжатия телеметрической информации, как правило, применяют алгоритмы, обеспечивающие точное восстановление исходных данных в целях их обработки и анализа информации, содержащейся в них. Точное восстановление данных в том виде, в каком они были получены от объекта телеизмерений системой регистрации, необходимо для анализа нештатных ситуаций, восстановления сбойных участков в потоке телеметрической информации и других видов постобработки или обработки данных в режиме реального времени. Эффективность методов обратимого сжатия во многом определяется свойствами кодируемой информации. Алгоритмы, хорошо сжимающие текст, могут давать неудовлетворительные результаты при сжатии датчиковой информации. Алгоритмы, уступающие в эффективности при обработке входных стационарных данных, могут существенно улучшить показатели сжатия, если статистические характеристики входных данных быстро изменяются в процессе проведения эксперимента.

В данном разделе представлены результаты исследований, проведенных для разработки эффективного метода обратимого сжатия потока данных телеметрии в формате IRIG-106. Это открытый стандарт группы телеметрии RCC, разработанный для использования в аэрокосмической промышленности и широко используемый в системах записи телеметрии для различных целей. Информация в потоке передается в кадрах с фиксированной длиной и предварительно определенной внутренней структурой без изменений.

В кадре могут передаваться показания нескольких источников информации: оцифрованные показания аналоговых датчиков; показания

цифровых приборов. Каждый источник передается в отдельном канале коммутатора системы регистрации телеметрической информации, текущее значение канала — в телеметрическом слове кадра, расположенном по заданному смещению от начала кадра. Все телеметрические слова кадра имеют одинаковую разрядность. Кадр содержит дополнительную служебную информацию, необходимую для обнаружения битовых ошибок, кадровой синхронизации временной привязки и др.




Рисунок 1.1 – Примеры исследуемых сигналов для температуры смещения (1), температуры входа (2) и выхода (3), угла (4), температуры выхода (5) и входа (6), датчика давления полупроводников (7), датчика давления (8) и датчика перемещения (9)

Подготовка данных для проведения экспериментов. В кадр телеметрической информации были включены оцифрованные отсчеты аналоговых датчиков, измеряющих типичные для телеметрической системы параметры (температуру, давление, данные позиционирования), которые получены в лабораторных условиях. В качестве объектов телеизмерений использованы системы автоматического регулирования. Примеры исследуемых сигналов приведены на рис. 1.1. Для проведения экспериментов были разработаны схемы коммутации, на их основе сформированы потоки телеметрической информации.

Описание экспериментов. Процедуру обратимого сжатия телеметрической информации (рис. 1.2) предложено разделить на два основных этапа: 1) моделирование; 2) энтропийное кодирование. На первом этапе достигается снижение корреляционных зависимостей в обрабатываемых данных — декорреляция. В основе различных методов декорреляции лежит способ предсказания значений входного сигнала X . Эффективность работы алгоритмов декорреляции можно оценить по двум показателям:




Рисунок 1.2 – Схема процедуры обратимого сжатия телеметрической информации

- 1) по отношению дисперсии исходных данных к дисперсии сигнала ошибки предсказания $(E) \sigma_x^2 / \sigma_e^2$ (коэффициент усиления дисперсии);
- 2) по энтропии сигнала ошибки предсказания.

По результатам экспериментов вычислялись оценки этих значений. На практике для оценки эффективности алгоритма удобнее использовать энтропию, так как этот показатель не зависит от формы исходного сигнала. В проведенных исследованиях сравнивались следующие основные подходы к декорреляции данных: различные варианты линейного предсказания и применение операции “исключающее или” для телеметрических слов соседних кадров в потоке. Схема декорреляции на основе линейного предсказания подробно описана, например, в работах. Значение дискретного, квантованного по уровню сигнала отсчета x_i предсказывается по известным значениям предыдущих отсчетов x_{i-1}, x_{i-2}, \dots этого сигнала. На каждом шаге ошибка предсказания рассчитывается по формуле.

$$e_i = x_i - Q \left\{ \sum_{j=1}^p \hat{a}_j x_{i-j} \right\} \quad (1.1)$$

Где \hat{a}_j — коэффициенты фильтра предсказателя. Предсказатель реализуется с помощью цифрового фильтра с конечной импульсной характеристикой и передаточной функцией $\hat{A}(z)$. Значения коэффициентов фильтра предсказателя \hat{a}_j требуются для восстановления последовательности x_i по известным значениям ошибки e_i . Коэффициенты фильтра вычисляют из условия минимизации суммы квадратов ошибок предсказания.

Согласно предложенной схеме сжатия, сигнал ошибки, т.е. разность предсказанного и реального значений на входе декоррелятора, поступает на вход энтропийного кодера. В экспериментах были использованы несколько методов энтропийного кодирования: метод Хаффмана; арифметическое кодирование; метод Райса; алгоритм Deflate, основанный на кодах Хаффмана. В качестве критерия оценки алгоритма сжатия применяли коэффициент сжатия — отношение размера исходных данных к размеру данных на выходе системы сжатия.

Два варианта различных структур кадра телеметрической информации, которые использовались в экспериментах, показаны на рис. 1.3. Первый вариант структуры кадра состоит из девяти каналов, подключенных к источникам датчиковой информации. Дополнительно кадр содержит служебную информацию, обеспечивающую кадровую синхронизацию в потоке телеметрической информации. Такая структура кадра может быть получена при одноступенчатой схеме коммутации каналов с единственным (основным) коммутатором.

SYNC F	Данные 1	Данные 2	Данные 3	Данные 4	Данные 5	Данные 6	Данные 7	Данные 8	Данные 9
SYNC16	Тсм	Твх	Твых	угол	Тв_вых	Тв_вх	Дат давл полу	Дат давл	Дат перемещ

а

SYNC F	SYNC SF1	Данные 1	Данные 2	Данные 3	Данные 4	Данные 5	Данные 6
SYNC16	C1	Тсм	Твх	Тв_вых	Тв_вых	угол	Дат давл полу
SYNC16	C2	Тсм	Твх	Тв_вых	Тв_вх	угол	Дат давл полу
SYNC16	C3	Тсм	Твх	Тв_вых	Дат давл	угол	Дат давл полу
SYNC16	C4	Тсм	Твх	Тв_вых	Дат перемещ	угол	Дат давл полу

б

Рисунок 1.3 – Структуры кадра телеметрической информации при одно- (а) и двухступенчатой (б) схемах коммутации

Второй вариант кадра имеет более сложную структуру, полученную с помощью двухступенчатой схемы коммутации. На рис. 1.3, б представлены четыре последовательно передаваемых кадра IRIG-106. В четвертом канале основного коммутатора передаются значения каналов коммутатора второй ступени. Таким образом, полный цикл опроса всех параметров занимает четыре кадра основного коммутатора. За этот цикл каналы основного коммутатора опрашиваются четыре раза.

Разрядность телеметрических слов кадра составляет 8 бит, в которых сохраняется один квантованный отсчет сигнала датчика, приведенный к шкале 0–255.

Пример гистограммы распределения значений телеметрических слов в исследуемых потоках телеметрической информации приведен на рис. 1.4.




Рисунок 1.4 – Гистограмма распределения значений телеметрических слов в исследуемых потоках телеметрической информации

Согласно этой гистограмме, значения распределены по всей шкале. Гистограмма имеет несколько выраженных пиков, типичных для телеметрической информации, в которой контролируемые параметры долгое время сохраняют значения, близкие к постоянным, и немного отклоняются от них под воздействием шумов. Результаты исследований алгоритма декорреляции на основе регрессионной модели в комбинации с несколькими методами энтропийного кодирования для двух схем коммутации в виде зависимостей коэффициента сжатия от порядка фильтра предсказателя показаны на рис. 1.5. В соответствии с полученными данными коэффициент сжатия резко возрастает, когда порядок фильтра становится равным числу слов в циклически повторяющейся структуре потока информации.




Рисунок 1.5 – Результаты исследований алгоритма декорреляции на основе регрессионной модели в комбинации с методами Хаффмана (1), арифметического кодирования (2) и Райса (3) при одно- (а) и двухступенчатой (б) схемах коммутации в виде зависимостей коэффициента сжатия от порядка фильтра предсказателя

В первом случае (рис. 1.5, а) эта длина равна длине кадра основного коммутатора, а во втором (рис. 1.5, б) — числу слов, содержащихся в четырех кадрах основного коммутатора. Пример гистограммы распределения значений ошибок предсказания, полученных в экспериментах с одноступенчатой схемой коммутации каналов, приведен на рис. 1.6.

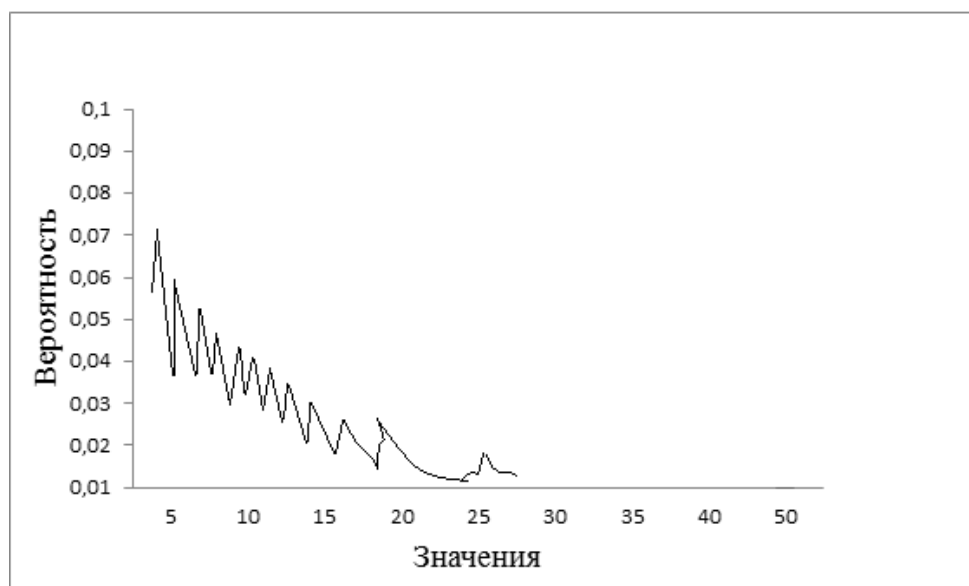


Рисунок 1.6 – Гистограмма распределения значений ошибок предсказания фильтра девятого порядка, полученных в экспериментах с одноступенчатой схемой коммутации каналов

Гистограмма имеет выраженный пик в области нуля, позволяющий качественно оценить эффективность работы фильтра предсказателя. Для оценки эффективности промежуточного этапа сжатия (декорреляции) использовались два параметра: коэффициент усиления дисперсии и энтропия ошибки на выходе фильтра предсказателя. Численные результаты этого эксперимента при дисперсии исходного сигнала $\sigma_x^2 = 6085,77$ и энтропии 7,45 в зависимости от порядка фильтра приведены ниже:

	1	2	8	9	18
σ_e^2	5565	5599	4394	78	82
σ_x^2/σ_e^2	1,10	1,10	1,38	77,70	73,83
Энтропия сигнала ошибки	7,78	7,86	7,71	3,06	3,79

Результаты исследования нескольких комбинаций декоррелятора на основе метода линейного предсказания и методов энтропийного кодирования приведены ниже (фильтр девятого порядка для потока слов телеметрической информации):

	Метод Хаффмана	Арифметическое кодирование	Метод Райса	Метод Zlib
Коэффициент сжатия	2,64	2,59	2,13	1,56

Приведен коэффициент сжатия, полученный методом Zlib, который построен на основе алгоритма Deflate и адаптивного варианта метода

Хаффмана. Метод Zlib представлен как образец хорошо оптимизированного и широко применяемого метода сжатия информации общего назначения, в котором, однако, не используются априорные сведения о структуре кодируемых данных. Метод Хаффмана и арифметическое кодирование демонстрируют схожие результаты, немного лучшие, чем метод Райса. Однако следует учесть, что метод Райса эффективен в условиях, когда статистические характеристики изменяются очень быстро, за несколько кадров в потоке телеметрической информации. Метод Zlib очевидно проигрывает, оставляя область для исследований, направленных на разработку эффективных алгоритмов сжатия телеметрической информации, учитывающих особенности представления этого вида информации.

В рассмотренном методе декорреляции на основе линейного предсказания на вход декоррелятора передавались телеметрические слова в порядке их следования в потоке телеметрической информации. Можно предположить, что между отсчетами одного и того же параметра в соседних кадрах существуют сильные корреляционные зависимости, а между соседними словами в потоке телеметрической информации такие зависимости отсутствуют. Повышение порядка фильтра для выявления указанных зависимостей приводит к увеличению сложности вычислений. Это хорошо работает для одноступенчатой схемы коммутации, но в более сложной структуре с двухступенчатой схемой коммутации такой прямолинейный подход неэффективен. Декоммутация каналов кадра и применение методов линейного предсказания к каждому каналу не упрощает вычисления, при этом согласно результатам экспериментов позволяет улучшить характеристики декоррелятора. Следует отметить, что использование фильтров первого порядка для предсказания значений каждого канала достаточно эффективно. Дальнейшее увеличение порядка фильтра предсказателя снижает оценку энтропии несущественно. Поэтому в качестве альтернативы методу декорреляции, основанному на линейном предсказании, можно предложить более простой метод снижения корреляционных зависимостей соседних кадров в потоке телеметрической информации. Для пары телеметрических слов, расположенных на одинаковых позициях в соседних кадрах, выполняется побитовая операция “исключающее или”. Результат операции передается на вход энтропийного кодера. Экспериментально полученная гистограмма распределения значений ошибки на выходе построенного по этому принципу декоррелятора представлена на рис. 1.7.

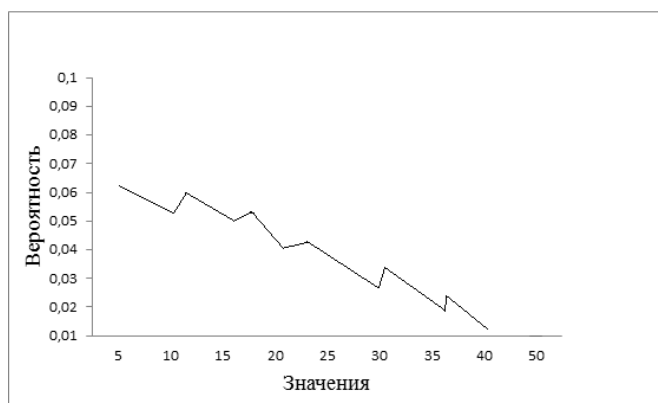


Рисунок 1.7 – Экспериментально полученная гистограмма распределения значений ошибки на выходе метода декорреляции с помощью операции “исключающее или”

Основные экспериментально полученные результаты, позволяющие провести сравнительную оценку эффективности трех различных методов декорреляции, приведены в табл. 1.1. Два метода, с которыми осуществлялось сравнение, основаны на модели линейного предсказания. В первом методе применялись фильтры предсказателя девятого порядка для одноступенчатой схемы коммутации и 24 порядка для двухступенчатой схемы коммутации. На вход фильтра подавались слова в порядке их следования в потоке телеметрической информации. Во втором методе предварительно выполнялась операция извлечения (декоммутации) каналов из кадров IRIG-106, а затем — процедура декорреляции каждого канала. В эксперименте для всех каналов использовались фильтры первого порядка.

Таблица 1.1 – Сравнение эффективности методов декорреляции для одно- (числитель) и двухступенчатой (знаменатель) схем коммутации

Параметры	Фильтр 9/24 порядка для поток слов телеметрической информации	Фильтр первого порядка для каждого канала	Операция «исключающее или»
Энтропия исходного сигнала	7,45/7,26		
	77,70/28,31	40,84/40,84	9,54/7,47
Энтропия сигнала ошибок	3,06/4,57	3,34/3,34	2,90/3,41

Результаты работы перечисленных методов обратимого сжатия телеметрической информации, представляющих собой различные комбинации методов декорреляции и энтропийного кодирования, приведены в табл. 1.2.

Таблица 1.2 – Эффективность методов сжатия телеметрической информации для одно- (числитель) и двухступенчатой (знаменатель) схем коммутации

Значения коэффициента сжатия					
Метод Хаффмана	Арифметическое кодирование	Метод Райса	Алгоритм Deflate	Метод Zlib	Сжатие с использованием Нейронных сетей
<i>Фильтр 9/24 порядка для потока слов телеметрической информации</i>				1,56/1,27	1,5/3
2,64/1,72	2,59/1,73	2,13/1,65	2,39/1,63		
<i>Фильтры первого порядка для каждого канала</i>					
2,45/2,45	2,40/2,40	1,96/1,96	2,46/2,14		
<i>Операция «исключающее или»</i>					
2,77/2,43	2,72/2,32	1,67/1,58	2,30/2,03		

1.3 Алгоритмы сжатия с потерями

Первыми для архивации изображений стали применяться привычные алгоритмы. Те, что использовались и используются в системах резервного копирования, при создании дистрибутивов и т.п. Эти алгоритмы архивировали информацию без изменений. Однако основной тенденцией в последнее время стало использование новых классов изображений. Старые алгоритмы перестали удовлетворять требованиям, предъявляемым к архивации. Многие изображения практически не сжимались, хотя “на взгляд” обладали явной избыточностью. Это привело к созданию нового типа алгоритмов — сжимающих с потерей информации. Как правило, коэффициент архивации и, следовательно, степень потерь качества в них можно задавать. При этом достигается компромисс между размером и качеством изображений.

Одна из серьезных проблем машинной графики заключается в том, что до сих пор не найден адекватный критерий оценки потерь качества изображения. А теряется оно постоянно — при оцифровке, при переводе в ограниченную палитру цветов, при переводе в другую систему цветопредставления для печати, и, что для нас особенно важно, при архивации с потерями. Можно привести пример простого критерия: среднеквадратичное отклонение значений пикселей (L_2 мера, или root mean square — RMS):

$$d(x,y) = \sqrt{\frac{\sum_{i=1,j=1}^{n,n} (x_{ij} - y_{ij})^2}{n^2}} \quad (1.2)$$

По нему изображение будет сильно испорчено при понижении яркости всего на 5% (глаз этого не заметит — у разных мониторов настройка яркости варьируется гораздо сильнее). В то же время изображения со “снегом” — резким изменением цвета отдельных точек, слабыми полосами или “муаром” будут признаны “почти не изменившимися”. Свои неприятные стороны есть и у других критериев.

Рассмотрим, например, максимальное отклонение:

$$d(x,y) = \max_{i,j} |x_{ij} - y_{ij}| \quad (1.3)$$

Эта мера, как можно догадаться, крайне чувствительна к биению отдельных пикселей. Т.е. во всем изображении может существенно измениться только значение одного пикселя (что практически незаметно для глаза), однако согласно этой мере изображение будет сильно испорчено.

Мера, которую сейчас используют на практике, называется мерой отношения сигнала к шуму (peak-to-peak signal-to-noise ratio — PSNR).

$$d(x,y) = 10 \cdot \log_{10} \frac{255^2 \cdot n^2}{\sum_{i=1,j=1}^{n,n} (x_{ij} - y_{ij})^2} \quad (1.4)$$

Данная мера, по сути, аналогична среднеквадратичному отклонению, однако пользоваться ей несколько удобнее за счет логарифмического масштаба шкалы. Ей присущи те же недостатки, что и среднеквадратичному отклонению.

Лучше всего потери качества изображений оценивают наши глаза. Отличной считается архивация, при которой невозможно на глаз различить первоначальное и разархивированное изображения. Хорошей — когда сказать, какое из изображений подверглось архивации, можно только сравнивая две находящиеся рядом картинки. При дальнейшем увеличении степени сжатия, как правило, становятся заметны побочные эффекты, характерные для данного

алгоритма. На практике, даже при отличном сохранении качества, в изображениях могут быть внесены регулярные специфические изменения. Поэтому алгоритмы архивации с потерями не рекомендуется использовать при сжатии изображений, которые в дальнейшем собираются либо печатать с высоким качеством, либо обрабатывать программами распознавания образов. Неприятные эффекты с такими изображениями, как мы уже говорили, могут возникнуть даже при простом масштабировании изображения.

1.4 Международные стандарты ISO 15887-2010

Как известно, для унификации и установлении единых международных требований ИСО (www.iso.org) вырабатывает международные стандарты. В частности, для регулирования сжатия телеметрических данных выпущен международный стандарт ИСО 15887-2010. Настоящий стандарт устанавливает требования для сжатия информации без потерь и к информационным системам передачи данных. Стандарт устанавливает общую структуру и обеспечивает общую основу для алгоритма сжатия данных без потерь, применяемого к нескольким различным типам данных.

Цель настоящего стандарта заключается в установлении требования по алгоритму сжатия данных для кодирования источника, применяемого к цифровым данным и для установления метода вставки сжатых данных в пакеты источника для поиска данных и декодирования.

Кодирование источника для сжатия данных это метод, применяемый в системах данных для сокращения объема цифровых данных для улучшения в следующих областях:

- а) сокращение ширины полосы канала передачи;
- б) сокращение требований к буферизации и хранению;
- в) сокращение времени передачи данных при установленной скорости.

Настоящий стандарт применяется в космических системах, использующих скоростной пакетированный телеметрический обмен данными. Дополнительно он служит в качестве рекомендаций для разработки согласованных с CCSDS стандартов в космической деятельности основанных на инженерной практике.

Выводы. Анализ результатов проведенных экспериментов позволяет сделать следующие выводы.

1. Использование априорных сведений о структуре потока телеметрической информации позволяет повысить эффективность обратимого сжатия этих данных. Если применяется схема коммутации каналов с фиксированной структурой кадров, то для декорреляции можно использовать линейный фильтр, порядок которого равен длине цикла опроса каналов схемы коммутации.

2. Если телеметрический кадр имеет более сложную структуру, построенную, например, на основе двухступенчатой схемы коммутации, то

декорреляция каналов по отдельности существенно увеличивает коэффициент сжатия. При этом в обработке появляется дополнительная операция декоммутации каналов.

3. Покадровая декорреляция данных в потоке телеметрической информации с помощью операции “исключающее или” упрощает вычисления и для двух рассмотренных схем коммутации каналов демонстрирует лучший результат. Этот метод предпочтителен в случае, когда схема коммутации каналов в потоке известна.

4. Метод Хаффмана в проведенных экспериментах позволил определить лучшие значения коэффициента сжатия.

5. Разделение входных данных на блоки позволяет отчасти компенсировать изменение во времени статистических характеристик исследуемого потока телеметрической информации. Изменение размеров блоков увеличивает коэффициент сжатия. Основные результаты работы. Предложена общая схема обратимого сжатия телеметрической информации, состоящая из декорреляции и энтропийного кодирования. На основе анализа структуры и статистических характеристик потока данных телеметрической информации разработаны альтернативные подходы к решению задачи обратимого сжатия телеметрической информации. Для проведения экспериментов в среде MATLAB реализованы необходимые процедуры. В экспериментах с реальными данными получены численные результаты, позволяющие сделать выводы об эффективности предложенных методов и разработать рекомендации для создания системы обратимого сжатия телеметрической информации. Дальнейшее направление исследований. Характеристики регистрируемых параметров и даже структура потока телеметрической информации может быстро изменяться в процессе работы. В связи с этим представляет интерес исследование адаптивных методов декорреляции и энтропийного кодирования телеметрической информации, в частности, возможности динамической подстройки параметров декоррелятора и выбора модели, описывающей статистические параметры сигнала ошибки на входе энтропийного кодера.

2 Анализ возможностей искусственных нейронных сетей

2.1 Перспективы использования нейронных сетей для сжатия данных

В этом разделе мы рассматриваем перспективы развития нейронных сетей на основе метода прямого решения (МПР) для сжатия цифровых изображений. Предлагаемая методика включает в себя этапы разбивки больших изображений на меньшие окна и устранения избыточной информации и может широко использоваться для дистанционного зондирования Земли. Отмечается важность использования в этой методике инструментов нейронной сети обученная методом прямого решения. Алгоритм обратного распространения ошибок также используется для обучения нейронной сети, и сравниваются оба алгоритма обучения. Расчетные результаты, такие как степень сжатия и время передачи сжатых изображений показывает актуальность развития метода сжатия данных.

Задача сжатия (компрессии) данных состоит в уменьшении количества хранимой или передаваемой информации с возможностью ее полного восстановления (декомпрессии) в дальнейшем. Существует множество методов сжатия информации. Применение нейронной сети позволяет получить новые возможности для сжатия с потерей (с допустимой утратой определенной части информации при хороших обобщающих способностях и при относительно высоком коэффициенте компрессии). Сжатие изображения позволяет уменьшить количество битов при передаче. Это, в свою очередь, помогает увеличить объем данных, передаваемых в течение некоторого времени, наряду с сокращением необходимых затрат. Традиционные методы, которые уже были определены для сжатия данных, включают: прогнозирующее кодирование, кодирование с преобразованием и векторное квантование.

Вкратце, кодирование с предсказанием относится к декорреляции аналогичных соседних пикселей в изображении для удаления избыточности. После удаления избыточных данных может передаваться более сжатое изображение или сигнал. Результаты, достигнутые с помощью метода, основанного на преобразовании, сильно зависят от выбора используемого преобразования (косинус, вейвлет, Karhunen-Loeve и т. д.). Наконец, методы векторного квантования требуют разработки соответствующей кодовой книги для сжатия данных, что затрудняет оперативность процесса.

Цель этого раздела - представить новый метод сжатия изображений с использованием нейронной сети на основе МПР. Метод обучения с использованием искусственных нейронных сетей (ИНС) не является итеративным и работает быстрее, чем некоторые из более популярных алгоритмов, таких как обратное распространение ошибок. Результаты представлены для ИНС, обученных с использованием алгоритма по методу прямого решения и алгоритма обратного распространения ошибок (ОРО).

2.2 Метод прямого решения на основе нейронной сети

В этом разделе мы представляем краткое описание МПР для обучения нейронной сети. Этот метод использует многослойный перцептрон с одним скрытым слоем. Математическая модель восприятия информации мозгом (перцептрон) вычисляет линейную комбинацию и суперпозицию (в случае многослойных перцептронов) нелинейных функций одного переменного, называемый активационной функцией нейрона. Хотя теоретически эта функция может быть произвольной гладкой нелинейной функцией (6), на практике от выбора активационной функции зависит скорость обучения, сходимость, достигнутая погрешность. Основная цель метода - сначала преобразовать нелинейные выходы в линейные и установить линейную систему уравнений для выходного слоя (рис. 2.1). Модифицированный метод Грама-Шмидта используется для решения линейной системы уравнений.

2.3 Архитектура нейронной сети


Пусть n - количество нейронов во входном слое, m - количество нейронов в выходном слое, N_l - количество нейронов, принадлежащих l -му слою, и $o_k^{(l)}$ - выход k -го нейрона l -го слоя, тогда вычисление, выполняемое каждым нейроном, может быть выражено как:

$$\mathbf{net}_k^{(l)} = \sum_{j=1}^{N_{l-1}} \mathbf{w}_{kj}^{(l)} \mathbf{O}_j^{(l-1)} \quad (2.1)$$

$$\mathbf{o}_k^{(l)} = f(\mathbf{net}_k^{(l)}) \quad (2.2)$$

где $\mathbf{net}_k^{(l)}$ - взвешенная сумма k нейронов l -го слоя, $\mathbf{w}_{kj}^{(l)}$ - вес, на который тот же нейрон умножает выходной сигнал $\mathbf{O}_j^{(l-1)}$ j -го нейрона предыдущего слоя и $f(\cdot)$ является нелинейной ограниченной функцией, часто сигмоидальной функцией.

$$f(\mathbf{net}_k) = 1 / (1 + \exp(-\mathbf{net}_k))$$



$$\mathbf{net}_{ij} = \ln((\mathbf{d}_{ij}) / (1 - \mathbf{d}_{ij})) \quad (2.3)$$

где

\mathbf{net}_{ij} = значение net для i -го нейрона и j -й пары в выходном слое.

\mathbf{d}_{ij} = желаемое значение \mathbf{d}_{ij} i -го нейрона и j -й пары в выходном слое.

Используя (2), уравнение (3) становится

$$\mathbf{w}_{1i} * \mathbf{x}_{1j}^1 + \mathbf{w}_{2i} * \mathbf{x}_{2j}^1 + \dots + \mathbf{w}_{hi} * \mathbf{x}_{hj}^1 = \mathbf{net}_{ij}^1 \quad (2.4)$$

где: \mathbf{w}_{hi} = значение веса от нейрона \mathbf{h} в скрытом слое до нейрона \mathbf{i} в выходном слое.

\mathbf{x}_{hj}^1 = значение выхода для нейрона \mathbf{h} пары \mathbf{j} в скрытом слое 1.

Используя приведенное выше уравнение (2.4), для каждого нейрона в выходном слое мы можем написать линейную систему

$$\mathbf{X}_w = \mathbf{net} \quad (2.5)$$

где: \mathbf{net} - это \mathbf{p}_{x1} , \mathbf{w} - это \mathbf{h}_{x1} , $\mathbf{p} > \mathbf{h}$, а \mathbf{X} - это $\mathbf{p} \times \mathbf{h}$ с рангом \mathbf{h} .

Весовой вектор (\mathbf{W}) рассчитывается по методу модифицированного Грама-Шмидта.

Машинное обучение весов скрытого слоя. Изображение «сжато» в скрытых единицах ИНС (рис.2.1). Веса скрытого слоя фактически установлены случайными значениями. Используемыми весовые вектора являются любые небольшие реальные значения, кроме нуля. Причина назначения малых весов состоит в том, чтобы добиться лучшего обобщения. Веса не могут быть равны нулю, поскольку это приведет к созданию идентичных входных векторов для выходного слоя и, следовательно, уменьшит шансы нахождения весов выходного слоя.

Машинное обучение весов выходного слоя. Веса выходного слоя играют важную роль в ИНС, поскольку они напрямую связаны с выходным слоем. Веса (неизвестные) определяются путем решения системы линейных уравнений, которая затем может быть использована для «декомпрессии» изображения. Уравнения решаются с использованием метода Модифицированного Грама-Шмидта. Этот метод стабилен и требует меньше вычислительной мощности, чем другие существующие алгоритмы (2.5).

Краткое описание методики приведено ниже:

Этап 1: Рассмотрим многослойный персептрон (МСП) с одним скрытым слоем.

Этап 2: Инициализируйте веса скрытого слоя маленькими случайными значениями.

Этап 3: Представьте входные векторы (8x8 окон) и желаемые выходные векторы (8x8 окон).

Этап 4: Разработайте линейную систему уравнений для выходного слоя.

- Преобразуйте выходную нелинейную функцию активации в линейный выход, используя уравнение (2.1).

- Используя уравнение (2.2), разработайте систему уравнений, как показано в уравнении (2.5).

Этап 5: Рассчитайте веса выходного слоя, используя метод Модифицированного Грама-Шмидта (2.5).

Этап 6: Повторите этапы с 4 по 6 для каждого нейрона в скрытом слое.

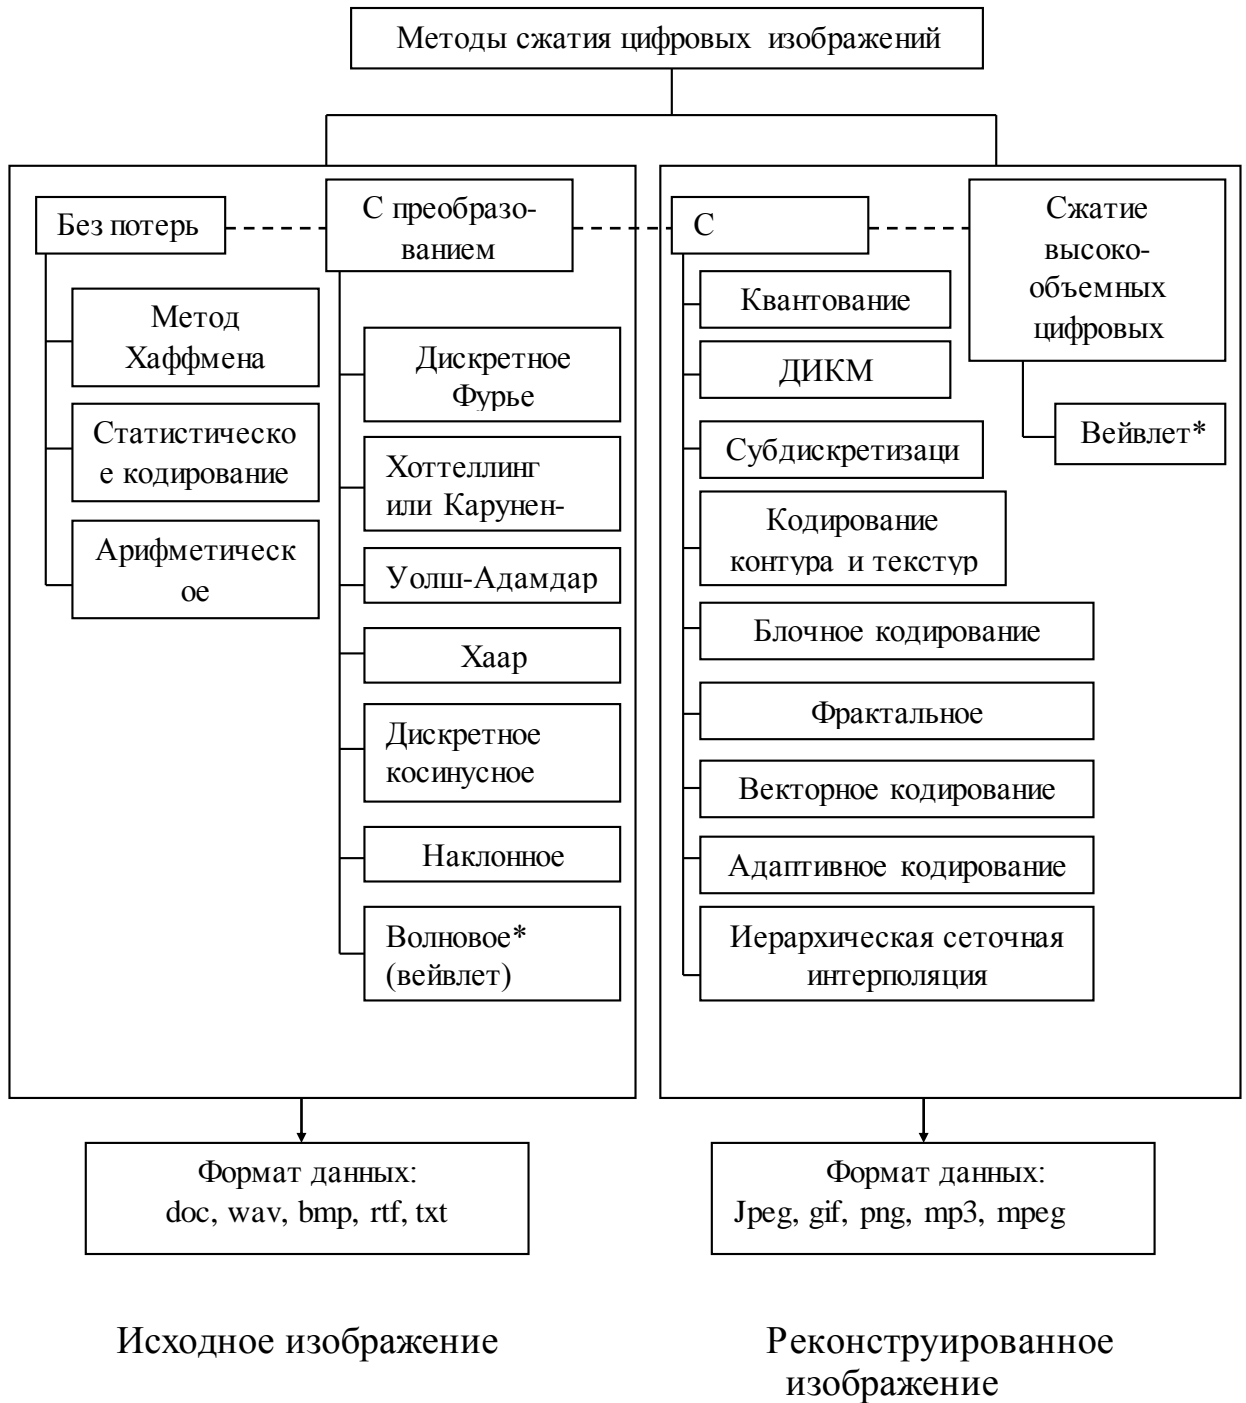


Рисунок 2.1 – Сжатие и декомпрессия изображения в ИНС

2.4 Алгоритм сжатия и распаковки изображений

Для успешного сжатия изображения с использованием обычных или интеллектуальных методов необходимо предпринять следующие этапы:

1. Получение изображения;
2. Предварительная обработка;
3. Сегментация изображения;
4. Подготовка обучающих пар;
5. Исключение аналогичных обучающих пар;
6. Сжатие изображения с использованием ИНС. обучение ПРМ и ОРО, и
7. Реконструкция изображения.

Этап 1. Получение изображения

Изображения сканировали с использованием планшетного сканера и персонального компьютера с программным пакетом OFOTO. Изображения были сохранены в формате изображения с тегами (ФИТ). Затем их можно было легко перемещать по платформам ПК на IBM-совместимый компьютер под управлением Windows 95. Пакет Paint Shop Pro использовался для преобразования изображений ФИТ в изображения растрового типа (ИРТ). Затем изображения были преобразованы в двоичную форму, чтобы они могли существовать исключительно в черно-белом (монохромном) формате. Это достигается с помощью метода определения порогов «ближайшего цвета». Перевод цветного изображения в двухцветное черное – белое, бинаризация, осуществляется так, чтобы каждое изображение могло быть уменьшено в размере, следовательно ускоряя передачу для эксперимента. Бинаризация была также выполнена так, чтобы сокращение подобных обучающих пар могло быть легче выполнено в дальнейших этапах.

Этап 2. Предварительная обработка

После бинаризации каждое растровое изображение преобразуется в ASCII «1s» и «0s». Процесс следует выполнять так, чтобы сегментацию и другие методы предварительной обработки можно было выполнить проще. Этот этап был выполнен с использованием уже реализованной программы, написанной на ANSI C. Простая программа сегментации реализуется для сегментирования больших изображений в меньшие блоки, готовые для использования в сочетании с методом классификации.

Этап 3. Сегментация изображения

Затем изображение было сегментировано на более мелкие изображения или окна с помощью программы, реализованной в ANSI C. Сначала программа приняла размер окна, необходимый для сегментации, а затем нашла общий размер изображения. Сегментация была очень важна, чтобы ограничить количество входов в ИНС и учесть исключение избыточных обучающих пар на последующих этапах.

Этап 4. Подготовка тренировочных пар

После того, как более крупное изображение разбивается на более мелкие и более полезные окна, необходимо преобразовать их в форму, готовую для использования с ИНС. Затем готовится файл, в котором каждое окно было записано в виде двух одинаковых векторов для формирования обучающей пары. Другими словами, первый вектор будет входным вектором, а второй вектор будет желаемым выходом.

Этап 5. Исключение подобных тренировочных пар

Поскольку многие из протестированных изображений были чрезвычайно большими, после сегментации будет много похожих тренировочных пар. Чтобы устранить эту избыточную информацию, необходимо использовать программу для поиска в файле обучения похожих обучающих пар и удаления их. Это не только уменьшает количество избыточных обучающих пар, но и значительно сокращает время обучения ИНС.

Этап 6. Сжатие изображения с использованием ИНС, обученного МПР и ОРО

Нейросеть на основе МПР из раздела 1.4 вместе с алгоритмом ОРО (5) сравнивается для задачи сжатия изображений. Для каждого эксперимента необходимо использовать много разных изображений для обучения ИНС и для сжатия / декомпрессии. Выходные данные скрытого слоя вместе с весами выходного слоя передается на удаленный сайт для распаковки изображения. Данная система разрабатывается для работы с подобными изображениями, которые необходимо регулярно загружать/разгружать. Поэтому в данной методике не предусматривается сжатие или распаковку изображений, не используемых в обучении ИНС. Тем не менее, это может стать целью расширения нашей работы в будущем.

Этап 7. Реализация программы по реконструкции образа

В итоге, вывод, произведенный ИНС в виде распакованных векторов или окон, будет реконструирован для получения полного исходного изображения. ASCII «1» и «0» надо преобразовывать в их правильное графическое представление и необходимо сопоставлять с исходным изображением.

2.5 Анализ практического применения нейросжатия для телеметрических задач космического назначения

В настоящее время объем информационного контента канала передачи телеметрической информации (ТМИ) с бортов космических аппаратов (КА) растет динамически и неуклонно. Это обстоятельство связано не только с усложнением процессов управления и жизнеобеспечения на борту КА, но и ростом потребности космических услуг во всех отраслях экономик. Телеметрическая информация космического назначения – это совокупность технологий, позволяющая производить дистанционные измерения и сбор научных данных об объекте исследования (данные дистанционного

зондирования Земли - ДДЗЗ) и информации о состоянии бортовых подсистем КА для предоставления оператору или пользователю. Основными требованиями при выполнении телеметрических задач космической системы являются надежность и устойчивость к сбоям и нештатным ситуациям.

С целью повышения надежности и устойчивости процесса приема и передачи телеметрической информации разработана требования к ТМИ КА в специальном стандарте CCSDC, где основным методом решения этих проблем является многократное резервирование аппаратных и программного обеспечения. Но, в последнее время с развитием позволяют учесть не только случайные характер сигналов, но и особенности затухания принимаемых и передаваемых сигналов, особенности функционирования конкретных подсистем КА и дальнейшее сжатие для снижения объемов передаваемой информации. Основной задачей при этом будет являться создание обучаемой и адаптируемой структуры управления ТМИ на основе имитационного моделирования (Рис. 2.2).

При разработке имитационного моделирования учтены следующие основные требования: обеспечение базовых задач передачи и приема как ТМИ, так и ДДЗЗ; предварительная и интеллектуальная обработка получаемых данных на борту КА; сжатие информации; сохранение информации при различных условиях работы аппаратных средств.

Средства получения телеметрических данных КА и данных ДЗЗ



Рисунок 2.2 – Структура управления телеметрической информацией в соответствии с требованиями международного стандарта CCSDC

Практика использования подсистемы нейросетевой обработки ТМИ и ДДЗЗ показывает, что данная подсистема состоит из следующих функциональных блоков – нейросетевой блок интерполяции траектории движения КА, который осуществляет интерполяцию траектория движения КА и

позволяет получать векторы положения и скорости в промежутках движения КА, который позволяет осуществлять экстрополяцию траектории движения КА; блок управления положением и ориентацией КА, который предназначен для выработки управляющих воздействий на маховики КА с целью коррекции движения и положения КА; блок диагностирования подсистем КА, который предназначен для контроля работоспособности различных подсистем КА; блок управления приема и передачи данных дистанционного зондирования Земли, который предназначен для выполнения основного функционала полезной нагрузки. Вся получаемая БД информации со всех функциональных блоков в дальнейшем обрабатывается в нейросетевом блоке сжатия информации, который предназначен для сокращения и оптимизации объемов информации для передачи по каналам связи. Каждая из систем искусственного интеллекта состоит из трех компонент – оценки массива данных, распределения весовых коэффициентов по значимости (принятие решений) и прогнозирование поведения каждого блока.

Выводы. Алгоритмы сжатия ТМИ и ДЗЗ можно использовать как универсальные, так и специализированные. В работе рассматривается эффективность сжатия пяти алгоритмов – алгоритм, учитывающий корреляцию между нулевыми битами кадра данных; - алгоритм, учитывающий корреляции между единичными битами кадра данных;

- алгоритм на основе гамма – кода Элиаса;

- алгоритм на основе дельта – кода Элиаса;

- алгоритм Кадана, поиск уже в найденных однородных областей. Для достижения наибольшего возможного значения коэффициента сжатия каждого кадра телеметрической информации, оптимальный алгоритм сжатия может выбираться путем оценки эффективности сжатия всех используемых в подсистеме обработки ТМИ и ДЗЗ на базе ИНС.

3. Программная реализация сжатия снимков искусственных нейронных сетей

Soft Statistica Neural Networks открывает широкому кругу читателей современный анализ данных. *STATSOFT* (производитель StatSoft, USA) занимает лидирующее положение среди программ анализа данных и имеет сотни тысяч зарегистрированных пользователей в России и мире. На простых, ясных примерах популярно описаны современные методы анализа данных - визуальный анализ и графическое представление данных, описательные статистики, методы классификации и прогнозирования.

Классические методы дополнены самым современным инструментарием, включая нейронные сети и DataMining. Знакомится с методами и компьютерными технологиями анализа данных и учится применять их на практике.

Идея нейронных сетей (гр. *neuron* - нерв) родилась в результате попыток воспроизвести способность человеческого мозга обучаться и исправлять ошибки. Если классические методы анализа не работают или точность результатов не удовлетворяет исследователя, встает задача выбора нового инструмента. Таким инструментом могут служить нейронные сети. В последние годы интерес к нейронным сетям существенно возрос.

Если вы хотите продвинуться в исследовании задач классификации, прогнозирования или построения сложных *нелинейных* зависимостей, вам стоит испытать нейронные сети. Мы далеки от мысли создавать культ нейронных сетей - мы предлагаем рассматривать их как полезный инструмент анализа.

SOFT STATSOFT предоставляет нейронные сети в ваше распоряжение. Вначале попробуем применить нейронные сети к простым задачам с известным ответом, затем используем для решения практических задач. Модуль Нейронные Сети *STATSOFT* предлагает нам гибкий инструментарий для построений нейронных сетей.

В системе *STATSOFT* есть замечательное средство - *вероятностный калькулятор*, пользоваться которым так же просто, как обычным калькулятором. Многие элементарные вероятностные задачи могут быть решены с помощью этого средства. В этой программе есть возможность пользоваться вероятностным калькулятором, а также строить разнообразные статистические графики: гистограммы, диаграммы рассеяния, графики типа «ящики с усами», вычислять простейшие статистики: среднее, стандартное отклонение, корреляции, процентные точки и т. д. А также генерировать случайные последовательности в *STATSOFT*, например, последовательности, возникающие при бросании монет.

В *STATSOFT* имеются сотни типов графиков, предназначенных для визуализации, разведывательного анализа, графического представления результатов и выбора последующих направлений анализа. Такие уникальные графики, как лица Черного, диаграммы Вороного, матричные графики,

позволяющие, например, визуализировать корреляционную матрицу, категорированные, трассировочные и др. графики, а также большой выбор двумерных и трехмерных научных и деловых графиков и диаграмм становятся доступными для пользователя.

Кроме стандартных типов графиков в *STATSOFT* имеется большое количество специализированных статистических графиков: «ящиков с усами» с разнообразными опциями по выбору средней точки, граничных значений, подгонки распределений, определения выбросов, разнообразных гистограмм, графиков на нормальной вероятностной бумаге, графиков типа «вероятность-вероятность», «квантиль-квантиль» и т. д.

Примеры нескольких графиков приведены на рис. 3.1-3.3.

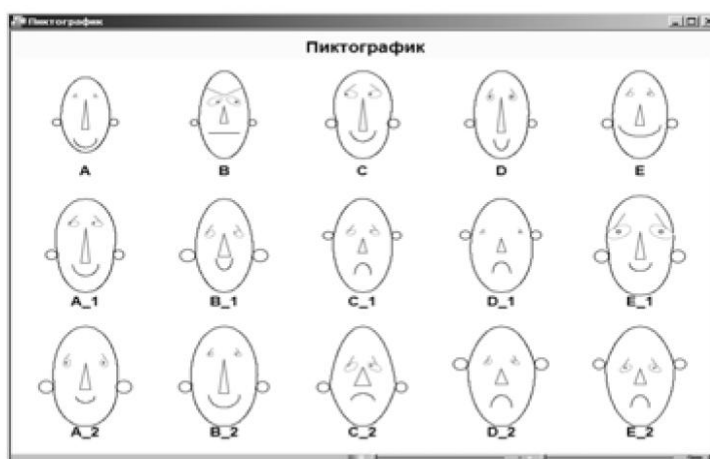


Рис. 3.1. Лица Чернова результаты допинг-контроля спортсменов

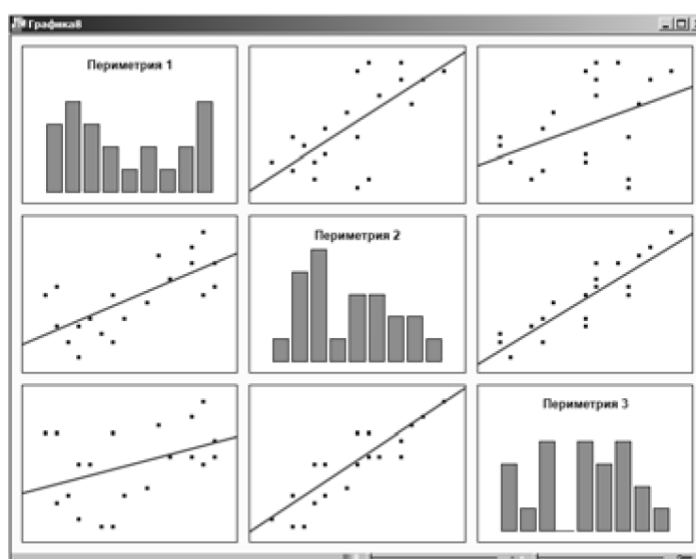


Рис. 3. 2. Визуализация корреляций

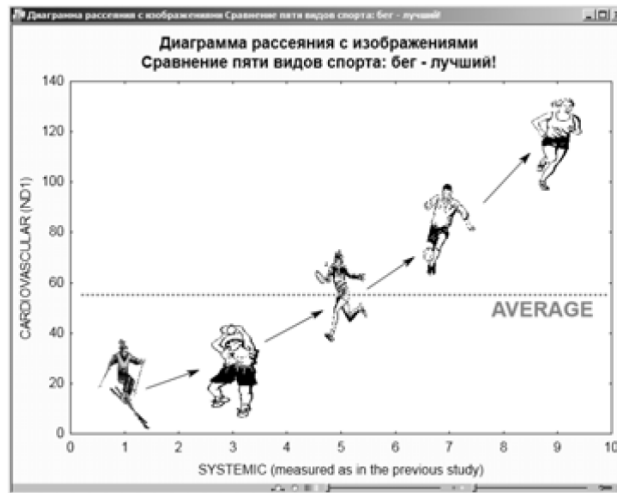


Рисунок 3.3 – Диаграмма рассеяния с образами - предпочтения в видах спорта

Графики можно уменьшать, увеличивать, накладывать друг на друга, вращать, корректировать перспективу, применять средство «Рентген» в трехмерной графике, чтобы увидеть «очертания дальних гор на фоне ближних», определять собственную палитру цветов, добавлять пользовательский текст, рисунки, стрелки и т. д.

В последних версиях системы многие настройки можно осуществлять непосредственно в окне графика, не открывая дополнительных окон. Например, вращение трехмерного графика осуществляется с помощью прокруток, расположенных в нижней части окна (рис. 3.4) - *технологично, просто, удобно*. Графики автоматически изменяются при изменении связанного с ними файла данных.

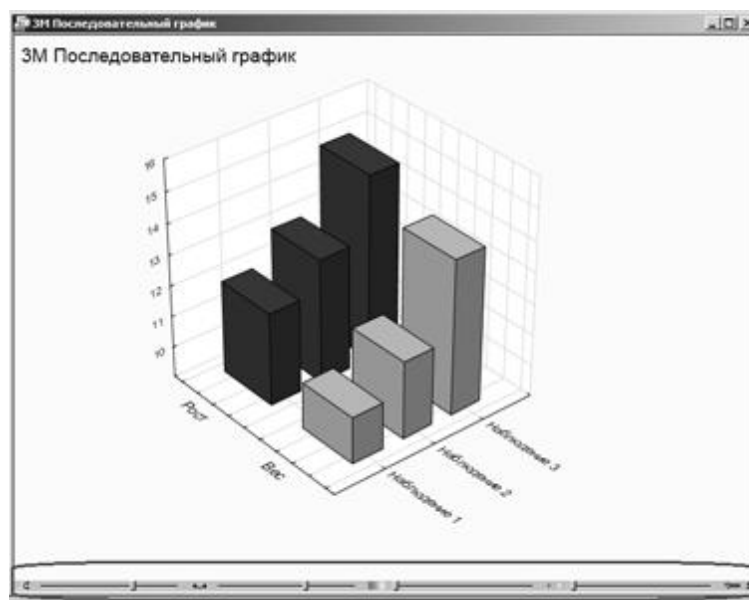


Рисунок 3. 4 – Продвинутое изображение настройки графика

Особенно важно средство Кисть для визуального анализа данных, описанию которого мы посвятим отдельный раздел книги.

Одной из интересных возможностей *STATSOFT* является визуальное отображение данных и наложение результатов анализа на географическую карту.

В качестве необычного примера рассмотрим визуальный анализ текста. Первые 200 страниц прозы В. Гете «Ученические годы Вильгельма Мейстера» представляют прекрасный, почти недостижимый образец музыкальной прозы. Графическое изображение этого ритма мы видим на линейном графике, где ритм Гете отображен вместе с ритмом Толстого в повести «Казачьи» (рис. 3.5).




Рисунок 3. 5 – Представление текста в виде линейных графиков

В *STATSOFT* процесс анализа данных превращается в увлекательное исследование с использованием новейших компьютерных технологий.

Итог вашей исследовательской работы - развернутый аналитический отчет, позволяющий увидеть и понять данные, принять верное решение в сложной ситуации.

Ранее каждый шаг анализа, начиная от представления данных, перевода их в нужный формат, проверки, группировки, сортировки, сжатия, графической интерпретации, подготовки программ обработки до просмотра результатов, был трудной задачей. Теперь достаточно двух-трех щелчков мыши, чтобы огромные объемы данных чрезвычайно быстро преобразовывались, обрабатывались и появлялись на экране в виде графиков, диаграмм и таблиц. Все результаты анализа складываются в рабочие книги *STATSOFT* - своего рода контейнеры, содержащие нужные документы и доступные вам.

Вы можете вернуться в любую точку анализа, подвергнуть данные другому способу обработки. Вы также можете внести в них искусственные изменения и проверить гипотезу типа «что будет, если».

Статистические модули системы *STATSOFT* покрывают практически весь спектр современного и классического анализа данных.

Если говорить кратко, то основное достоинство *STATSOFT* состоит в том, что весь анализ проводится в интерактивном режиме последовательно открывающихся диалоговых окон, покрывающих большинство вариантов анализа. Это дает возможность даже неподготовленному пользователю провести углубленный анализ данных и получить результат.

3.1 Автоматизированные нейронные сети *STATISTICA (SANN)*

Откроем модуль Автоматизированные Нейронные Сети (Automated Neural Networks). Надеемся, что работа в нем доставит вам удовольствие (рис. 3.6).

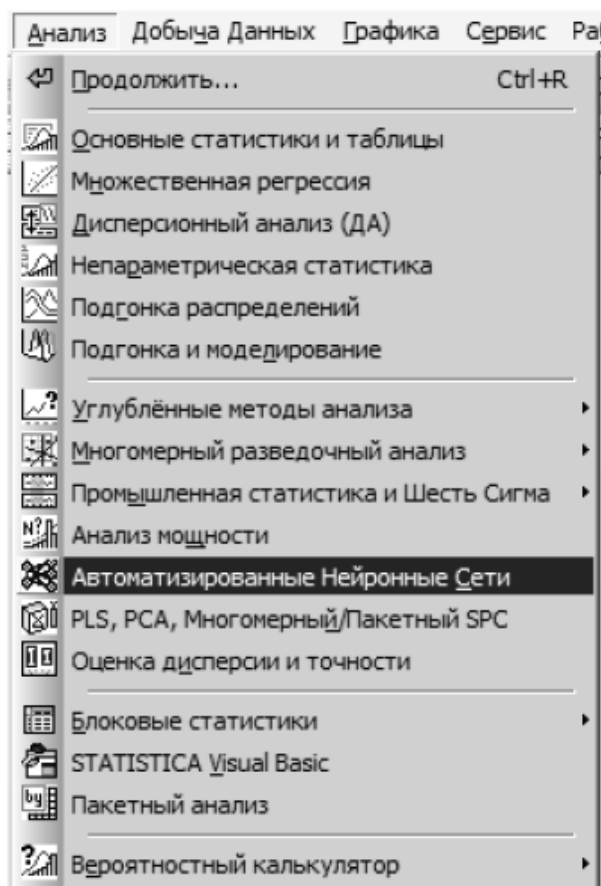


Рисунок 3.6 – Запуск Автоматизированных Нейронных Сетей

Как у любого инструмента, у нейронных сетей есть свои ограничения. Например, было бы неразумно применять нейронные сети для классификации

такого ясного экспериментального материала, как цветы ириса Фишера, хотя полезно использовать файл *Irisdat.sta* для проверки работы сети; или использовать нейронные сети для проверки гипотезы о виде распределения, где существуют точные математические результаты. Однако вполне разумно использовать сети для того, чтобы разобрать «гору» или, лучше сказать, разгрести завал данных, имеющихся у исследователя.

Действительно, анализируя геологические данные, полученные в результате полевых исследований, или данные о продажах в супермаркетах с тысячей сортов разнородной продукции, вы находитесь в принципиально иной ситуации, чем в случае классификации объектов, которые описываются лишь небольшим количеством признаков. Само построение правдоподобных гипотез в подобных задачах представляет собой достаточно сложную задачу. Особенно полезны нейронные сети на этапе разведочного анализа данных, когда связи между данными не очевидны и имеется небольшое число гипотез о связях между ними. Нейронные сети помогают понять структуру исходных данных, сформулировать разумные гипотезы, которые затем могут быть проверены точными методами.

Основные парадигмы нейронных сетей. Вначале нам нужно понять идею нейронных сетей, а затем опишем диалог в *STATISTICA*. Нейронным сетям посвящено много прекрасных книг и статей, которыми мы и руководствуемся.

Мы уже отмечали, что идеи нейронных сетей возникли из попыток смоделировать человеческий мозг. Удивительно, что мозг, состоящий из простых клеток - нейронов, - способен создавать сложные образы - произведения искусства подтверждают это. Математические результаты говорят, что с помощью нейронов можно смоделировать сколь угодно сложные функции. При изучении нейронных сетей мы переходим из одной сферы в другую: из области техники в биологию, и там находим многие важные идеи и образы. Переложенные на технический язык биологические идеи и ассоциации дают богатый материал для построения разнообразных моделей.

Итак, ключевым здесь является понятие нейрон. Нейроны - это специальные нервные клетки, способные распространять электрохимические сигналы. Для нас важно, что нейрон имеет каналы *ввода* информации (дендриты), ядро и канал *вывода* информации (аксон). Аксоны нейрона соединяются с дендритами других клеток с помощью синапсов. При возбуждении нейрон посылает сигнал по своему аксону. Через синапсы сигнал достигает другие нейроны, которые, в свою очередь, могут возбуждаться. Нейрон возбуждается, когда суммарный уровень сигналов, пришедших к нему, превышает определенный уровень (порог активации). При этом интенсивность сигнала, получаемого нейроном (следовательно, возможность его активации), зависит от активности синапсов.

Итак, запомним:

- Нейрон получает сигналы через *несколько* входных каналов. Каждый сигнал проходит через соединение - синапс, имеющее определенную

интенсивность (или вес); этот вес соответствует синаптической активности нейрона.

Обозначим через w_i ; вес i -го синапса, $1 \leq i \leq N$. Тогда текущее состояние нейрона определяется как взвешенная сумма входных сигналов, формально:

$$S = \sum x_i \times w_i \quad (3.1)$$

где суммирование распространяется по всем синапсам $1 \leq i \leq N$.

• Полученный сигнал преобразуется с помощью функции активации f (или передаточной функции), в результате получается *выходной* сигнал нейрона.

Обозначим через Y выходной сигнал нейрона. Тогда выход нейрона есть функция его состояния:

$$Y = f(s) \quad (3.2)$$

Функция *активации* или *передаточная* функция f , - некоторая нелинейная функция.

Самый простой пример функции активации - индикаторная, или функция единичного скачка: $f(x) = a$, если $x \leq T$; $f(x) = b$, если $x \geq T$, где a, b - константы (например, $a = +1, b = -1$).

Если текущее состояние нейрона меньше определенного порогового значения T , то его выход равен 0 - возникает состояние торможения.

Если текущее состояние нейрона больше порогового значения T , то выход равен 1 - состояние возбуждения.

STATISTICA позволяет использовать также другие передаточные функции, например, тождественную, линейную, логистическую и другие.

Заметьте, мы употребили слово *текущее* состояние нейрона, поэтому формально в приведенных формулах нам следует учесть зависимость от дискретного времени $t = 1, 2, 3...$ Но в упрощенном случае зависимость от t опускается. Очевидно, что эта модель очень проста и не в состоянии воспроизвести *структуру* мозга, однако, в некоторых ситуациях она имеет ценность.

Именно такую модель использовал Розенблатт в 1959 г., чтобы построить однослойный перцептрон, способный распознавать простейшие образы: отнести подаваемый сигнал к одному из двух классов. Понятно, что Розенблатт хотел смоделировать процесс дрессировки животных. И это ему удалось. Конструкция замечательна своей простотой и ясностью - мы к ней вернемся ниже.

3.2 Математические модели

Итак, мы получили представление о том, что такое нейрон. Перейдем к пониманию *сети* нейронов. Соединенные друг с другом нейроны образуют *сеть*. Если сеть предполагается для чего-либо использовать (например, с целью классификации), то у нее должны быть входы (принимающие значения интересующих нас переменных из внешнего мира) и выходы (прогнозы или управляющие сигналы).

Входы и выходы соответствуют сенсорным и двигательным нервам, например, соответственно идущим от глаз и к рукам. Но, кроме этого, в сети может быть еще много промежуточных (скрытых) нейронов, выполняющих внутренние функции. Входные, скрытые и выходные нейроны связаны между собой.

Простейшая сеть имеет структуру прямой передачи сигнала: сигналы проходят от *входов* через скрытые элементы и в конце концов поступают на *выходные* элементы (рис. 3.7).

Каждый элемент сети (нейрон) описывается своим собственным набором параметров. Входной слой служит исключительно для ввода значений входных переменных. Каждый из скрытых и выходных нейронов соединен со всеми элементами предыдущего слоя. Если сеть рекуррентная (содержит связи от более дальних к более ближним нейронам, сигнал передается не только слева направо, но и справа налево), то она может быть неустойчивой и иметь очень сложную динамику поведения.




Рисунок 3.7 – Сеть с прямой передачей сигнала

Можно было бы рассматривать сети, в которых нейроны данного слоя связаны лишь с *некоторыми* нейронами предыдущего слоя.

Для большинства приложений предпочтительны сети с полной системой связи, которые реализованы в модуле Автоматизированные Нейронные Сети.

При работе сети на входные элементы подаются значения входных переменных, затем возбуждаются нейроны промежуточных слоев, и далее сигнал поступает на выходной слой. Каждый из них вычисляет свое значение активации - вычитая из взвешенной суммы выходов элементов предыдущего слоя пороговое значение. Затем значение активации преобразуется с помощью функции активации, и в результате получается выход нейрона.

После того как сеть отработает, выходные значения элементов выходного слоя принимаются за выход сети в целом. Таким образом нейронная сеть преобразует входные сигналы в выходные.

Обучение и кросс-проверка

Самое замечательное, что нейронную сеть действительно можно обучить.

На философский вопрос: почему? имеется философский ответ: сеть моделирует работу мозга, а живые существа имеют способность обучаться, поэтому адекватная модель мозга или клеток мозга должна обладать тем же свойством.

Основной постулат обучения состоит в следующем: обучение заключается в изменениях силы синаптических связей и порога T - варьируя эти связи, можно моделировать процесс обучения.

Формально процедура обучения состоит в том, чтобы, меняя веса $w(i,j)$, где (i, j) обозначает i -й нейрон в j -м слое сети и значение порога T , добиться заданного результата работы сети.

После того как удастся достичь результата на обучающей выборке, сеть может быть применена к реальным данным.

Ключевым моментом анализа является разделение исходных данных на *обучающую, контрольную и тестовую* выборку.

На *обучающей* выборке проводится обучение сети - оценка параметров сети. Естественно, большая часть данных участвует в обучении сети.

Контрольная выборка контролирует процесс обучения, на *тестовой* выборке проводится оценка точности результатов (кросс-проверка).

Рассмотрим процедуру обучения на примере простой и ясной модели Розенблатта однослойного перцептрона (лат. *perceptio* - восприятие). Конечно, здесь будут описан лишь один из возможных алгоритмов обучения.

3.3 Модель Розентблатта

В этой модели число слоев равно 1, поэтому мы исключаем второй индекс нумерации слоев и рассматриваем только веса $w(i)$, $1 \leq i \leq N$. Входной сигнал может принадлежать либо классу А, либо класса Б.

На вход сети подается сигнал (x_1, x_2, \dots, x_N) . Предположим, для простоты, $N = 2$.

Обучение однослойного персептрона

Шаг 0. Начальные установки: веса w_1 , w_2 и порог T задаются случайным образом. Введем шаг обучения t : $t=0$.

Шаг 1. Примем $t=t+l$. Предъявим сети входной сигнал: $(x_1(t), x_2(t))$. Пусть $d(t)=l$, если входной сигнал принадлежит классу А; $d(t)=-l$, если входной сигнал принадлежит классу Б.

Шаг 2. Вычислим *состояние* нейрона в момент времени t :

$$s(t) = w_1(t)x_1(t) + w_2(t)x_2(t) - T \quad (3.3)$$

Шаг 3. Вычислим выходной сигнал нейрона $y(t)$ в момент t :

$$y(t) = \text{sign}(s(t)). \quad (3.4)$$

Шаг 4. Вычислим новые веса по формулам:

$$w_1(t) = w_1(t-1) + r(y(t) - d(t)), \quad w_2(t) = w_2(t-1) + r(y(t) - d(t)) \quad (3.5)$$

где r - шаг обучения.

Шаг 5. Если r меньше объема обучающей выборки L , то переходим к шагу 1. В противном случае обучение заканчивается.

В итоге, мы имеем обученный персептрон с весами w/L . $w_2(L)$, T .

Обученный однослойный персептрон способен решать очень простые задачи классификации.

Обучение многослойного персептрона

Обучение однослойного персептрона, естественно, приводит к многослойным персептронам. Обучение может вестись как с учителем, так и без него. При обучении с учителем обучающий набор представляет собой ряд наблюдений, для которых указаны значения *входных* и *выходных* переменных. Учитель проверяет результат и подтверждает правильность ответа. Это облегчает обучение.

Отталкиваясь от случайной начальной конфигурации весов порогов (случайно взятой точки на поверхности ошибок), алгоритм обучения постепенно отыскивает минимум.

Конечно, вы понимаете отличие глобального минимума от локального: локальный минимум - это минимум для некоторой *окрестности* точки из области определения функции, но не для всей области. Найдя локальный минимум, вы вовсе не можете быть уверены в том, что этот минимум глобальный.

Другие точки могут иметь меньшее значение. Вообще локальный минимум может значительно отличаться от глобального. Лучше всего это можно понять, представив себе географическую карту и рассмотрев точки суши, лежащие ниже уровня моря. Очевидно, самая нижняя точка в окрестности

города Москвы существенно отличается от самой нижней точки Московской области или всей России.

Заметим, что эффективных алгоритмов нахождения глобального минимума в самой общей ситуации не существует: в одних ситуациях эффективны одни алгоритмы, в других - другие.

От теоретических конструкций перейдем к модулю Автоматизированные Нейронные Сети программы *STATISTICA*.

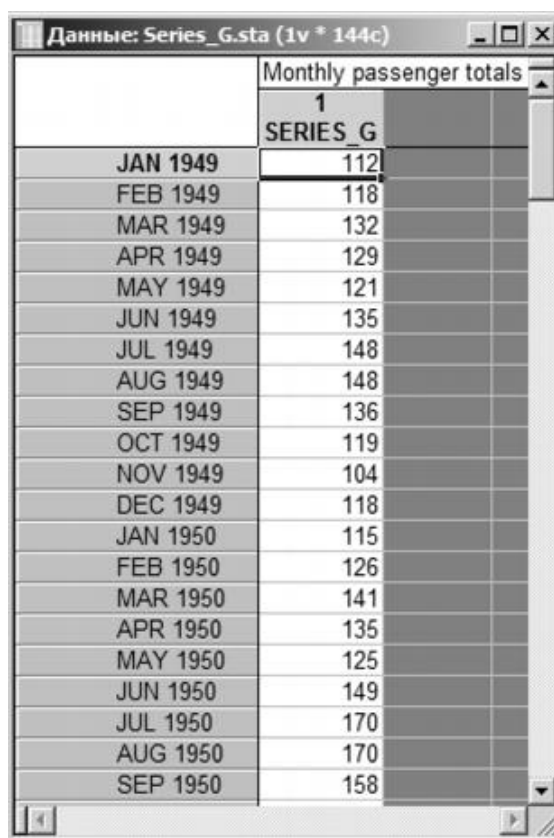
Пошаговый пример: прогнозирование временных рядов с помощью нейронных сетей

Рассмотрим пример анализа временных рядов, где значения переменных изменяются в различные моменты времени и где присутствуют (или, по меньшей мере, ожидаются) зависимости между *последовательными* значениями одной и той же переменной.

Целью исследования является прогноз значения переменной в следующий момент времени по ее значениям в предшествующие моменты.

Мы будем работать с классическими данными, исследованными Боксом и Дженкинсом, и применим к ним технологии нейронных сетей.

Шаг 1. Откроем файл данных *Series G.sta* из папки *Examples*. Данные содержат значения месячных авиаперевозок пассажиров в США (рис. 3.8).



Monthly passenger totals	
1	SERIES_G
JAN 1949	112
FEB 1949	118
MAR 1949	132
APR 1949	129
MAY 1949	121
JUN 1949	135
JUL 1949	148
AUG 1949	148
SEP 1949	136
OCT 1949	119
NOV 1949	104
DEC 1949	118
JAN 1950	115
FEB 1950	126
MAR 1950	141
APR 1950	135
MAY 1950	125
JUN 1950	149
JUL 1950	170
AUG 1950	170
SEP 1950	158

Рис. 3.8. Файл данных Series G.sta

Шаг 2. Проведем визуализацию данных. Нажмем правой кнопкой мыши по переменной **SERIES_G** и выберем в выпадающем меню построение Линейного графика по столбцам.

В результате в системе *STATISTICA* построится график временного ряда (рис. 8.4). С помощью графика ряда легко определить, что мы имеем дело с рядом, который обладает возрастающим трендом, сезонной изменчивостью.

Шаг 3. Спектральный анализ ряда - из временной области перейдем в частотную. Это позволит найти *периодичности* в данных.

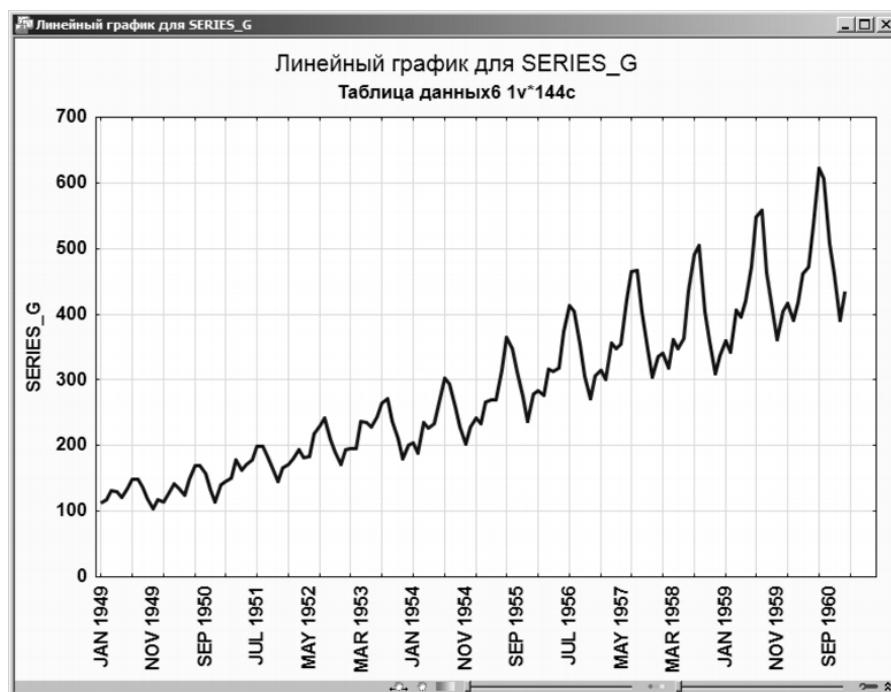


Рисунок 3.9 – График исходного временного ряда

Откроем модуль Временные ряды и прогнозирование, находящийся на вкладке Углубленные методы меню Анализ (рис. 3.10).

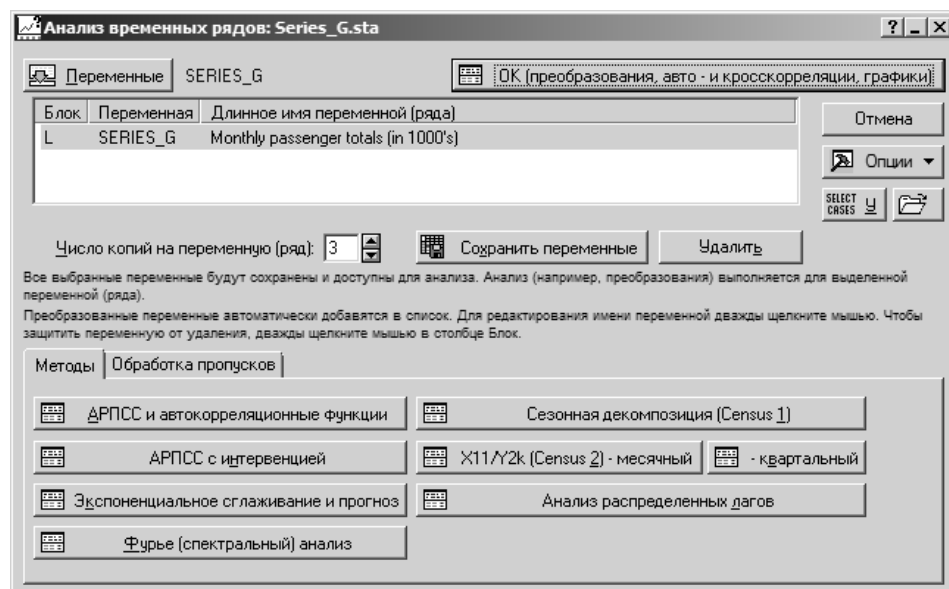


Рисунок 3.10 – Стартовое окно модуля Анализ временных рядов

Далее нажмем кнопку Фурье (спектральный) анализ. Для нахождения периода в наших данных построим периодограмму (рис. 3.11).

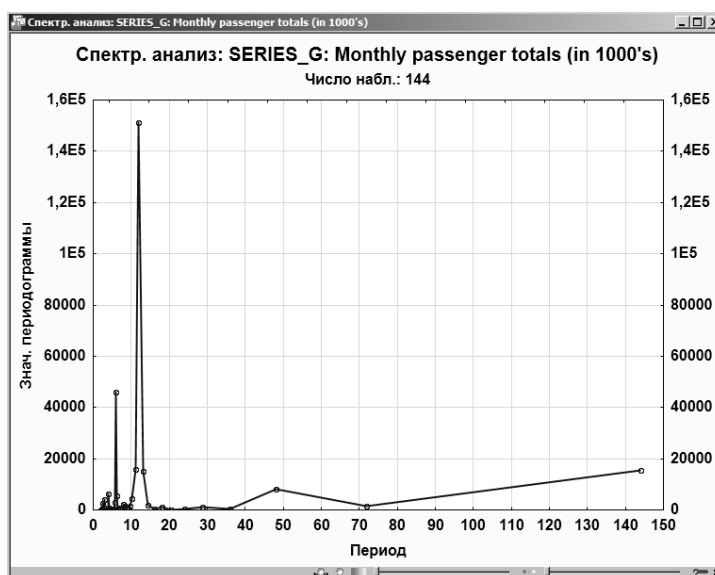


Рисунок 3.11 – Периодограмма

Исследуя построенный график, замечаем, что периодограмма имеет ярко выраженный пик, что свидетельствует о наличии сезонности в данных. Наибольшее значение периодограммы соответствует периоду 12. Данные имеют годовую периодичность.

Шаг 4. Проведем анализ с помощью **Автоматизированных Нейронных сетей STATISTICA (SANN)**.

Запустим модуль **Автоматизированные Нейронные сети**. На экране появится стартовое окно (рис. 3.12).

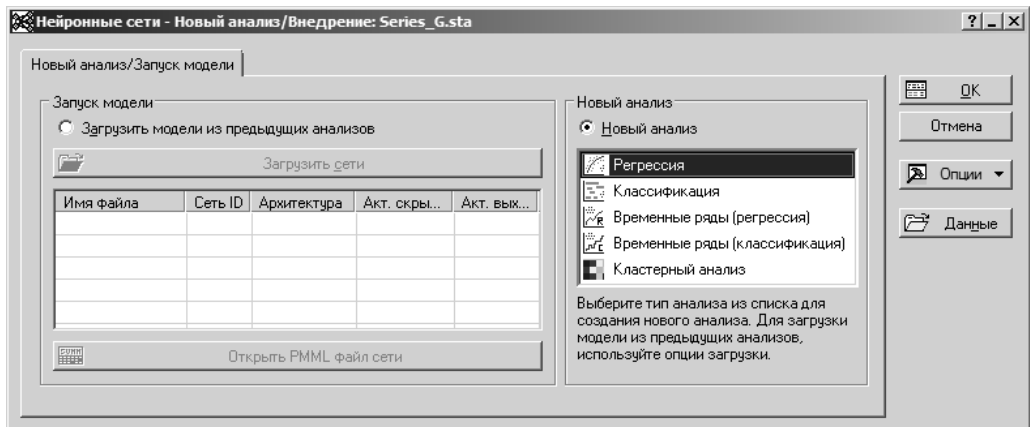


Рисунок 3.12 – Стартовое окно модуля Нейронных сетей

Файл данных *SeriesG.sta* ранее открыт нами. Если вы работаете с новым файлом нажмите кнопку **Данные** в правой части окна.

В стартовом окне модуля Нейронные сети можно выбрать различные виды анализа: регрессию, классификацию, прогнозирование временных рядов, кластерный анализ.

Также можно загрузить и использовать в анализе сети, построенные ранее.

Выберем тип анализа Временные ряды (регрессия), чтобы построить прогноз,

и нажмем кнопку ОК. На экране появится окно Отбор данных (рис. 3.13). В этом окне имеется несколько вкладок, выберем вкладку Быстрый. Далее выберем переменные для анализа из открытого файла данных.

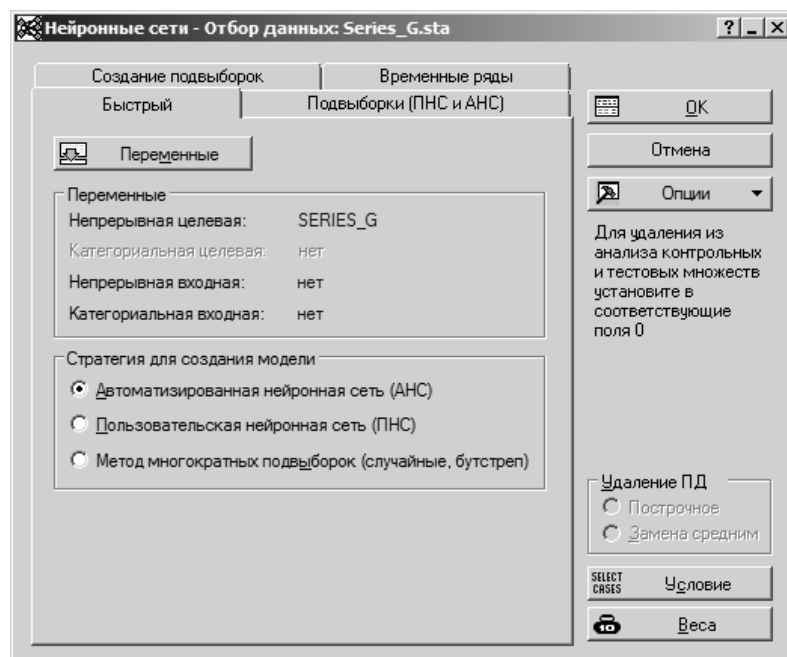


Рисунок 3.13 – Окно отбора данных для анализа

Шаг 5. Выбор переменных. Нажмем кнопку Переменные на вкладке Быстрый.

На экране появится окно выбора переменных. Переменные могут быть непрерывными и категориальными (рис. 3.14). Переменная **SERIES_G** является непрерывной *целевой* переменной, которую мы хотим прогнозировать.

Шаг 6. Создание обучающих, контрольных и тестовых выборок. В задачах анализа временных рядов особенное внимание следует уделить выбору обучающих, контрольных и тестовых подмножеств. В обычной ситуации каждое наблюдение рассматривается независимо, и никаких вопросов с выбором множеств не возникает. Во временных рядах наблюдения не являются независимыми, значение ряда в момент времени t , зависит от значения в моменты времени $t-1$, $t-2$ и т. д.



Рисунок 3.14 – Выбор переменных для анализа

В нашем примере выставим настройки: наблюдений на обучающую выборку - 85 %, на контрольную - 15 % и 0 % - на тестовую (рис. 3.15).

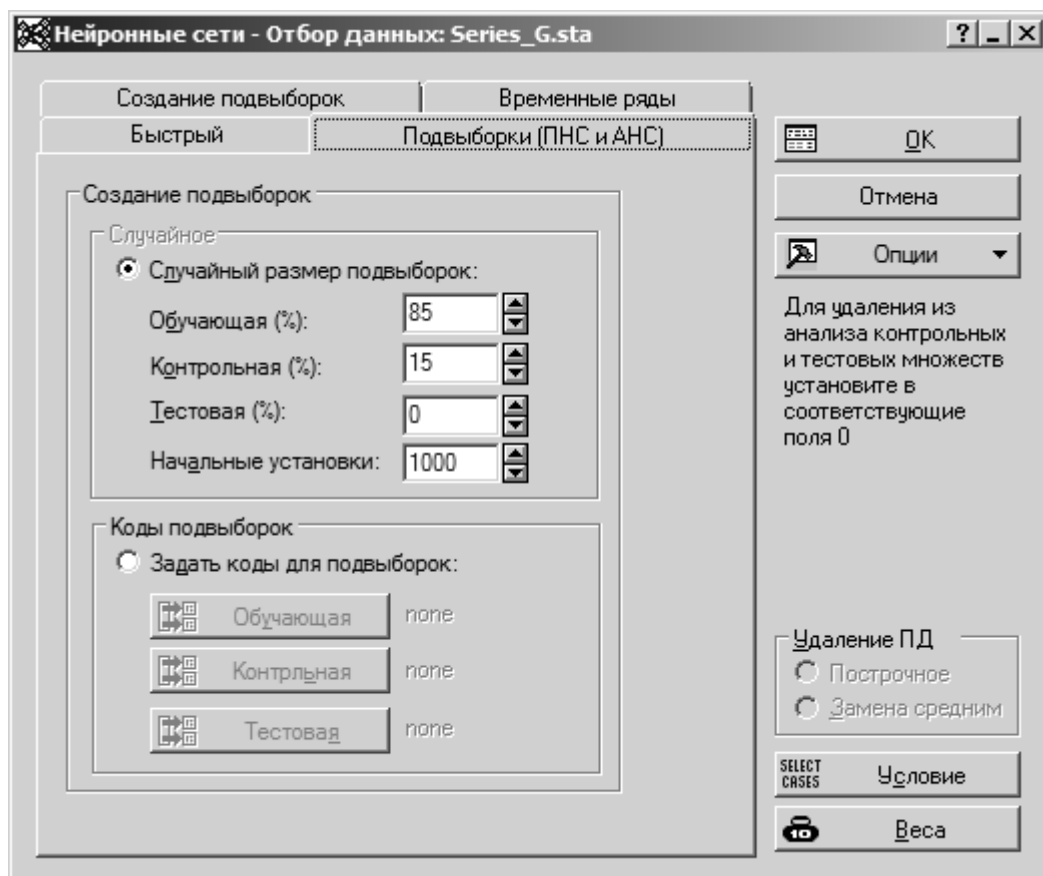


Рисунок 3.15 – Определение подвыборок для обучения сети

Чем сложнее проектируемая модель, тем больше данных необходимо для корректного обучения нейронной сети.

Далее переходим к вкладке Временные ряды (рис.3.16).

В задаче прогнозирования необходимо указать размер окна, который определяет количество *входов* нейронной сети. Нейронная сеть должна знать, как далеко вперед должен строиться прогноз, иными словами, нужно указать *горизонт* прогноза. Данные имеют годовую периодичность, поэтому в качестве размера окна выберем значение 12.

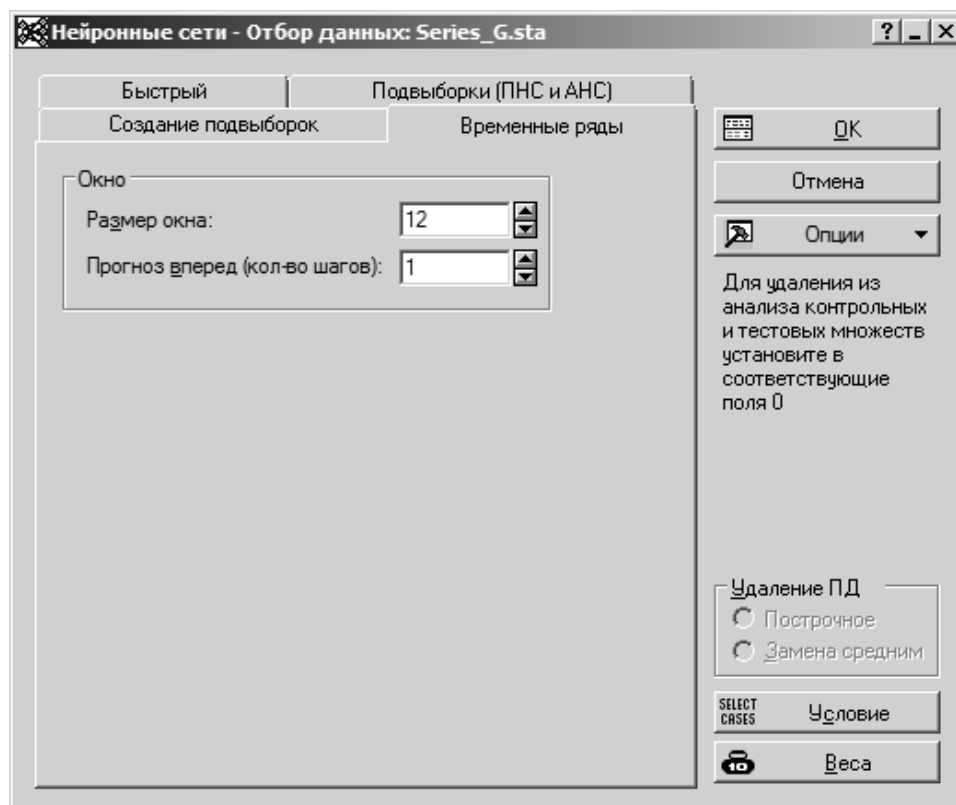


Рисунок 3.16 – Вкладка Временные ряды окна отбора данных

Шаг 7. Выбор архитектуры сетей. Нажмем кнопку ОК и перейдем к окну Автоматизированные Нейронные Сети (рис. 8.12). В этом окне имеется несколько вкладок, позволяющих выбрать тип обучаемых сетей, функции активации и др.

Выберем вкладку Быстрый. Здесь можно выбрать тип сети, например, многослойные персептроны (МЛП) или радиальные базисные функции (РБФ), указать количество скрытых нейронов (минимальное и максимальное значение), количество сетей для обучения и сохранения, выбрать функцию ошибки.

В задачах прогнозирования обычно используют многослойные персептроны.

Количество обучаемых сетей возьмем 50, сохраняемых - 5.

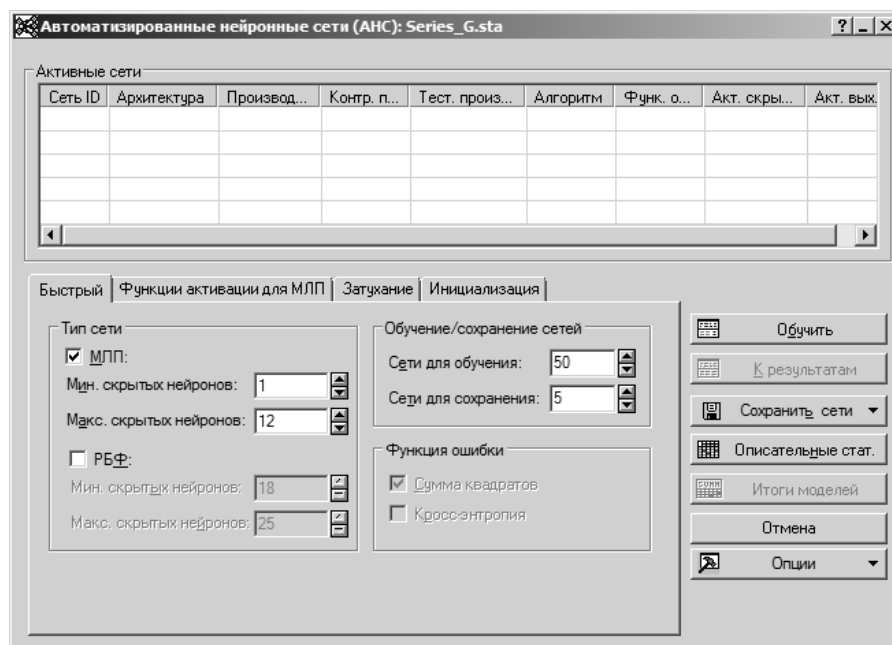


Рисунок 3.17 – Окно настроек параметров сети - вкладка Быстрый

Откроем далее вкладку **Функции активации** (рис. 3.18). В этой вкладке можно выбрать различные функции активации для скрытых и выходных нейронов многослойных персептронов. Выберем, например, тождественные функции активации, хотя можно экспериментировать и с другими функциями.

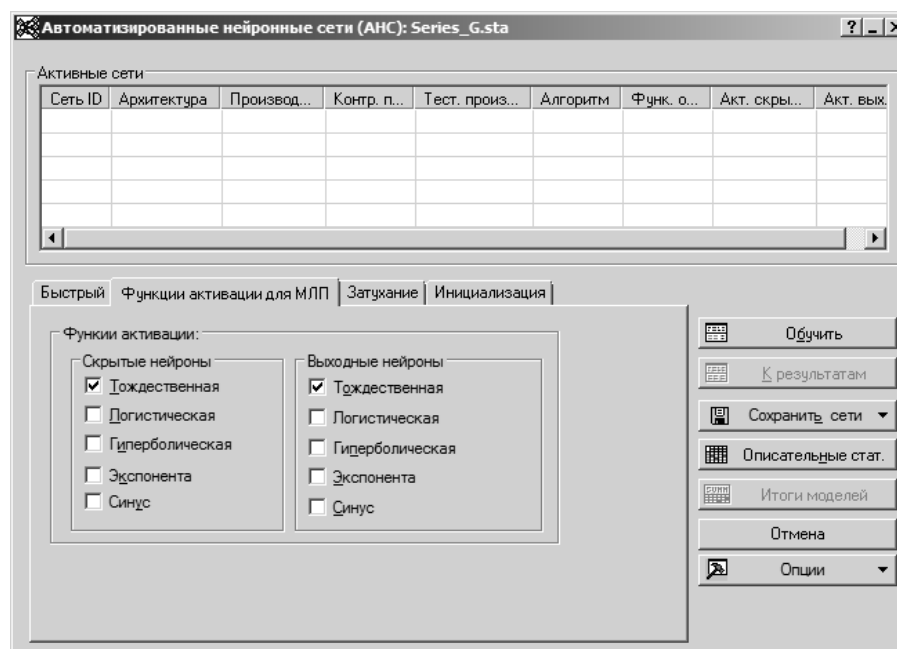


Рисунок 3.18 – Окно настроек параметров сети - вкладка Функции активации для МЛП

Модуль нейронных сетей *STATISTICA* позволяет реализовать гибкий творческий подход к анализу данных с помощью нейронных сетей.

Шаг 8. Обучение сети. Итак, структура сети определена - это многослойный персептрон, тождественные функции активации, число нейронов от 1 до 12. Нажмем кнопку. Обучить и перейдем к процессу обучения, после окончания процесса обучения моделей на экране появится окно Нейронные сети - Результаты. В верхней части окна показаны лучшие сети и показатели качества моделей, в нижней находятся вкладки, позволяющие всесторонне проанализировать результаты.

Шаг 9. Анализ результатов и построение прогноза. Программа проанализировала 50 различных сетей - многослойных персептронов, - и отобрала 5 наилучших нейронных сетей, отображенных в верхней части окна. В окне указана архитектура сети, производительность, алгоритм обучения, функция ошибок и другие характеристики. Построенные сети можно использовать для прогноза, именно в этом заключалась наша цель.

С помощью обученной сети можно выполнить так называемую *проекцию* временного ряда. При этом вначале сеть обрабатывает на первых 12 входных значениях ряда и строит прогноз следующего значения. Это спрогнозированное значение вместе с одиннадцатью предыдущими входными значениями подается на вход сети, и снова строится прогноз очередного значения. Такую проекцию можно повторять любое число раз, хотя очевидно, чем больше количество итераций будет использовано, тем хуже получится качество прогноза.

В окне Нейронные сети - Результаты откроем вкладку Временные ряды (рис. 3.19).

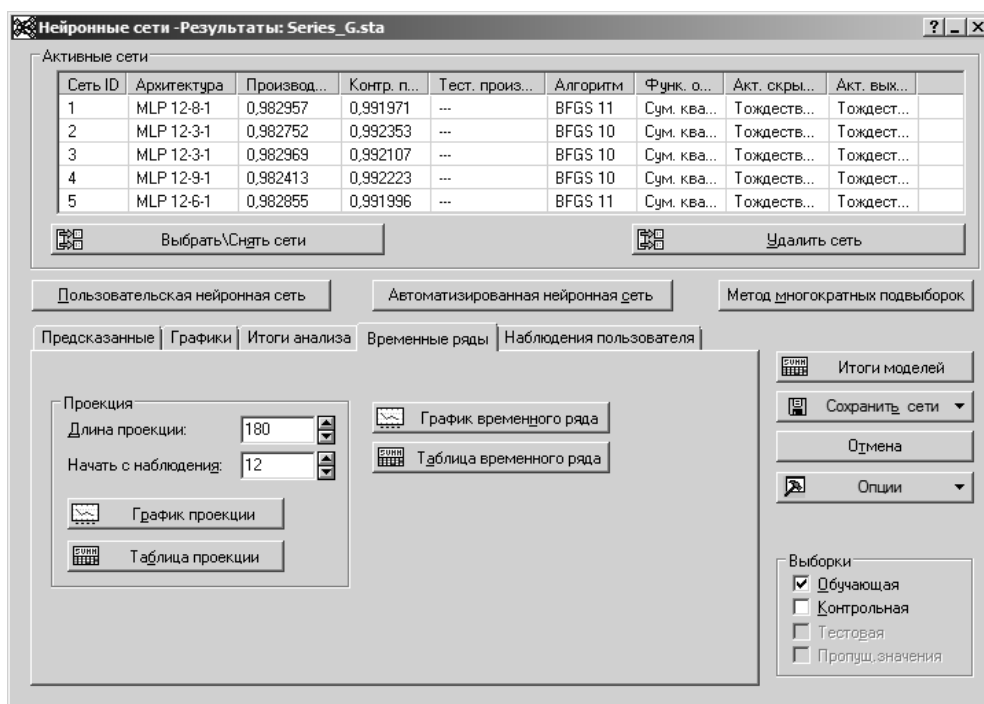


Рисунок 3.19 – Окно результатов анализа, вкладка Временные ряды

Используя опции этой вкладки, можно построить графики временного ряда, отобразить результаты в таблице, а также построить проекции. Для

построения проекции необходимо выбрать всего два параметра - **Длина проекции** и **Начать с наблюдения**. Построим проекцию длиной 180, начиная с 12 шага. Для этого в окне результатов выставьте **Длину проекции** равной 180, а в поле **Начать с наблюдения** введите значение 12. Затем нажмем кнопку **График проекции**.

На экране появится график временного ряда и предсказанные временные ряды, наложенные друг на друга во времени (рис. 3.20). В каждый момент отмечается соответствующее целевое значение и предсказанные значения. Заметьте, строятся проекции для лучших сетей.

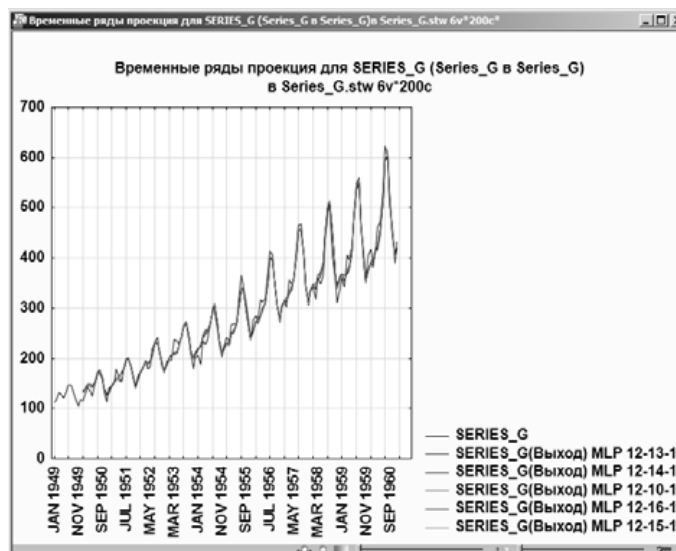


Рисунок 3.20 – График исходных и предсказанных значений

Как видно из графика, полученные модели хорошо ложатся на исходный ряд. Можно построить график прогноза на последний год (рис. 3.21).

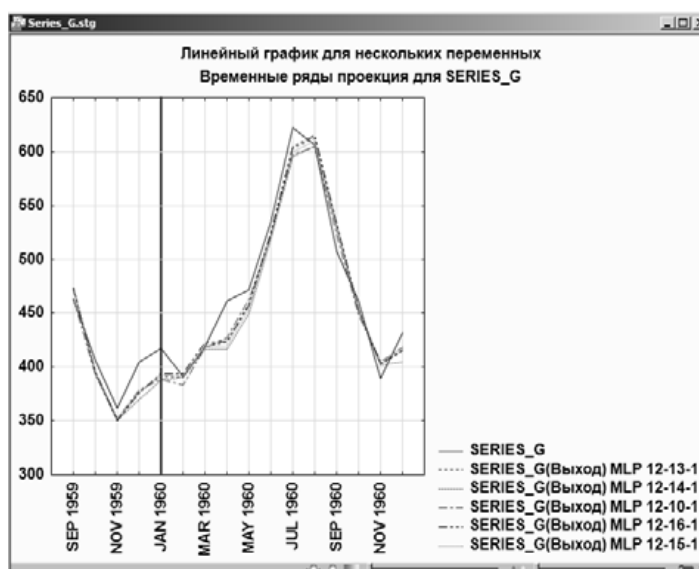


Рисунок 3.21 – График временного ряда

Графики прогнозируемых значений близки к истинным значениям. Ошибки, полученные на кросс-проверке приведены в таблице 3.1.

Таблица 3.1 – Ошибки кросс-проверки

	<i>SERIES_G</i> (Выход) <i>MLP 12-13-1</i>	<i>SERIES_G</i> (Выход) <i>MLP</i> <i>12-14-1</i>	<i>SERIES_G</i> (Выход) <i>MLP 12-10-1</i>	<i>SERIES_G</i> (Выход) <i>MLP 12-16-1</i>	<i>SERIES_G</i> (Выход) <i>MLP</i> <i>12-15-1</i>
Mean square error	322,8545	472,5462	301,7871	314,4865	363,9434
Mean absolute error	14,7448	17,5286	14,4242	15,0202	15,5333
Mean relative squared error	0,0016	0,0025	0,0015	0,0016	0,0018
Mean relative absolute error	0,0322	0,0391	0,0320	0,0328	0,0340
Correlation coefficient	0,9767	0,9707	0,9809	0,9760	0,9739

Из таблицы видно, что средняя относительная ошибка - четвертая строка таблицы - составляет 3-4 %. Наилучший результат дает третья сеть: MLP 12-10-1 - многослойный персептрон, состоящий из 10 скрытых нейронов, имеющих тождественные функции активации.

Результаты всех лучших построенных сетей довольно близки и мало зависят от числа скрытых нейронов: существенным оказалось, что функции активации тождественны. При других функциях активации результаты получаются существенно хуже.

Все полученные сети медленно вырождаются - их можно использовать для построения прогноза на несколько месяцев вперед.

3.4 Data Mining - Добыча данных

Термин *Data Mining* переводится как «извлечение информации» или «добыча данных», в действительности это *добыча знаний*. Нередко рядом с *Data Mining* встречаются слова *knowledge discovery* - «обнаружение знаний» и *Data Warehouse* - «хранилище данных». Возникновение указанных терминов, которые являются неотъемлемой частью *Data Mining*, связано с новым витком в развитии средств и методов обработки и хранения данных. Основная цель *Data Mining* состоит в выявлении скрытых правил и закономерностей в наборах данных, образно говоря, в «нахождении золотых песчинок в огромной куче руды». Дело в том, что человеческий разум сам по себе не приспособлен для восприятия больших массивов разнородной информации. В среднем человек, за исключением некоторых индивидуумов, не способен улавливать более двух-трех взаимосвязей даже в небольших выборках.

Но и традиционная статистика, долгое время претендовавшая на роль основного инструмента анализа данных, также нередко пасует при решении

задач из реальной жизни. Она оперирует усредненными характеристиками выборки, которые часто являются фиктивными величинами (средней платежеспособностью клиента, когда в зависимости от функции риска или функции потерь, вам необходимо уметь прогнозировать состоятельность и намерения клиента; средней интенсивностью сигнала, тогда как вам интересны характерные особенности и предпосылки пиков сигнала и т. д.). Поэтому методы статистики оказываются полезными главным образом для проверки заранее сформулированных гипотез, тогда как определение гипотезы иногда бывает достаточно сложной и трудоемкой задачей. Современные технологии *Data Mining* перелопачивают информацию с целью автоматического поиска шаблонов (паттернов), характерных для каких-либо фрагментов неоднородных многомерных данных.

Data Mining - это не один, а совокупность большого числа различных методов обнаружения знаний. Выбор метода часто зависит от типа имеющихся данных и от того, какую информацию вы пытаетесь получить. Вот, например, некоторые методы: ассоциация (объединение), классификация, кластеризация, анализ временных рядов и прогнозирование, нейронные сети и т. д.

Сфера применения *Data Mining* ничем не ограничена - *Data Mining* востребован везде, где имеются данные для исследования.

Этапы работы в *Data Mining*

Процедура работы в *Data Mining* включает три основных этапа:

- 1) начальное исследование;
- 2) построение модели или идентификация выборки вместе с проверкой и подтверждением;
- 3) развертывание (применение модели к новым данным для осуществления прогноза).

Рассмотрим каждый из перечисленных этапов более подробно.

Этап 1. Исследование. Этот этап обычно начинается с подготовки данных, которая может включать очистку данных, преобразования данных, выбор подмножеств, а также, в случае наборов данных с большим числом переменных (полей), анализа их свойств для

того, чтобы количество переменных свести к разумному числу (в зависимости от рассматриваемых статистических методов).

Затем, в зависимости от характера аналитической задачи, первый этап процесса «добычи данных» может включать как простой выбор непосредственных предикторов для регрессионной модели, так и тщательное проведение разведочного анализа с использованием ряда графических и статистических методов для нахождения наиболее подходящих переменных и определения сложности и/или общего характера моделей, которые можно использовать на следующем этапе.

Этап 2. Построение модели и проверка. Этот этап включает рассмотрение различных моделей и выбор наилучшей на основании их характеристик (объяснение изменчивости и получение надежных результатов по выборкам). Может показаться, что эта простая операция. Но, на самом деле, она иногда

является очень сложным процессом. Имеется ряд методов, разработанных для достижения этой цели, многие из которых основаны на так называемой «конкурентной оценке моделей», которая состоит в применении различных моделей к одному и тому же набору данных и последующем сравнении их характеристик для выбора наилучшей модели. Эти методы, которые часто рассматриваются как ядро *Предсказывающей добычи данных*, включают: *Накопление {Голосование, Усреднение}*, *Бустинг* и *Мета-обучение*.

Этап 3. Развертывание. Этот завершающий этап включает использование модели, выбранной в качестве наилучшей на предыдущем этапе, и ее применение к новым данным с целью получения прогнозов или оценок ожидаемых результатов. Концепция «добычи данных» приобретает все большее распространение, как инструмент для управления деловой информацией в тех случаях, когда предполагается, что из имеющихся данных можно будет извлечь знания для принятия решений в условиях неопределенности.

В последнее время возрос интерес к разработке новых методов анализа данных, специально предназначенных для сферы бизнеса (*Деревья классификации, Общие модели деревьев классификации и регрессии, Общие CHAID модели*), но, в целом, системы добычи данных по-прежнему основываются на классических принципах разведочного анализа данных (РАД) и построения моделей и используют те же подходы и методы.

Имеется, однако, важное отличие процедуры «добычи данных» от классического разведочного анализа данных. Системы «добычи данных» в большей степени ориентированы на практическое приложение полученных результатов, чем на выяснение природы явления. Иными словами, при «добыче данных» нас не интересует конкретный вид зависимостей между переменными. Выяснение природы участвующих здесь функций или конкретной формы интерактивных многомерных зависимостей между переменными не является главной целью этой процедуры. Основное внимание уделяется поиску решений, на основе которых можно было бы строить достоверные прогнозы.

Таким образом, в области «добычи данных» принят подход к анализу данных и извлечению знаний, который иногда характеризуют словами «черный ящик», при котором используются не только классические приемы разведочного анализа данных, но и такие методы, как нейронные сети, позволяющие строить достоверные прогнозы, не уточняя конкретный вид тех зависимостей между переменными, на которых такой прогноз основан.

Очень часто область «добычи данных» трактуется как «смесь статистики, методов искусственного интеллекта (ИИ) и анализа баз данных», и до самого последнего времени она не признавалась полноценной областью интереса специалистов по статистике, а порой ее даже называли «задворками статистики». Однако благодаря своей большой практической значимости, эта проблематика ныне интенсивно разрабатывается и привлекает большой интерес и в ней достигнуты важные теоретические результаты.

В *STATISTICA Data Miner* содержится более 260 узлов анализа, которые могут соединяться с одним или несколькими источниками данных. Эти узлы можно рассматривать как независимые объекты статистического анализа, включающие в себя все функциональные возможности системы *STATISTICA* и процедуры работы с данными.

Рассмотрим более подробно узлы в различных областях рабочего окна Data Miner (рис. 3.22).

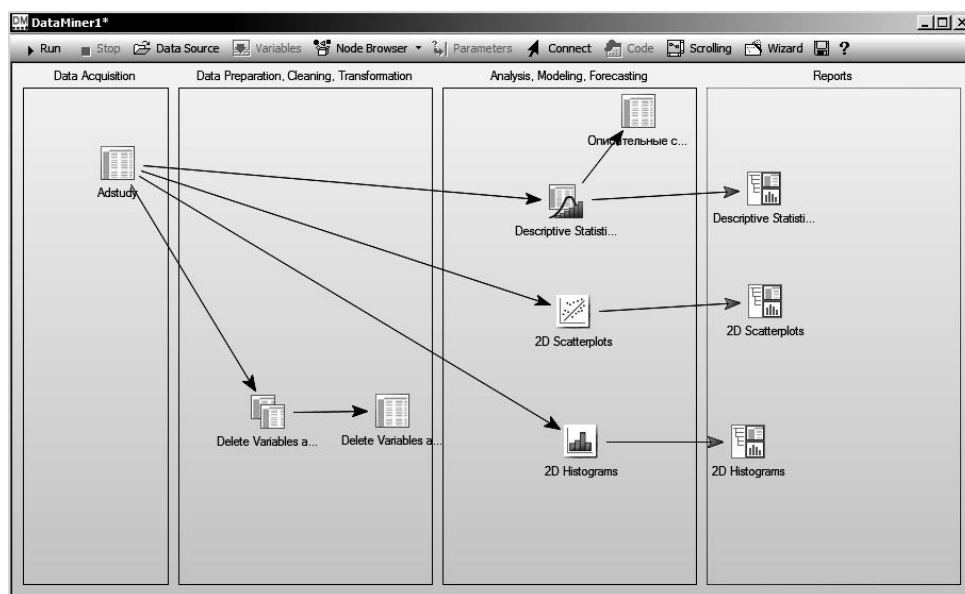


Рисунок 3.22 – Добыча Данных в STATISTICA

Используя основные пункты меню в верхней части окна, пользователь может задать источник данных, открыть диспетчер узлов, соединить узлы стрелками, запустить созданный проект. Все процедуры, доступные в *STATISTICA Data Miner*, можно загрузить через меню ^o Node Browser - Диспетчер узлов (рис. 3.23).

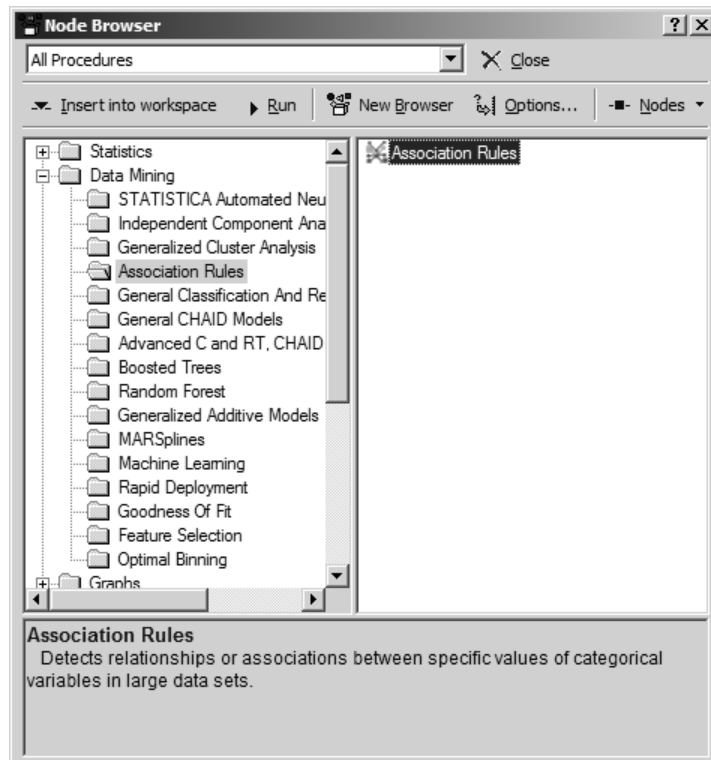


Рисунок 3.23 – Диспетчер узлов

В левой части диспетчера узлов находится дерево просмотра, с помощью которого можно выбрать различные узлы для исследовательского проекта.

Помимо специфических процедур *Data Mining*, например, *association rules* - ассоциативных правил, *machine learning* - машинное обучение, можно найти и стандартные процедуры анализа данных, доступные в системе *STATISTICA*.

Просматривая узлы в правой части окна, мы выбираем нужные узлы и добавляем их в рабочее окно.

Средства анализа *STATISTICA Data Miner*

В пакете предлагается исчерпывающий набор процедур и методов визуализации.

Средства анализа *STATISTICA Data Miner* можно разбить на пять основных классов. *Бурение и расслоение*. Набор процедур позволяющий группировать переменные,

вычислять описательные статистики, строить исследовательские графики и т. д. Запомните, в добыче данных самое важное - обнаружить интересные явления, закономерности, связи. Проведя бурение в разных направлениях, вы можете найти золотую жилу, которую будете эксплуатировать в дальнейшем.

Классификатор (деревья и кластеры). *STATISTICA Data Miner* включает в себя полный пакет процедур классификации: обобщенные линейные модели, деревья классификации, регрессионные деревья, кластерный анализ и т. д.

Разведчик многомерных моделей. Данный элемент содержит линейные, нелинейные обобщенные регрессионные модели.

Мастер прогнозов. Включает в себя модели авторегрессии и проинтегрированного скользящего среднего (АРПСС), сезонные модели АРПСС, экспоненциальное сглаживание, спектральный анализ Фурье, сезонную декомпозицию, прогнозирование при помощи нейронных сетей и т. д.

Нейросетевой разведчик. В данной части содержится наиболее полный пакет процедур нейросетевого анализа.

Data Mining включает огромный набор различных аналитических процедур, однако его могут использовать и обычные пользователи, обладающие небольшим опытом в анализе данных и математической статистике.

Для этого, кроме общих методов анализа, были встроены готовые законченные (сконструированные) модули анализа данных, предназначенные для решения наиболее важных и популярных задач: прогнозирования, классификации, создания правил ассоциации и т. д.

Пример проекта в *STATISTICA Data Miner*

В предыдущей главе мы рассмотрели пример анализа временных рядов с помощью нейронных сетей, теперь мы хотим повторить этот же анализ в среде *STATISTICA Data Miner* и сравнить полученные результаты.

Шаг 1. Открытие файла данных. В рабочем пространстве Data Miner нажмем

кнопку Data Source - Источник данных. Откроется окно Выберите источник данных (рис. 3.24)

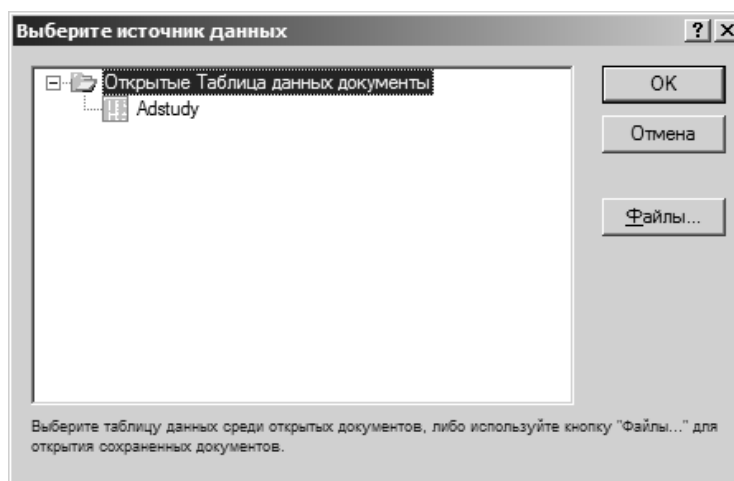


Рисунок 3.24 – Выбор источника данных для анализа

Как и ранее, будем работать с файлом *SeriesG.sta*. Если файл был открыт в рабочей области *STATISTICA*, то он будет предложен в списке источников автоматически. Нажмем кнопку *Файлы...* и выберем файл *Series G.sta* из папки примеров.

Шаг 2. Выбор переменных для анализа. После нажатия кнопки *Открыть* на экране автоматически появляется окно выбора переменных (рис. 9.6).

Переменная *SERIES_G* является непрерывной зависимой переменной. Выбираем переменную, как показано на рисунке, и нажимаем кнопку ОК. В результате в секцию *Data Acquisition - Сбор данных* добавилась иконка таблицы исходных данных.

Шаг 3. Выбор анализов с помощью Node Browser - Диспетчера узлов.

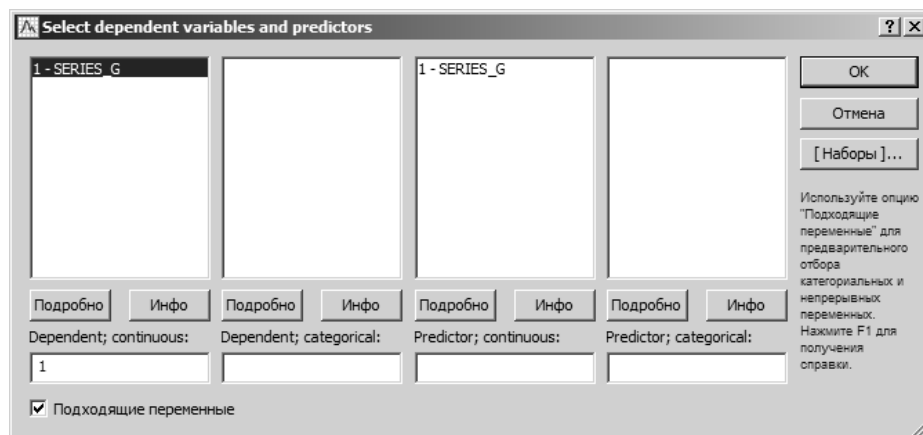


Рисунок 3.25 – Выбор переменных для анализа

Нажмем кнопку ^a Node Browser. Откроется меню Диспетчера узлов. Добавим в рабочую область построение Линейного графика. В левой части окна выберем Graphs - 2D Graphs (Графика - 2М Графики). В правой части появится список стандартных графиков, предлагаемых системой *STATISTICA* (рис. 3.26).

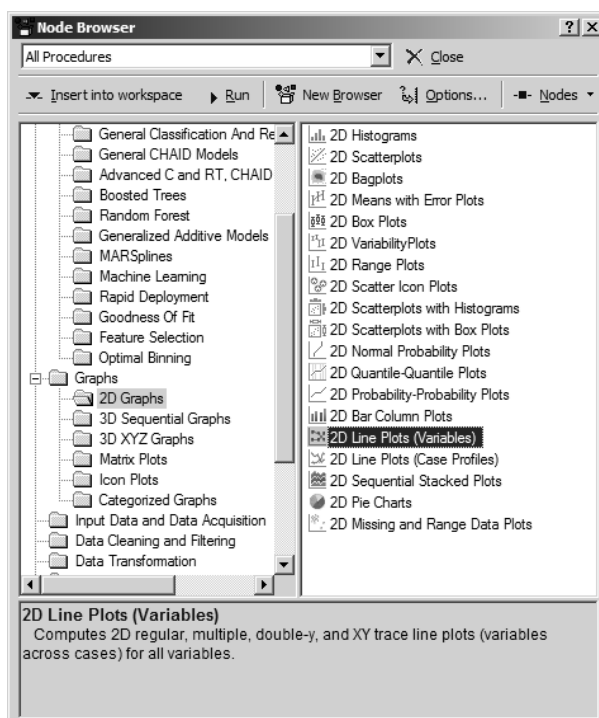


Рисунок 3.26 – Добавление Линейного графика

Выберем 2D Line Plots (Variables) - 2М Линейный график (для переменных) и переместите в рабочую область Data Miner. Таким образом в рабочее окно добавлена процедура построения двумерного линейного графика для переменной SERIES_G.

Выберем узел нейронные сети *STATISTICA - STATISTICA Automated Neural Networks (SANN)*. Заметьте, можно выбрать созданную ранее сеть (*custom neural networks*) или создать новую сеть (рис. 3.27).

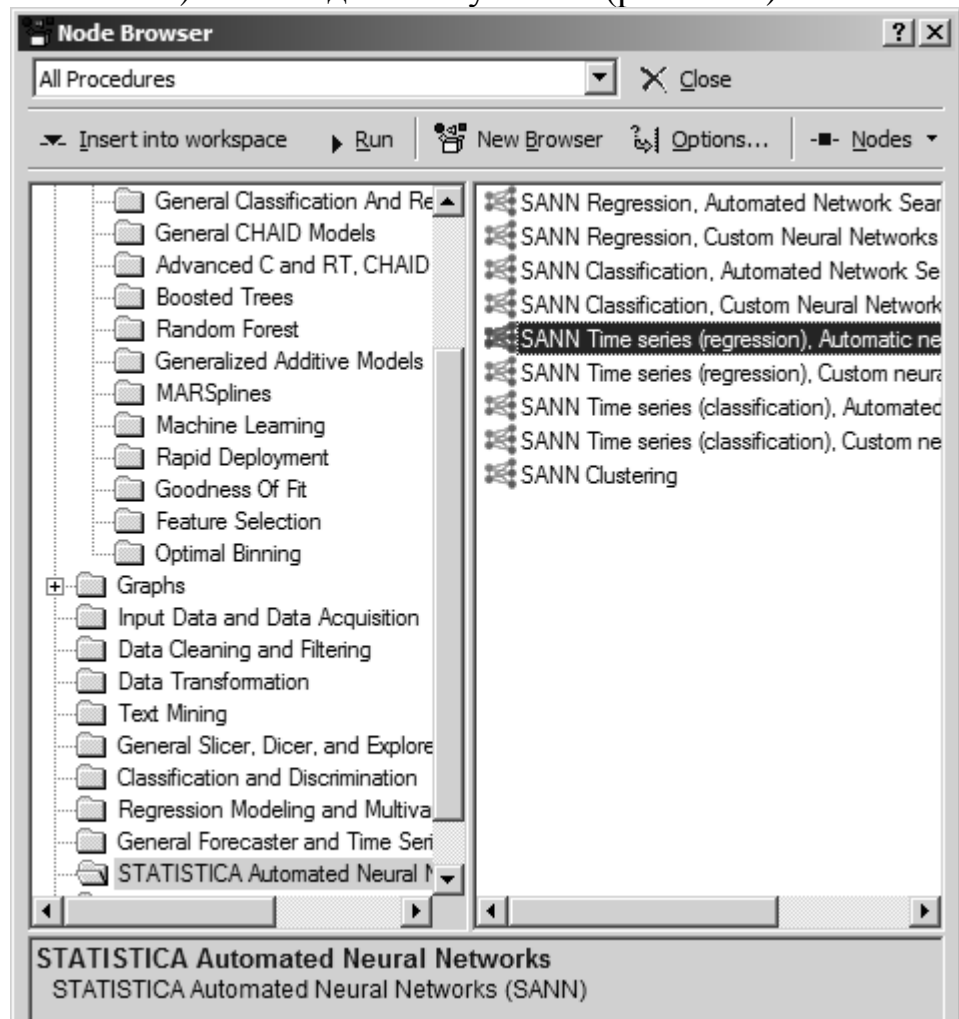


Рисунок 3.27 – Добавление построения прогноза временных рядов

Соедините выбранные элементы с помощью кнопки Connect, как показано на рис. 3.28.

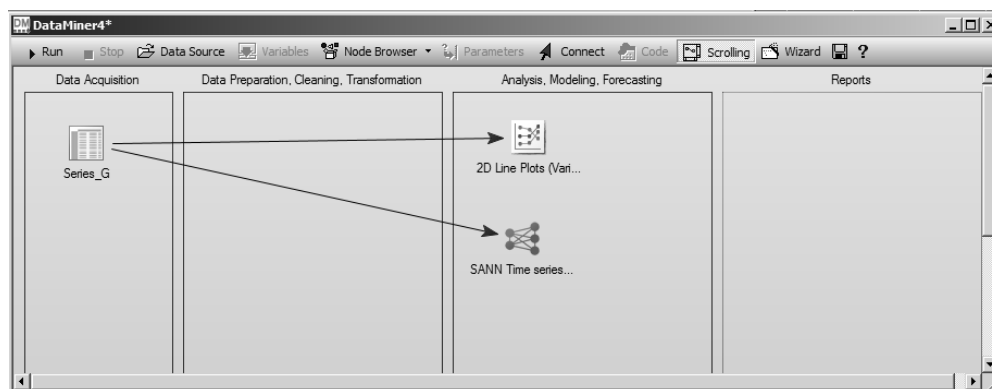


Рисунок 3.28 – Связь добавленных анализов и источника данных

Шаг 4. Определение параметров прогноза. В этом окне мы определяем количество входов сети, длину проекции, начало проекции, число шагов, на которые необходимо построить прогноз.

Дважды щелкнем по иконке анализа временных рядов, откроется окно настроек (рис. 3.29).

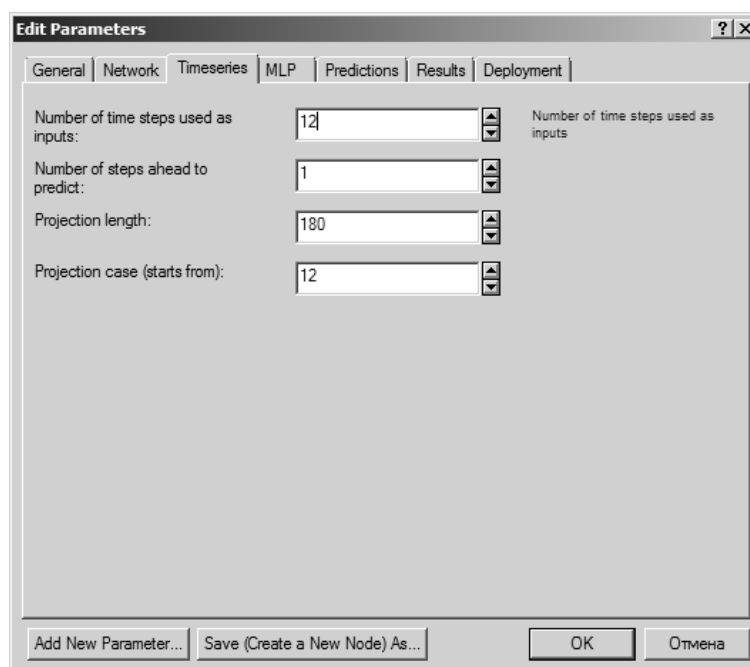


Рисунок 3.29 – Окно настроек для анализа временных рядов

Вкладки открывшегося окна похожи на вкладки окон Отбор данных и Автоматизированные Нейронные Сети, выставим значения параметров, которые мы использовали ранее, нажмем кнопку ОК.

Шаг 5. Запуск анализов и получение результатов. Нажмем кнопку Run - Выполнить для запуска вычислений. Система проведет вычисления и представит результаты в виде рабочих книг (рис. 3.30). В результате сформированы две рабочие книги.

В первой книге содержится построенный Линейный график для переменной SERIES_G.

Во второй рабочей книге содержатся таблицы и графики, предлагаемые в окне результатов модуля Нейронные сети.

Проведенный анализ можно углубить и использовать методы, реализованные в модуле Анализ временных рядов.

В этом модуле реализованы классические процедуры прогнозирования временных рядов, авторегрессия и проинтегрированное скользящее среднее (АРПСС), сезонная декомпозиция, экспоненциальное сглаживания. Легко добавить эти процедуры в рабочую область Data Miner и построить прогноз альтернативными методами.

Далее с помощью процедуры *кросс-проверки* можно найти модель, обеспечивающую наилучшую точность.

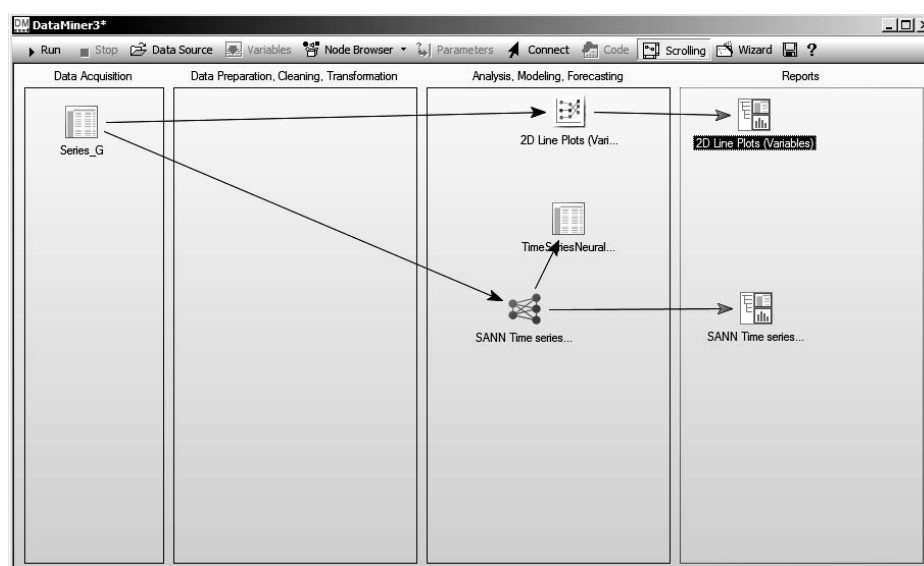


Рисунок 3.30 – Результаты работы Data Miner

Выводы. Мы рассмотрели лишь небольшую часть возможностей модуля Автоматизированные Нейронные Сети *STATISTICA* и сделали первые шаги в познании этого метода анализа данных.

Целью этой главы являлось показать возможность проведения анализа с использованием *STATISTICA Data Miner*. Всего нескольких нажатий кнопок позволило провести анализ - от определения исходных данных до построения прогноза.

Конечно, это учебный пример, серьезные проекты, например, в геологии или телекоммуникациях требуют серьезных усилий и понимания предметной области исследования.

ЗАКЛЮЧЕНИЕ

В этом исследовании мы сравнили различные методы сжатия с алгоритмом итерационного сжатия длины, который обеспечивает резервное копирование хранилища и оптимизацию базы данных в режиме реального времени для достижения более высокой эффективности с лучшей производительностью. Анализ и экспериментальные результаты показывают, что итеративные алгоритмы имеют лучшую производительность, чем традиционные алгоритмы.

Таким образом, результаты, полученные в ходе проведенных исследований, позволяют сделать вывод о том, что даже простейшая и наиболее универсальная архитектура ИНС существенно превосходит системы с применением численных методов оценки классифицирующего признака для сжатия какой либо информации.

В результате экспериментов установлено, что нейронные сети могут работать эффективно в области распознавания изображений.

Мы рассмотрели лишь небольшую часть возможностей программы *SOFT STATISTICA NEURAL NETWORKS* и сделали первые шаги в познании этого метода анализа данных.

Целью 3 главы являлось показать возможность проведения анализа с использованием *SOFT STATISTICA NEURAL NETWORKS* и *STATISTICA Data Miner*. Всего нескольких нажатий кнопок позволило провести анализ - от определения исходных данных до построения прогноза.

Считаем, что дальнейшее развитие методов использования нейронных сетей в сжатии телеметрической информации в космических технологиях, а также создания алгоритмов их обучения является одним из важных аспектов проблем в работе большими данными.

Результаты работы и часть их интерпретации были опубликованы в Научном журнале Санкт-Петербургского аналитического центра (№2423-10 9-10 декабрь 2019 года) под названием «Перспективы использования нейронных сетей для сжатия данных».

Перечень сокращений

ИНС – искусственные нейронные сети
ИИ – искусственный интеллект
МПР – метод прямого решения
МСП – многослойный персептрон
ПК – персональный компьютер
ФИТ – формат изображений тегами
ТМИ – телеметрическая информация
КА – космический аппарат
ДДЗЗ – данные дистанционного зондирования Земли
ДЗЗ – дистанционно зондирование Земли
ИСО – ISO International Organization for Standardization
АРПСС - авторегрессия и проинтегрированное скользящее среднее
РАД – разведочный анализ данных
SANN – Statistica Automated Neural Networks
CCSDC – Consultative Committee for Space Data Systems –
Консультативный Совет по космическим системам передачи данных

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Дони Р. Д. и Хайкин С., Нейросетевые подходы к сжатию изображений. Материалы IEEE, 1995, Vol. 23, № 2, с. 289-303.
2. Namphol, A. et al., Image Compression with a Hierarchical Neural Network, IEEE Transactions on Aerospace and Electronic Systems, 1996, Vol. 32, No. 1, pp. 327-337.
3. Jiang, J., (1996), A Neural Network Design for Image Compression and Indexing. International Conference on Artificial Intelligent Expert Systems and Neural Networks, Hawaii, USA, 1996, pp 296-299.
4. Гелен Р. и Сунгар М., «Обучение случайным сетям и сжатие изображений с использованием искусственных нейронных сетей», 1996, том 6, IEEE, стр. 3996-4001.
5. Верма Б., Быстрое обучение многослойных персептронов, IEEE Trans. на нейронных сетях, 1997, Vol. 8, № 6, с. 1314-1321.
6. Nelson, M., The Data Compression Book, M & T Publishing Inc. 1991
7. Цзян, Дж. [Jiang, J.], (1996), Проект нейронной сети для сжатия и индексации изображений. Международная конференция по искусственным интеллектуальным экспертным системам и нейронным сетям, Гавайи, США, с. 296-299.
8. Йоутсенсало, Дж. [Joutsensalo, J.], (1994), Нелинейное сжатие и представление данных путем объединения самоорганизующейся карты и правила подпространства, IEEE Международная конференция по нейронным сетям, том 2, стр. 637-642.
9. Блюменштейн М. [Blumenstein, M.] (1996), Распознавание печатных и рукописных почтовых адресов с использованием искусственных нейронных сетей, диссертация, Университет Гриффит, Австралия.
10. Нельсон, М. [Nelson, M.], (1991), Книга сжатия данных, M & T Publishing Inc.
11. Гелен Р. и Сунгар М, [Gelene R., and Sungar, M.], (1994), «Обучение случайным сетям и сжатие изображений с использованием искусственных нейронных сетей», том 6, IEEE, стр. 3996-4001.
12. Сикуранса Г.Л., Рампони Дж. И Марси С. [Sicuranza, G.L., Ramponi G, и Marsi S.], (1990), Искусственная нейронная сеть для сжатия изображений, электронные письма, стр. 477-479.
13. Эш Т. , [Ash, T.], (1989), Создание динамических узлов в сетях обратного распространения, Нейронные сети, стр. 365-375.
14. Кенью С. К. [Kenue S. K.], (1992), Модифицированная нейронная сеть обратного распространения с приложениями к сжатию изображений, SPIE Vol.1709, Приложения искусственных нейронных сетей, стр. 394-401.

15. *Карбонара М., Фаулер Дж. И Ахалт С.* [Carbonara, M., Fowler J., and Ahalt, S.] (1992). Сжатие цифровых видеоданных с использованием искусственного нейронного сетевого дифференциального векторного квантования, SPIE Vol. 1709, Приложения искусственных нейронных сетей, с. 422-433.
16. *Мин К. и Мин Г. Min,* [K., and Min, H.] (1992). Сжатие изображений на основе нейронной сети с использованием AMT DAP 610, SPIE Vol. 1709, Применение искусственных нейронных сетей, с. 386-393.
17. *Хамбаба М., Коффи Б. и Хемлани Н.* [Hambaba, M., Coffey B., and Khemlani, N.] (1992), Кодирование изображений с использованием системы распознавания на основе знаний, SPIE Vol. 1709. Применение искусственных нейронных сетей.
18. *Верма Б.* [Verma, B.], (1997), Быстрое обучение многослойных персептронов, IEEE Trans. на нейронных сетях, Vol. 8, № 6, с. 1314-1321.
19. *Оджа, Э.* [Oja, E.], (1991), Сжатие данных, извлечение признаков и автоассоциирование в нейронных сетях с прямой связью в искусственных нейронных сетях, (Eds) Kohonen et al., Elsevier Science Publishers, стр. 737-745.
20. *Дони Р. Д. и Хайкин С.* [Dony, R. D., and Haykin, S.], (1995). Нейросетевые подходы к сжатию изображений. Материалы IEEE, Vol. 23, № 2, с. 289-303.
21. *Каррато, С.* [Carato, S.], (1992), Нейронные сети для сжатия изображений, Нейронные сети и приложения 2, (Ed) Gelenbe E., Elsevier Science Publishers, стр. 177-198.
22. *Мужо, М.* [Mougeot, M. et al.], (1991), Сжатие изображений с обратным распространением: улучшение визуального восстановления с использованием различных функций стоимости, Нейронные сети, том 4., с. 467-476.
23. *Нампхол, А.* [Namphol, A. et al.], (1996), Сжатие изображений с помощью иерархической нейронной сети, IEEE Транзакции в аэрокосмической и электронной системах, Vol. 32, № 1, с. 327-337.
24. Современная телеметрия в теории и на практике: учебный курс. СПб. : Наука и техника, 2007.
25. *Dem'ianov A.V.* . Tekhnologii razrabotki aviatcionny`kh sistem s kritichny`mi trebovaniiami k bezopasnosti. – МКА – No 3. – 2007. – S. 84-86.
26. CCSDS 650.0-B-1 Reference Model for an Open Archival Information System (OAIS). Blue Book. Issue 1. Washington, D.C.: CCSDS, September 2007
27. *В.В. Ганченко, А.А. Дудкин, А.В. Инютин, Е.Е. Марушко, Л.П. Поденок* - Программная нейросетевая система контроля космической телеметрии, ISSN 1561-5359, «Искусственный интеллект», 2013 No 4.

ПРИЛОЖЕНИЯ А. Оттиски опубликованных статей



21 ЯНВАРЯ 2020 ГОДА
СЕРИЯ И НОМЕР СЕРТИФИКАТА
77 S.J № 00002

О ПУБЛИКАЦИИ СТАТЬИ В ЖУРНАЛЕ
НАУЧНЫЙ ЖУРНАЛ

№ 1(46) январь 2020 г

СВИДЕТЕЛЬСТВО ФЕДЕРАЛЬНОЙ СЛУЖБЫ ПО НАДЗОРУ В СФЕРЕ СВЯЗИ, ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ
И МАССОВЫХ КОММУНИКАЦИЙ (РОСКОМНАДЗОР) ПИ № ФС 77-63075
МЕЖДУНАРОДНЫЕ СТАНДАРТНЫЕ СЕРИЙНЫЕ НОМЕРА: ISSN PRINT 2413-7081, ISSN ONLINE 2542-8801

ОБЛАДАТЕЛЬ СЕРТИФИКАТА

Саттыбалдиев Акжал Абдикерим
магистрант, кафедра электроники, телекоммуникации и космической технологии,
факультет космической техники и технологий;

Паштаев Ерлан Паштаевич
профессор, кандидат технических наук, заведующий кафедрой,
кафедра электроники, телекоммуникации и космической технологии,
Казахский национальный исследовательский технический университет им. К.И. Сатпаева,
г. Алматы, Республика Казахстан

СТАТЬЯ

**АНАЛИЗ ПРАКТИЧЕСКОГО ПРИМЕНЕНИЯ НЕЙРОСЖАТИЯ
ДЛЯ ТЕЛЕМЕТРИЧЕСКИХ ЗАДАЧ КОСМИЧЕСКОГО НАЗНАЧЕНИЯ**

РАСПОЛОЖЕНИЕ СТАТЬИ В АРХИВЕ ЖУРНАЛА
<http://scientificmagazine.ru/layout/arkhiv-zhurnala.html>

ГЛАВНЫЙ РЕДАКТОР



ВАЛЫЦЕВИЧ В.

ИЗДАТЕЛЬСТВО «ПРОБЛЕМЫ НАУКИ». УЧРЕДИТЕЛЬ ООО «ОЛИМП»



Санкт-Петербургский Центр Системного Анализа

ДИПЛОМ

I степени

**Сатыбалдиеву Акжол Адікерұлы
Таштай Ерлану Таштаевичу**

вручается за доклад по теме:

*«Перспективы использования нейронных сетей
для сжатия данных»*

на Международной научно-практической конференции

*«Синергия науки и практики в контексте
инновационных прорывов в развитии экономики
и общества: национальный и международные
аспекты»*

Направление – Информационные технологии

9-10 декабря 2019 года

г. Санкт-Петербург

*Генеральный директор
«Санкт-Петербургского
Центра Системного Анализа»,
канд. экон. наук, доцент*



Сусина Н.Н.

Санкт-Петербургский Центр Системного Анализа

Сертификат

Настоящим удостоверяется, что

**Сатыбалдиев Акжол Адикерулы
Таштай Ерлан Таштаевич**

приняли участие в

Международной научно-практической конференции

*«Синергия науки и практики в контексте
инновационных прорывов в развитии экономики
и общества: национальный и международные
аспекты»*

Направление – Информационные технологии

9-10 декабря 2019 года

г. Санкт-Петербург

*Генеральный директор
«Санкт-Петербургского
Центра Системного Анализа»,
канд. экон. наук, доцент*

*Лицензионный
Договор с eLibra.ru
№2423-10/2014К*



Сисина Н.Н.