

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«КУБАНСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ»
(ФГБОУ ВО «КубГУ»)

Факультет компьютерных технологий и прикладной математики
Кафедра анализа данных и искусственного интеллекта

Допустить к защите
Заведующий кафедрой
д-р тех. наук, доцент

_____ А.В. Коваленко

15.06.22

2022 г.

Руководитель ООП

д-р физ.-мат. наук, профессор


_____ М.Х. Уртенев

15.06.22

2022 г.

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА
(МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ)

ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ И
ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ ОЦЕНКИ
КРЕДИТОСПОСОБНОСТИ ПРЕДПРИЯТИЙ

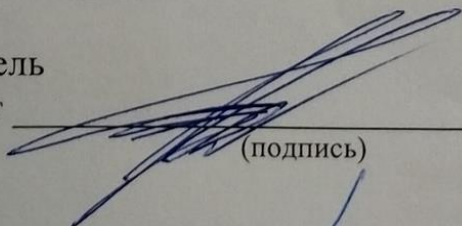
Работу выполнил _____  _____ Н.Ю. Колесниченко
(подпись)

Направление подготовки 01.04.02 Прикладная математика и информатика

Направленность (профиль) Математическое и информационное обеспечение
экономической деятельности

Научный руководитель

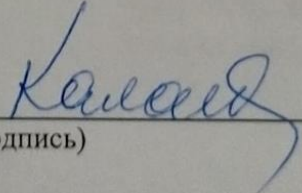
д-р тех. наук, доцент

_____  _____
(подпись)

А.В. Коваленко

Нормоконтролер

канд. физ.-мат наук, доцент

_____  _____
(подпись)

Г.В. Калайдина

Краснодар
2022

РЕФЕРАТ

Выпускная квалификационная работа (магистерская диссертация) 69 с., 3 ч., 26 рис., 15 источников.

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ, КРЕДИТОСПОСОБНОСТЬ, НЕЙРОННЫЕ СЕТИ, STATISTICA, STATISTICA NEURAL NETWORKS

Нейронная сеть создана для предоставления доступного инструмента оценки кредитоспособности предприятий.

Объектом исследования выступают предприятия различной формы собственности отраслевой принадлежности.

Цель работы – создание и обучение нейронной сети, позволяющей оценить рейтинг кредитоспособности предприятия в соответствии с национальной рейтинговой шкалой.

В процессе работы была изучена литература по анализу основных финансовых показателей и их использованию для оценки кредитоспособности предприятия.

На основе изученного реализована нейронная сеть для оценки кредитоспособности предприятия.

СОДЕРЖАНИЕ

Введение.....	4
1 Кредитоспособность предприятия	7
1.1 Понятие кредитоспособности	7
1.2 Основные методы анализа кредитоспособности предприятия.....	12
2 Нейронные сети.....	24
2.1 Общие сведения	24
2.2 Математические модели	25
2.3 Искусственные нейронные сети.....	26
2.4 Многослойный персептрон	28
2.5 Обучение нейронных сетей	30
3 Реализация программы.....	34
3.1 Особенности работы с пакетом Statistica Neural Networks	35
3.2 Создание набора данных.....	36
3.3 Создание сети.....	40
3.4 Обучение сети	44
3.5 Анализ обученной сети	50
Заключение	53
Список использованных источников	55
Приложение А	57
Приложение Б.....	66

ВВЕДЕНИЕ

Искусственный интеллект (Artificial Intelligence) как научная дисциплина возникла в 1950-х годах на стыке кибернетики, лингвистики, психологии и программирования. Основная задача искусственного интеллекта – воссоздание (имитация) с помощью искусственных устройств когнитивных действий человека.

С момента создания искусственные нейронные сети широко используются для решения технических и практических задач, а также при изучении функциональных возможностей мозга. Нейронные сети нашли свое применение в большом количестве программ, где используются для прогнозирования, распознавания по образам, сжатия данных, а также в задачах управления и так далее.

Задачи прогнозирования являются важнейшим направлением применения искусственных нейронных сетей. К ним относят задачи финансовой отрасли, такие как прогнозирование курса валют и курса ценных бумаг на фондовом рынке, прогнозирование цен на товары, предсказание платежеспособности, состоятельность молодой компании. С помощью прогнозирования обнаруживают случаи страхового мошенничества и мошенничества при банкротстве.

Обобщая все вышесказанное, можно утверждать, что искусственные нейронные сети можно применять для решения задач в которых невозможно применение статистических методов анализа из-за недостатка данных, а также для решения задач, для решения которых нет адекватной математической модели.

В практической жизни широко применяются схемы кредитования, аудит и методы антикризисного управления, а оценка экономического, финансового состояния предприятия и оценка кредитоспособности предприятия, является важной практической задачей и актуальной научной проблемой.

Проблема использования и разработки новых инструментальных и математических средств анализа, таких как нейронные сети, гибридные сети, методы нечетких множеств, так же как и классический аппарат теории вероятности и случайных процессов, особенно важна для малых и средних предприятий, так как для наиболее точной оценки финансового состояния предприятий необходимы, помимо количественных показателей, качественные показатели.

Большое количество научных работ посвящено созданию и применению моделей и методов нейронных сетей, нечётких множеств для оценки финансового состояния разных предприятий, но такие вопросы и проблемы как: оценка состояния предприятия, оценка кредитоспособность предприятия нейронными сетями, анализ количественных характеристик и анализ качественных характеристик, имеющих прямое влияние на состояние предприятия, до сих пор остаются мало исследованными.

Учитывая тот факт, что на состояние предприятия влияет внешняя рыночная среда, с конъюнктурными возмущениями, которые имеют неопределенность как в классическом понимании статистической природы, так и в лингвистическом, а классических методов статистического анализа оказывается недостаточно (регрессионный анализ, дискриминатный анализ, канонический анализ, факторный анализ и т.д.) данная проблема имеет комплексный характер.

Подводя итог вышесказанному, тема выпускной квалификационной работы посвященной созданию и использованию нейросетевых технологий для исследования и оценки финансово-экономического состояния предприятия, является актуальной.

Выпускная квалификационная работа состоит из введения, трех глав, заключения, списка цитируемой литературы и двух приложений.

В главе 1 исследуются теоретические основы и понятийный аппарат, а также проводится эмпирический анализ работ, посвященных современным

математическим моделям и методам, используемым в оценке кредитоспособности предприятия.

Во второй главе выпускной квалификационной работы представлены краткие сведения об интеллектуальных системах и искусственных нейронных сетях.

В третьей главе подробно описано построение и обучение нейронной сети в пакете Statistica Neural Networks, с помощью которой оценивалась кредитоспособность предприятий малого и среднего бизнеса РФ. А также показано, что построенная сеть практически с нулевой погрешностью относит предприятие к одной из шести используемых для оценки категорий. Это означает, что нейронная сеть обучена правильно и может использоваться для решения поставленной задачи.

В заключении подведены основные итоги исследований, проведенных в выпускной квалификационной работе.

1 Кредитоспособность предприятия

1.1 Понятие кредитоспособности

Одним из самых прибыльных направлений в работе банков становится кредитование, в особенности только начинающего развиваться реального сектора. Однако же достаточно серьезные проблемы возникают при выдаче кредитов реальному сектору российской экономики.

Большинство российских предприятий, будучи недостаточно финансово обеспеченными и пребывая в неустойчивом финансовом состоянии, решают прибегнуть к банковским кредитам. Выдача же кредитов для банков напрямую связана с риском, который оказывается под влиянием факторов внешней и внутренней среды. В таком случае банкам необходимо иметь реальное представление о том, насколько большой риск представляет из себя выдача кредитных средств определенному хозяйствующему субъекту. Поэтому для банка также очень важно решить насколько безопасным является решения о выдаче кредита.

Таким образом можно с уверенностью сказать, что есть некоторая необходимость в некоторой системе оценки финансового состояния заемщика, а также того, насколько рискованным может быть предоставление ему кредита и это одна из тех задач, которые банк может решить, основываясь на свою кредитную политику.

Большое разнообразие отечественных и зарубежных методик оценки и анализа кредитоспособности говорит нам о том, что при оценке кредитоспособности заемщика, одним из основных направлений для анализа его состояния является финансовый анализ.

Однако же состав финансовой оценки и анализа кредитором заемщика и также его основные аспекты, отличаются от характеристик анализа, который проводит сама компания. Для того, чтобы выявить свои слабые стороны, банки проводят финансовый анализ с меньшим уровнем детализации, так как

главными целями, стоящими перед банком, являются оценка уровня риска заемщика финансовой устойчивости и оценка его кредитоспособности на протяжении всего времени действия кредитного договора. В данном случае коммерческие банки сами устанавливают определенный набор финансовых показателей, а также их нормативные значения.

Кредитоспособность предприятия оценивается перед тем как принять решение о выдаче кредита, а также на каких условиях можно предоставить кредит. Ответ на вопрос, есть ли у заемщика финансовая возможность выполнять свои обязательства перед кредитором (банком) в указанный срок и в полном объеме, определяется по составу и содержанию показателей, на основе которых кредитор судит о финансово-хозяйственном положении заемщика и используемых показателей в анализе финансового состояния заемщика. Отсюда следует, что содержание оценки кредитоспособности заемщика состоит из исследования множества факторов, оказывающих прямое и косвенное влияние на вероятность погашения или невозврата кредита.

Оценка кредитоспособности заемщика является всего лишь одним из многих элементов, которые используются при анализе финансово-экономического состояния предприятия [1]. Наиболее полный анализ взаимосвязи элементов проведен в работе Ендовицкого Д.А. и Бочаровой И.В. [2]. Прямое воздействие на кредитоспособность предприятия оказывает финансовое и экономическое состояние заемщика, которое показывает состояние личного и заёмного капитала, эффективность использования капитала, финансовую устойчивость, возможности платежеспособности и распределение капитала между разными видами собственности.

Однако, только по кредитоспособности невозможно в полной мере определить финансовое и экономическое состояние предприятия, так как взаимоотношение банков и заёмщиков имеет достаточно своеобразный характер, произвести учет специфики, которого нельзя, проводя анализ только финансово-экономического состояния предприятия. Исходя из всего

вышесказанного, необходимо отдельно проводить анализ возможностей кредитоспособности заемщика.

Анализ ряда работ [3, 4, 5, 6], демонстрирует, всю сложность и неоднозначность проблемы оценки кредитоспособности заемщика и самого термина «кредитоспособность», которые подвергались изучению и разрабатывались в разные времена, различными авторами, которые использовали крайне отличающиеся подходы к определению понятия «кредитоспособность».

В большинстве определений практически не разграничиваются понятия «кредитоспособность» и «платежеспособность». Под «платежеспособность» понимается возможность предприятия расплачиваться по выбранным видам обязательств, а «кредитоспособность» определяется как способность и возможность расплатиться только по кредитным обязательствам. Платежеспособность – это возможность выполнить требования кредиторов в текущий момент времени, а кредитоспособность – это прогнозирование возможности выполнять требования кредиторов в будущем.

Весомым различием выступает то, что предприятие гасит свои обычные обязательства (за исключением кредитной задолженности), обычно, после получения выручки от реализации продукции (работ, услуг). Возвратить кредитные средства можно из собственных средств заемщика, а также с использованием средств, поступивших на счет предприятия после того, как банк реализовал обеспечение, предоставленного в залог, средств гаранта или поручителя, страховых выплат или с использованием перекредитования.

Судя по всему, в данный момент, с учетом всех факторов на российском рынке сложившихся в настоящее время, мы будем понимать под кредитоспособностью заемщика – совокупность правовых и финансовых характеристик, которые описаны посредством количественных и качественных, финансовых и нефинансовых показателей, что также дает возможность дать оценку его способности в будущем в полном объеме, а также в срок, предусмотренный условиями кредитного договора, рассчитаться

по своим долговыми обязательствам перед кредитором, а также определяющую степень риска банка при кредитовании конкретного заемщика.

В качестве следствия экономической деятельности предприятия может быть сформирована оценка его кредитоспособности, по которой можно также сказать о:

- рациональности комбинирования собственных и заемных источников;
- результативность производственно-финансовой деятельности;
- степени грамотности и эффективности управления менеджментом финансовыми ресурсами;
- эффективность использования собственного капитала;
- характере сотрудничества с партнерами в лице других организаций, кредиторов, бюджета, акционеров и пр.

В итоге, возможность организации участвовать в конкуренции, экономический потенциал организации, в основном определяется через кредитоспособность. Обладая данными о кредитоспособности заемщика, кредитор уменьшает свои риски потерь из-за возможных финансовых проблем, возникших у предприятия: срывов договоров и неисполнения платежей. Для заемщика же обладание информацией связанная с платежеспособностью и устойчивостью финансов, дает возможность и основу для разработки стратегий решения и обеспечения финансовыми ресурсами, которые могут быть направлены на развитие предприятия.

Принцип системности используется для рассмотрения кредитоспособности заемщика и является одним из главных принципов. Это значит, что анализ кредитоспособности выступает в качестве системы, включающей взаимосвязанные элементы более низкого уровня, и в то же время сам играет роль элемента системы более высокого уровня, взаимодействующего с другими подсистемами в комплексном экономическом анализе.

Возникновение большой потребности в проведении качественного экспресс-анализа по множеству факторов обуславливает применение всевозможных методов для оценки состояния предприятия. Анализ денежных потоков наравне со всем разнообразием экспресс-методик используется при оценке финансового состояния. В одном ряду с качественными характеристиками, внешними и внутренними факторами, оказывающими влияние на бизнес, кредитором также оцениваются и численные показатели, имеющие практическую ценность в оценке состояния предприятия.

Из-за недостатка единой нормативной базы для разных отраслей экономики, осуществимость полноценного анализа сильно ограничена. Нет также отраслевых справочников или классификаторов, позволяющих с полной уверенностью отнести то или иное предприятие-заемщик к определенному классу кредитоспособности с учетом его отраслевых особенностей, а также предоставляющих банкам возможность дать оценку своим рискам при предоставлении кредитных средств. Сейчас коммерческие банки используют информационную базу, которую они составили лично. В этой информационной базе приоритет отдается репутации заемщика и кредитной истории, но не финансовым возможностям заемщика.

Подводя итог всему вышесказанному, мы можем сделать вывод, что в России назрела необходимость в разработке и составлении единой нормативной базы, которая могла бы помочь в определении кредитоспособности заемщиков. Дать большому кругу лиц возможность доступа к рейтингу хозяйствующих субъектов, который включает в себя определенный набор частных показателей, а также расчет интегрального показателя, учитывающего влияние на кредитоспособность коммерческой организации различных количественных и качественных факторов.

1.2 Основные методы анализа кредитоспособности предприятия

Возникновение большой потребности в проведении качественного экспресс-анализа по множеству факторов обуславливает применение всевозможных методов для оценки состояния предприятия.

Для оценки текущей и потенциальной финансово-экономической ситуации в организации, а также вероятности ее неплатежеспособности или банкротства проводится анализ ее состояния, который представляет собой метод накопления, преобразования и последующего использования сведений числового и категориального вида.

В работе [7] описывается классификация методов оценки кредитоспособности заемщика, основная идея которой заключается в разбиении на группы экспертных методов оценки и автоматизированных систем оценки, которые в свою очередь делятся на методы линейного программирования, статистические методы, генетических алгоритмов и нейронных сетей и нечётко-множественные методы. В связи с тем, что составляющей процедуры оценки кредитоспособности заёмщика также является оценка финансового состояния предприятия, допустимо предположить возможность использования соответствующей классификации (с некоторыми преобразованиями) в качестве одного из способов классификации широко применяемых в анализе состояния предприятия математических методик. Поэтому мы предлагаем классифицировать существующие математические методики, широко используемые в процессе оценки состояния предприятия для обнаружения их основных преимуществ и недостатков, на следующие группы методов:

- методы многомерного статистического анализа;
- нейросетевые технологии;
- нечёткие продукционные системы;
- методы, основой которых служат на математические модели.

В свою очередь каждая из этих групп делится на подгруппы методов, причем некоторые методы могут быть использованы в разных группах, так, например, генетические алгоритмы могут использоваться самостоятельно, либо для оптимизации работы нейронных сетей, а являющийся составной частью методов многомерного статистического анализа, дискриминантный анализ, может быть использован для оценки коэффициентов в модели Альтмана.

Многомерные статистические методы анализа состояния предприятия являются одними из широко используемых методов.

Неизбежным является то, что наблюдения подвержены многочисленным случайным возмущениям, непредсказуемый, вероятностный характер, которых проявляется на всех этапах, начиная с процесса получения самих наблюдений и кончая процессом принятия решения, данная особенность реальных систем практически не учитывается в других детерминистских (перцептральных), синтаксических (лингвистических), логических и прочих системах оценки состояния предприятия. Следовательно, реализациями случайных величин являются дестабилизирующие факторы в статистических методах оценки состояния предприятия. Из этого можно сделать вывод, что разработка адекватных исследуемым процессам методов оценки состояния предприятия неизбежно связана с исследованием случайных отображений, что оказывается возможным если брать за основу статистические методы.

Из этого также следует, что «статистические методы оценки состояния предприятия позволяют отразить структуру и особенности проявления исследуемых объектов через описывающие их признаки, как при обучении, так и при принятии решений с учетом всех дестабилизирующих факторов, и количественно описать указанные процессы, используя хорошо развитые методы математической статистики». Это создает основу для количественного выражения основных параметров оценки состояния предприятия – размерности признакового пространства, времени обучения и принятия

решения через главный показатель качества системы – достоверность оценки состояния предприятия, что в свою очередь позволяет реализовать в статистических системах гарантированную достоверность.

Наиболее удобными методами многомерного статистического анализа, которые вполне могли бы использоваться для оценки финансового состояния предприятия являются кластерный, дискриминантный, факторный и регрессионный анализ.

В качестве цели при использовании дискриминантного анализа выступает классификация (причисление одной из категорий) объекта, учитывая различные характеристики, оптимальным способом. В данном случае оптимальным считается способ, при котором минимальны либо математическое ожидание потерь, либо вероятность ложной классификации

Весьма широко используемым в экономических исследованиях является кластерный анализ. В то же время для исследования состояния предприятия его возможности используются недостаточно. Этот вид анализа позволяет разделить множество признаков и объектов исследования на однородные группы по множеству случайных признаков.

Понятие расстояния (метрики) между векторами измерений определяет различия и сходства объектов, в зависимости от расстояния между объектами, можно определить их сходство. Наиболее часто применяемые в исследованиях функции расстояний: Евклидово расстояние, степенное расстояния Минковского, квадрат евклидова расстояния, манхэттенское расстояние городских кварталов, процент несогласия, расстояние Чебышева и далее.

Алгоритмы кластерного анализа можно подразделить на агломеративные и итеративные дивизивные процедуры, неиерархические и иерархические (древовидные).

Факторный анализ понимается в современной статистике как комбинация методов, позволяющих выявлять латентные (неявные) обобщающие факторы, которые могут повлиять на оценку состояния

организации основываясь на реально существующих связях объектов (или признаков).

Регрессионный анализ – один из наиболее эффективных методов математической статистики, предназначенный для определения аналитического выражения вероятностной зависимости между исследуемыми признаками. Многомерный количественный регрессионный анализ данных позволяет изучить влияние номинальных признаков путём кодирования градаций предикторов дихотомическими переменными, которые принимают значение 1 для респондентов, принадлежащих соответствующей градации и значение 0 для остальных.

Классические модели оценки состояния предприятия условно можно разделить на количественные и качественные. Рассмотрим количественные методы оценки состояния предприятия.

В настоящее время в мировой учетно-аналитической практике известны десятки показателей, используемых для количественной оценки состояния предприятий. Классифицируя эти показатели, выделяют обычно шесть групп, описывающих имущественное положение компании, ее ликвидность, финансовую устойчивость, деловую активность, рентабельность, положение на рынке ценных бумаг. Так как состояние предприятия определяется в первую очередь показателями ликвидности, финансовой устойчивости, деловой активности и рентабельности, то в дальнейшем мы ограничимся рассмотрением этих четырёх групп:

1) показатели ликвидности и платежеспособности предприятия: величина собственных оборотных средств; коэффициент текущей ликвидности; коэффициент быстрой ликвидности; коэффициент абсолютной ликвидности; коэффициент обеспеченности текущей деятельности собственными оборотными средствами; коэффициент покрытия запасов.

2) показатели финансовой устойчивости: коэффициент финансовой автономии; коэффициент маневренности собственного капитала; коэффициент структуры долгосрочных источников финансирования;

коэффициент структуры привлеченных средств; коэффициент структуры заемных средств; коэффициент обеспеченности процентов к уплате; коэффициент покрытия постоянных финансовых расходов.

3) показатели деловой активности предприятия: коэффициент устойчивости экономического роста; коэффициент фондоотдачи; коэффициент оборачиваемости средств в активах.

4) показатели рентабельности: рентабельность совокупного капитала; рентабельность собственного капитала; рентабельность инвестиций; валовая рентабельность реализованной продукции (валовая маржа).

От частных показателей, характеризующих отдельную сторону хозяйствования компании, переходят к комплексным коэффициентам, характеризующим положение предприятия в целом.

Одной из простейших моделей прогнозирования вероятности банкротства считается двухфакторная модель [8]. Она основывается на двух ключевых показателях (показатель текущей ликвидности и показатель доли заемных средств). Используются следующая формула расчета:

$$Z = -0.3877 - 1.0736 * \text{КТЛ} + 0.579 * \text{ЗС/П},$$

где КТЛ – коэффициент текущей ликвидности и ЗС/ П – показатель удельного веса заемных средств в пассивах предприятия рассчитываются по формулам:

$$\text{КТЛ} = \frac{\text{Оборотные активы(1200)}}{\text{Краткосрочные пассивы(1500)'}}$$
$$\text{ЗС/П} = \frac{\text{Заемные средства(1510)}}{\text{Общие пассивы(1700)}}.$$

Если результат оказывается отрицательным, то вероятность банкротства невелика. Положительное значение Z указывает на высокую вероятность банкротства.

Следующей широко применяемой моделью является модель Альтмана, которая представляет собой многофакторное регрессионное уравнение:

$$Z = 1.2 * X_1 + 1.4 * X_2 + 3.3 * X_3 + 0.6 * X_4 + X_5,$$

где

$$X_1 = \frac{\text{Чистый оборотный капитал}(1300)}{\text{Общие активы}(1600)},$$

$$X_2 = \frac{\text{Нераспределенная прибыль(непокрытый убыток)}(1370)}{\text{Общие активы}(1600)},$$

$$X_3 = \frac{\text{Прибыль до налогообложения}(2300) + \text{Проценты к уплате}(2330)}{\text{Общие активы}(1600)},$$

$$X_4 = \frac{\text{Рыночная стоимость собственного капитала}}{\text{Стоимость общего долга}(1400)},$$

$$X_5 = \frac{\text{Выручка (нетто) от продажи}(2200)}{\text{Общие активы}(1600)}.$$

В зависимости от полученного значения для Z -счета можно судить об угрозе банкротства. Угроза банкротства с вероятностью 95% в течение ближайшего года у предприятия считается высокой при значениях $Z < 2,7$.

Z -коэффициент имеет общий серьезный недостаток – по существу его можно использовать лишь в отношении крупных компаний, котирующих свои акции на биржах. Именно для таких компаний можно получить объективную рыночную оценку собственного капитала.

В работе [9] показано, что веса в формуле Альтмана и пороговые интервалы сильно отличаются в зависимости от страны и от года

исследования, т.е. модель Альтмана не обладает устойчивостью к изменениям исходных данных.

Таким образом, ее можно использовать, когда исходные данные являются однородными и репрезентативными. Ключевым ограничением этого метода является уникальность и специфичность каждого предприятия, что не позволяет корректно использовать статистические вероятности.

Недостатки количественных методов ряд учёных пытается преодолеть, используя качественные методы, основанные на экспертных заключениях.

При этом надо отметить, что при анализе рассматриваются не только финансовые показатели, но и показатели, характеризующие уровень менеджмента на предприятии.

В качестве следствия экономической деятельности предприятия может быть сформирована оценка его кредитоспособности, по которой можно также сказать о:

- рациональности комбинирования собственных и заемных источников;
- результативность производственно-финансовой деятельности;
- степени грамотности и эффективности управления менеджментом финансовыми ресурсами;
- эффективность использования собственного капитала.

Рассмотрим качественные методы оценки состояния предприятия. Самым распространённым качественным методом оценки состояния предприятия является модель Аргенти (А-счет). Согласно этой методике, исследование начинается с предположений, что кризисный процесс на предприятии, ведущий к банкротству, продолжается нескольких лет и может быть разделен на три стадии. При расчете А-счета конкретного предприятия необходимо ставить либо количество баллов согласно Аргенти, либо ноль. Каждому фактору каждой стадии присваивают определенное количество баллов и рассчитывают агрегированный показатель – А-счет.

Следующим интересным методом оценки финансового состояния предприятия, но посвящённым в первую очередь оценке кредитоспособности предприятия является методика прогнозирования банкротства с учетом специфики отраслей, разработанная в [2]. В ней предлагается деление всех предприятий по классам кредитоспособности. Расчет класса кредитоспособности связан с классификацией оборотных активов по степени их ликвидности.

Особенности формирования оборотных средств в нашей стране не позволяют прямо использовать критериальные уровни коэффициентов платежеспособности (ликвидности и финансовой устойчивости), применяемых в мировой практике. Поэтому создание шкалы критериальных уровней может опираться лишь на средние величины соответствующих коэффициентов, рассчитанные на основе фактических данных однородных предприятий (одной отрасли).

Использование математических моделей для оценки состояния предприятия имеют ряд ограничений:

- 1) Модели не обеспечивают всесторонней оценки состояния предприятия, а потому возможны слишком значительные отклонения прогноза от реальности;
- 2) Модели ориентируются на какой-то один критерий, который весьма привлекателен с позиции теории, однако на практике не всегда оправдан.

Поэтому для преодоления недостатков этих методов необходимо дополнить и использовать их в комплексе с другими методами оценки состояния предприятия, такими как, нейронные сети, нечёткие множества, много мерные статистические методы, т.е. составить репрезентативную группу методов. Причем под репрезентативной группой методов, как отмечалось выше, понимается такой набор (комплекс) методов, который позволяет эффективно, адекватно и безошибочно оценить состояние любого отдельно взятого предприятия.

Нейронные сети - это новая и многообещающая вычислительная технология, существует необходимость ее развивать, чтобы в будущем получить новейшие подходы для изучения проблем экономической области. Чтобы эффективно обучить нейронную сеть и применять ее в обычной жизни, необходим большой объем данных для обучающей выборки.

Уникальность процесса обучения нейронной сети состоит в том, что в процессе обучения появляется неразрывная связь между входом и выходом.

Обучение нейронных сетей происходит с помощью использования двух типов алгоритма. Первый тип алгоритма - управляемое, второй тип алгоритма - неуправляемое. Для разных видов сетей используются разные алгоритмы обучения.

Хорошо обученная может приобрести способность формировать неизвестную функцию, которая будет объединять входные и выходные переменные. После обучения такой сети, ее можно использовать прогнозирования в ситуациях с неизвестными выходными значениями.

При оценке финансового и экономического состояния предприятия, с помощью методов многомерного статистического анализа, наблюдается некоторая схожесть с использованием нейронных сетей. Преимущество использования нейронных сетей, как инструмента оценки финансово-экономического состояния предприятия состоит в том, что взаимоотношения между величинами заранее не устанавливаются, поскольку метод предусматривает изучение существующих взаимосвязей на готовых моделях. Для нейронных сетей также не требуется никаких предположений относительно основного распределения совокупности, а также, в отличие от многих традиционных статистических методов, они могут работать с неполными данными.

Нейронные сети проявляют повышенную эффективность в случаях, когда начальные данные сильно коррелируют, либо анализируемой системе свойственна повышенная степень нелинейности.

Преимущества перед ранее разработанными статистическими методами были выявлены в ходе многочисленных исследований, затрагивающих применение нейронных сетей в финансах и бизнесе.

Вопросам сравнения двух видов анализа посвящены работы Кристоффа и Пьера Кувре, Дж. Такера и др. Подробная типизация методов экономического прогнозирования с использованием статистических методов и нейронных сетей рассматривается в работе Ханка Д.Э., Уичерна Д.У., Райтса А.Дж..

Из анализа, проведенного в указанных выше работах можно сделать вывод, что статистические методы и методы нейронных сетей прекрасно дополняют друг друга.

Оценке финансового состояния предприятия с применением нечётких нейронных систем посвящен большой ряд оригинальных разработок отечественных учёных. Среди этих работ первоочередно следует отметить работы Недосекина А.О. [9, 10], Илларионова А.В. [7] и т.д.

В работе А.О. Недосекина [9] были предложены нормы по всем частным параметрам в интегральной оценке финансово-экономического состояния предприятия, а также построена нечетко-множественная классификация параметров, введены веса показателей в интегральной оценке и рассчитана оценка финансового положения предприятия как свертка всех текущих уровней данных факторов. Это позволило получить интегральный показатель финансового состояния на интервале от 0 до 1 и пронормировать его по пенташкале, выделяя 5 состояний: «очень высокий», «высокий», «средний», «низкий» и «очень низкий» уровень комплексного показателя.

В методе строятся матрицы, в столбцах которых находятся финансовые показатели, а в строках – уровни этих показателей. На пересечении столбцов и строк находятся уровни принадлежности значений факторов тем или иным состояниям. Интегральный показатель строится по принципу двойной свертки элементов матрицы.

Значительный рост публикаций в сфере теории нечетких множеств являются прямыми доказательствами повышения интереса к этой области, а также их применению в экономических исследованиях.

Тем не менее практически неисследованными остаются вопросы и проблемы не только оценки кредитоспособности предприятия и его финансового состояния, но также и финансово-экономического состояния нечёткими производственными системами.

При оценке кредитоспособности предприятий в данной работе была использована национальная рейтинговая шкала, широко используемая отечественными рейтинговыми агентствами (АКРА, «Эксперт РА»).

Предприятия, выступающие в качестве объекта исследования поделены на шесть категорий кризисности:

- В – предприятия относящиеся к категории с низкой кредитоспособностью;
- ВВ – предприятия с умеренно низким уровнем кредитоспособности;
- ВВВ – предприятия категории умеренной кредитоспособности;
- А – предприятия с умеренно высоким рейтингом кредитоспособности;
- АА – категория предприятий с высокой кредитоспособностью;
- ААА – предприятия с наивысшим уровнем кредитоспособности.

Критериями для анализа и впоследствии отнесения предприятий к той или иной категории, являются показатели, разбитые на четыре группы:

- 1) Показатели финансовой устойчивости предприятия:
 - F1 – Коэффициент финансовой зависимости,
 - F2 – Коэффициент автономии собственных средств,
 - F3 – Коэффициент обеспеченности запасов собственными оборотными средствами,
 - F4 – Индекс постоянного актива;

- 2) Платежеспособности и ликвидности:
 - L1 – Коэффициент быстрой ликвидности,
 - L3 – Коэффициент покрытия запасов,
 - P1 – Текущий коэффициент ликвидности;
- 3) Показатели рентабельности предприятия:
 - R1 – Коэффициент общей рентабельности,
 - R2 – Коэффициент рентабельности активов,
 - R3 – Коэффициент рентабельности собственного капитала,
 - R4 – Коэффициент рентабельности продукции (продаж);
- 4) Показатели деловой активности предприятия:
 - A2 – Коэффициент оборачиваемости активов,
 - A4 – Коэффициент оборачиваемости кредиторской задолженности,
 - A5 – Коэффициент оборачиваемости дебиторской задолженности,
 - A6 – Коэффициент оборачиваемости запасов.

Данные показатели были выбраны основываясь на исследовании [10], в ходе которого анализировались бухгалтерские отчёты 400 отечественных организаций в периоде с 2000 – 2003 гг. (300-мелких и 100-крупных), были построены гистограммы исследуемых факторов и получены самые общие закономерности, которым подчиняются финансовые показатели российских предприятий.

Для данного исследования в качестве информационной базы были использованы формы отчетности 1 и 2, полученные из источников [11, 12], достоверные сведения о рейтинге исследуемых предприятий были получены из источников [13, 14]

2 Нейронные сети

2.1 Общие сведения

Искусственные нейронные сети – это вычислительные системы, которые представляют собой математическую структуру, имитирующую происходящие в мозгу человека, животных простые биологические процессы. К ним таким процессам относятся: способность к обучению и обобщению; адаптивность; низкое энергопотребление; распределенное представление информации и параллельные вычисления; толерантность к ошибкам.

При конструировании подобных сетей совершаются определенные упрощения и допущения. Искусственные нейросети показывают впечатляющий набор характеристик, свойственных мозгу. Такими характеристиками являются к примеру, обобщение, обучение на основании опыта, отделение значимой информации из избыточных сведений..

В задачах экспертной оценки нейросетевой подход является особенно эффективным, так как он сочетает в себе способность мозга к обобщению и распознаванию и способность компьютера к обработке чисел. Нейронная сеть позволяет обрабатывать независимо от наглядности большое количество факторов (до нескольких тысяч), таким образом, она может стать хорошим экспертом для вычисления адекватной оценки в любой области.

В ситуациях, где требуется определить значения неизвестных переменных или характеристик по известным данным наблюдений или измерений (сюда относятся различные задачи классификации, регрессии и анализа временных рядов), также могут использоваться методы нейронных сетей, при этом важно чтобы количество этих исторических данных было достаточным, а между неизвестными и известными значениями на самом деле существовала связь или система связей (нейронные сети довольно устойчивы к помехам). Разведочный анализ и поиск кластеров в данных является еще одним применением нейронных сетей (здесь используются сети Кохонена).

Эксперименты исследователей искусственного интеллекта по воссозданию предрасположенности биологических нервных систем к обучению и исправлению ошибок, с помощью имитации низкоуровневого строения мозга, повлекли за собой появление нейронных сетей.

Искусственный интеллект (Artificial Intelligence) как научная дисциплина возникла в 1950-х годах на стыке кибернетики, лингвистики, психологии и программирования. Основная задача искусственного интеллекта – воссоздание (имитация) с помощью искусственных устройств когнитивных действий человека.

Среди важнейших классов задач, которые ставились перед ИИ с момента его зарождения как научного направления, следует выделить следующие трудно формализуемые задачи, важные для задач робототехники: доказательство теорем, управление роботами, распознавание изображений, машинный перевод и понимание текстов на естественном языке, игровые программы, машинное творчество (синтез музыки, стихотворений, текстов).

2.2 Математические модели

Разработка адекватных с биологической точки зрения технических устройств, работающих по биологическим принципам, решается путем математического моделирования соответствующих биологических структур на всех уровнях организации нервной ткани. Популярным является подход нейросетевого моделирования, в котором сети со сложной пространственно-топологической организацией состоят из единичных нейронов, связанных синаптическими связями [15].

Искусственные нейронные сети (НС) – совокупность моделей биологических нейронных сетей. Представляют собой сеть элементов – искусственных нейронов – связанных между собой синаптическими соединениями. Сеть обрабатывает входную информацию и в процессе изменения своего состояния во времени формирует совокупность выходных

сигналов [16]. Среди важнейших классов задач, которые ставились перед ИИ с момента его зарождения как научного направления, следует выделить следующие трудно формализуемые задачи, важные для задач робототехники: доказательство теорем, управление роботами, распознавание изображений, машинный перевод и понимание текстов на естественном языке, игровые программы, машинное творчество (синтез музыки, стихотворений, текстов).

Применение для оценки состояния предприятия математических моделей влечет за собой некоторые ограничения:

- 1) Модели основываются на каком-то одном показателе, достаточно интересном с точки зрения теории, но фактически не всегда целесообразном.
- 2) Универсальная оценка предприятия не может быть обеспечена данными моделями, а потому возможны слишком значительные отклонения прогноза от реальности.

Поэтому для улучшения качества анализа и разрешения проблемы ограничений такие методы следует использовать в совокупности с прочими методами, используемыми для оценки.

2.3 Искусственные нейронные сети

Биологический нейрон – сложная система, математическая модель которого до сих пор полностью не построена. Введено множество моделей, различающихся вычислительной сложностью и сходством с реальным нейроном. Одна из важнейших – формальный нейрон (ФН), изображенный на рисунке 2.1. Несмотря на простоту нейронные сети, построенные из нейронов, могут сформировать произвольную многомерную функцию на выходе.




Рисунок 2.1 – Формальный нейрон

Нейрон состоит из взвешенного сумматора и нелинейного элемента. Функционирование нейрона определяется формулами:

$$\begin{aligned} \text{NET} &= \sum w_i x_i, \\ \text{OUT} &= F(\text{NET} - \theta), \end{aligned}$$

где NET – взвешенная сумма входных сигналов, x_i – входные сигналы, комбинация всех входных сигналов нейрона образует вектор X – вектор входных сигналов; w_i – весовые коэффициенты, комбинация всех весовых коэффициентов образует вектор весов w, θ – порог срабатывания данного нейрона; F – нелинейная функция, называемая функцией активации.

Нейрон имеет несколько входных сигналов x и один выходной сигнал OUT. Параметрами нейрона, определяющими его работу, являются: вектор весов w, пороговый уровень θ и вид функции активации F.

Модели нейрона свойственны некоторые ограничения:

1) Расчёт выходных значений нейрона полагаются мгновенными, не вносящими задержки. Соответственно конструировать динамические структуры, предполагающие наличие «внутреннего состояния», используя данный вид нейронов не представляется возможным.

2) Нервные импульсы в данной модели отсутствуют. А значит нет и модуляции уровня сигнала плотностью импульсов, как в нервной системе. Не появляются эффекты синхронизации, когда скопления нейронов обрабатывают информацию синхронно, под управлением периодических волн возбуждения-торможения.

3) Для определения оптимальной функции активации отсутствуют конкретные алгоритмы.

4) Регулирование деятельности сети является невозможным ввиду отсутствия механизмов.

5) Чрезмерная формализация понятий: «порог», «весовые коэффициенты». Данные понятия для реальных нейронов не существуют они динамически меняются в зависимости от активности нейрона и общего состояния сети. Весовые коэффициенты синапсов тоже не постоянны. «Живые» синапсы обладают пластичностью и стабильностью: весовые коэффициенты настраиваются в зависимости от сигналов, проходящих через синапс.

6) Существует большое разнообразие биологических синапсов. Они встречаются в различных частях клетки и выполняют различные функции. Тормозные и возбуждающие синапсы реализуются в данной модели в виде весовых коэффициентов противоположного знака, но разнообразие синапсов этим не ограничивается. Дендро-дендритные, аксо-аксональные синапсы не реализуются в модели формального нейрона.

7) В модели не прослеживается различие между градуальными потенциалами и нервными импульсами. Любой сигнал представляется в виде одного числа.

8) Модель формального нейрона представляет собой математическую абстракцию [16].

2.4 Многослойный персептрон

Существует множество способов комбинирования формальных нейронов в сети. Самым распространенным видом сети стал многослойный персептрон, изображенный на рисунке 2.2.




Рисунок 2.2 – Многослойный персептрон

Сеть состоит из произвольного количества слоев нейронов. Нейроны каждого слоя соединяются с нейронами предыдущего и последующего слоев по принципу «каждый с каждым». Первый слой (слева) называется сенсорным или входным, внутренние слои называются скрытыми или ассоциативными, последний (самый правый, на рис. состоит из одного нейрона) – выходным или результативным. Количество нейронов в слоях может быть произвольным. Обычно во всех скрытых слоях одинаковое количество нейронов.

Обозначим количество слоев и нейронов в слое. Входной слой: N_I нейронов; N_H нейронов в каждом скрытом слое; N_o выходных нейронов; X – вектор входных сигналов сети; Y – вектор выходных сигналов.

Есть некоторая неопределенность в расчете числа слоев сети. Входной слой не производит никаких расчетов, только распределяет входные значения, отчего в некоторых случаях он может быть учтен, а в некоторых – нет. Обозначим через N_l общее число слоев в сети, с учетом входного.

Принцип действия многослойного персептрона (МСП) задается формулами:

$$\begin{aligned} \text{NET}_{jl} &= \sum w_{ijl} x_{ijl}, \\ \text{OUT}_{jl} &= F(\text{NET}_{jl} - \theta_{jl}), \\ x_{ij(l+1)} &= \text{OUT}_{il}, \end{aligned}$$

где индексом i всегда будем обозначать номер входа; j – номер нейрона в слое; l – номер слоя; x_{ijl} – i -й входной сигнал j -го нейрона в слое l ; w_{ijl} – весовой коэффициент i -го входа нейрона номер j в слое l ; NET_{jl} – сигнал NET j -го нейрона в слое l ; OUT_{il} – выходной сигнал нейрона; θ_{jl} – пороговый уровень нейрона j в слое l .

Введем обозначения: w_{jl} – вектор-столбец весов для всех входов нейрона j в слое l ; W_l – матрица весов всех нейронов в слое l . В столбцах матрицы расположены вектора w_{jl} . Аналогично x_{jl} – входной вектор-столбец слоя l .

Каждый слой рассчитывает нелинейное преобразование от линейной комбинации сигналов предыдущего слоя. Таким образом становится очевидным, что применение линейной функции активации возможно только в сетях такой структуры, которая не требует последовательное объединение слоев нейронов. Для многослойных сетей функция активации должна быть нелинейной, иначе можно построить эквивалентную однослойную сеть, и многослойность оказывается ненужной. В случае использования линейной функции активации, выходным значением любого слоя будет линейная комбинация входных параметров. Каждый последующий слой будет давать линейную комбинацию выходных значений предыдущего слоя, что равносильно всего одной линейной комбинации с другими значениями, а значит возможна реализация в виде одного слоя нейронов [15].

Многослойная сеть может формировать на выходе произвольную многомерную функцию при соответствующем выборе количества слоев, диапазона изменения сигналов и параметров нейронов. На практике многослойные сети являют собой многофункциональный инструмент приближения функций наравне с рядами.

2.5 Обучение нейронных сетей

Искусственные нейронные сети, подобно биологическим, являются вычислительной системой с огромным числом параллельно

функционирующих простых процессоров с множеством связей. Несмотря на то, конструировании подобных сетей совершаются определенные упрощения и допущения. Искусственные нейросети показывают впечатляющий набор характеристик, свойственных мозгу. Такими характеристиками являются к примеру, обобщение, обучение на основании опыта, отделение значимой информации из избыточных сведений.

Для нейросетей свойственно подстраивать поведение под окружающую среду. Анализируя поступающие сигналы (с примерами выходных сигналов) они обучаются и проводят самонастройку, для соответствия ожидаемой реакции. Такая сеть способна делать верные предсказания, несмотря на возможные помехи и неточности поступающих сигналов.

Перед тем как использовать нейросеть для решения поставленных задач она должна быть обучена. В данном случае под обучением следует понимать наладку весов синаптических связей и архитектуры сети (строения связей между нейронами) для оптимального решения проблемы. В большинстве случаев обучение нейросети происходит с использованием определенного набора данных. В течение всего обучения, следующего определенному алгоритму, отклик нейросети на входные сигналы должен становиться все лучше.

Набор примеров включает в себя все данные, которые доступны для нейросети по решаемой проблеме, таким образом от объема обучающей выборки, а также того, насколько четко эти данные представляют решаемую проблему, зависит точность обучения нейросети. Следовательно, бессмысленным будет заставлять нейросеть предсказать дождь, если обучающая выборка полностью состоит из данных о солнечных днях.

Обучение нейросети непростой процесс, требующий обширных научных знаний. Для качественного обучения нейросети необходимо иметь в наличии хотя бы десяток примеров. Методы обучения нейросетей включают в себя множество характеристик и настроек, контроль над которыми требует понимания их воздействия.

В пакете Statistica Neural Networks программы Statistica реализованы основные алгоритмы обучения многослойных персептронов. После того, как сеть построена, следующим шагом будет ее обучение на имеющихся данных. В данной работе для обучения сети на имеющихся данных был использован метод обратного распространения. Чтобы иметь возможность следить за работой алгоритма во время обучения сети, в данном пакете предусмотрено большое количество инструментов для анализа, одним из таких инструментов является график ошибки обучения.

Перед тем как начать проектирование процедуры обучения следует получить образец внешней среды в которой функционирует нейросеть – собрать информацией доступную сети. Схема обучения определяется этой информацией. Далее требуется обозначить правила обучения влияющие на процесс настройки, методы преобразования весовых характеристик нейросети. Алгоритм обучения - процедура в которой применяются принципы обучения для расчета весов.

После расчета количества слоев и нейронов в них, необходимо вычислить значения весов нейросети при которых ошибка предсказания была бы минимальна, именно для этого и используются алгоритмы обучения. Суть процесса состоит в том, чтобы приблизить предсказанные сетью значения к значениям обучающего множества. Прогоняя через сеть все наблюдения, имеющиеся в наличии и сопоставляя полученные выходные значения с ожидаемыми (целевыми) значениями вычисляется ошибка для конкретной формы сети.

Наиболее предпочтительными из множества алгоритмов будут те, что способны обучить сеть за малое количество итераций, но в то же время непритязательны к численности переменных. Это связано с тем, что на вычислительных машинах, применяемых при обучении нейросетей крайне мал размер оперативной памяти и прослеживается низкая эффективность.

При разрешении проблемы улучшения большой размерности метод сопряженных градиентов крайне восприимчив к корректности расчетов. Для

методов, учитывающих направление антиградиента на некоторых итерациях или включающих в себя вычисление матрицы Гессе, необходимы добавочные переменные. В то время как для вероятностных алгоритмов необходимо чересчур много итераций. Из-за чего не представляется возможным применение этих методов для обучения нейросетей больших размерностей. Увеличение размерности проблемы в алгоритмах повсеместного улучшения, на порядок увеличивает трудоемкость перебора. Поэтому их применение в обучении нейросетей большой размерности является нереализуемым.

Так как оценочная функция, являющаяся фундаментом всех современных алгоритмов обучения нейросетей, анализирует надежность функционирования сети целиком, данные алгоритмы делают невозможным получение в достаточной мере хорошей структуры регулирования или модели для крайне комплексных объектов за приемлемое время, однако характеризуются сравнительной простотой. В данной области человек все еще удерживает место по скорости работы в сравнении с автоматикой.

3 Реализация программы

Для исследования были собраны данные 50 предприятий, различной специфики деятельности и формы собственности. Среди рассмотренных предприятий представлены как малые и средние предприятия, так и крупные.

Создание нейросети происходило в соответствии со следующим алгоритмом:

- 1) Сбор и обработка данных о рассматриваемых предприятиях.
- 2) Вычисление коэффициентов, применимых в задаче оценки кредитоспособности.
- 3) Занесение всех обработанных данных в набор данных для подачи его нейронной сети в качестве обучающей выборки. Данные используемые в данной работе указаны в приложении Б.
- 4) Построение нейронной сети в соответствии с характеристиками входных и выходных значений. В данной задаче был применен многослойный персептрон.
- 5) Обучение нейросети с использованием с применением выбранного метода обучения, в данном случае был использован методы обратного распространения ошибки, чтобы насколько это возможно минимизировать ошибки распознавания предприятий из обучающей выборки. Для обучения данной нейросети были использованы данные предприятий (приложение Б) с номерами 2-7, 19-22, 24-28, 45-47, 50-54, 63-66, 79-82, 85-88, 91-96, 98-101, 109, 111-115, 119, 125, 127, 137-140. Дальнейшим шагом была произведена оптимизация сети.
- 6) Анализ работы созданной сети. В качестве контрольных значений для проверки качества обученности нейросети были использованы данные предприятий (приложение Б) с номерами 1, 8-17, 29-36, 43, 44, 48, 49, 55-62, 67-69, 71, 75-78, 83, 84, 89, 90, 97, 102, 104-108, 110, 121-124, 128-136. Если сеть работает некорректно, недообучена или переобучена, то необходимо вернуться к пункту 4) и изменить структуру сети.

С использованием обученной нейронной сети может быть произведена оценка кредитоспособности прочих предприятий, которые не были задействованы ни в обучающей, ни в контрольной выборке, такими предприятиями стали предприятия с номерами 18, 23, 37-42, 70, 74, 103, 116-118, 120, 126.

3.1 Особенности работы с пакетом Statistica Neural Networks

Для построения нейронной сети был использован пакет Statistica Neural Networks программы Statistica (разработанной с помощью компиляторов C/C++ и других инструментов), в данном пакете представлен удобный интерфейс, который предоставляет возможность проводить исследования с использованием диалогового режима.

Достаточно большим преимуществом данного программного решения является то, что он естественно интегрирован в большой арсенал методов статистического анализа и визуализации данных, которые предоставлены в программе Statistica. Не будет лишним отметить реализованный в пакете весьма мощный аналитический метод. Генетический алгоритм отбора входных данных, позволяющий сформировать оптимальный набор входных переменных, также предоставляет пользователю возможность выбрать из них наиболее значимые для использования в последующем анализе с помощью традиционных моделей.

В данной системе реализовано множество типов нейронных сетей, используемых в современной практике для решения практических задач, наряду с ними реализованы также и современные алгоритмы быстрого обучения, автоматического конструирования и отбора переменных.

Начнем работу с пакетом SNN, стартовое окно приведено на рисунке 3.1.



Рисунок 3.1 – Стартовое окно SNN

3.2 Создание набора данных

На первом этапе необходимо подготовить и создать набор данных для работы с нейронной сетью. Для оценки и прогнозирования кредитоспособности были собраны данные о 50 предприятиях, относящихся к разным категориям кредитоспособности. Для каждого класса, в соответствии с бухгалтерской отчетностью, рассчитаны рассмотренные ранее 15 величин: L1, L3, P1, F1, F2, F3, F4, A2, A4, A5, A6, R1, R2, R3, R4.

Переменная в последнем столбце (Group)– целевая, обозначает категорию и для различных предприятий принимает следующие номинальные значения:

- AAA – Наивысший уровень кредитоспособности по национальной шкале;
- AA – Высокий уровень кредитоспособности;
- A – Умеренно высокий уровень кредитоспособности;
- BBB – Умеренный уровень кредитоспособности;
- BB – Умеренно низкий уровень кредитоспособности;
- B – Низкий уровень кредитоспособности.

Весь набор данных поделен на три части: обучающее множество (59 записей предприятий, из них 6 относятся к классу кризисности В (номера строк 6, 7, 19, 20, 47, 127), 13 относятся к классу ВВ (номера 45, 46, 54, 63-66, 85-88, 119, 125), 10 относящихся к классу BBB (записи 25-28, 101, 111-115), 11 записей из класса А (записи 2-5, 21, 22, 24, 137-140), относящихся к классу AA 9 (номера 50-53, 82, 95, 96, 98, 109) и 10 записей относящихся к классу

ААА (номера строк 73, 79-81, 91-94, 99, 100)), тестовое множество (17 записей исследуемых предприятий (номера строк 7,8, 15, 30, 31, 56-58, 81, 85, 107, 108, 129, 130)) и контрольное множество (64 записи). Все записи предприятий разных классов кризисности были перемешаны в произвольном порядке.

В пакете Statistica Neural Networks данные, используемые для обучения нейронной сети, хранятся в виде набора данных (Data Set). Набор данных содержит количество наблюдений, для каждого наблюдения заданы значения входных и выходных переменных. Количество переменных указывается при создании набора данных и может быть изменено позже.

Существует два варианта создания нового набора данных: создать прямо в пакете или загрузить набор данных из уже созданной таблицы в программе Statistica.

Для создания набора данных в пакете необходимо сделать следующее:

- 1) Открыть диалоговое окно *Создать набор данных – Create Data Set*, В пользовательском меню выбрать опцию *Файл – File*, далее в подменю *Новый – New* выбрать пункт *Набор данных – Data Set...* как показано на рисунке 3.2.

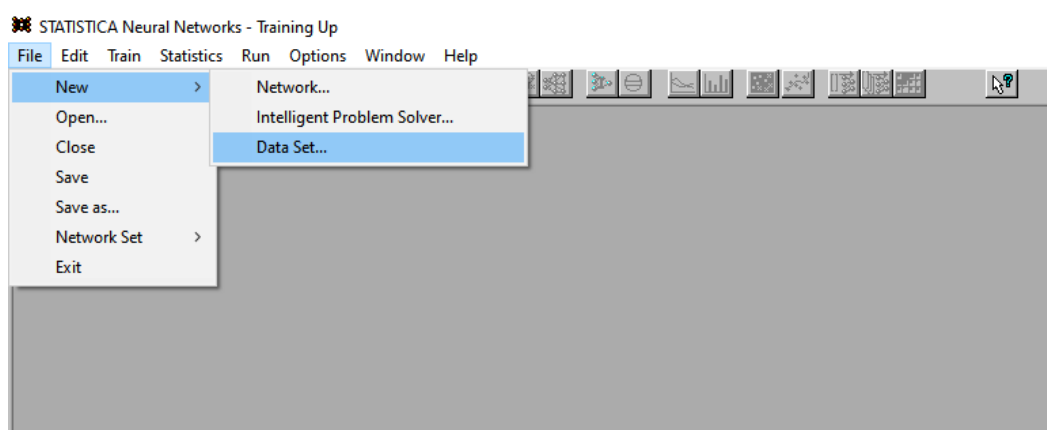


Рисунок 3.2 – Создание нового набора данных

- 2) В поле *Inputs* ввести значения числа входных и в поле *Outputs* ввести число выходных переменных создаваемого набора данных. На рисунке

3.3 указано пятнадцать входных и одна выходная переменная для нашей задачи.




Рисунок 3.3 – Определение числа входных и выходных переменных

Для того чтобы переопределить тип уже созданной переменной, необходимо нажать правой кнопкой мыши на соответствующий столбец, после в списке выбрать необходимый тип данных: *Входной– Input*, *Выходной– Output*, *Входной и Выходной– Input/Output* или *Неучитываемый – Ignored*.

3) Нажать кнопку *Создать – Create*. Программа SNN автоматически откроет окно *Редактор данных – Data Set Editor*, при создании нового набора данных. Главным элементом в открывшемся окне является таблица, в которой содержатся все записи набора данных. В таблице каждая строка соответствует наблюдению. В новой таблице будет представлена только одна строка, а значения всех переменных будут обозначены знаком вопроса (“неизвестными”), как показано на рисунке 3.4. Заголовки столбцов разных переменных обозначены разным цветом: входные – черным, выходные – голубым. Также входные и выходные переменные отделены черной вертикальной линией. Редактирование существующих данных или добавление новых наблюдений возможно через редактирование таблицы.




Рисунок 3.4 – Новый набор данных

– AAA – предприятия с наивысшим уровнем кредитоспособности.

Для задания номинальной переменной, следует нажать правой кнопкой мыши на метке необходимой выходной переменной и выбрать команду *Определение – Definition...* из появившегося контекстного меню.

Весь набор данных для решения поставленной задачи поделен на три части: обучающее множество (59 записей предприятий, из них 6 относятся к классу кризисности В (номера строк 6, 7, 19, 20, 47, 127), 13 относятся к классу ВВ (номера 45, 46, 54, 63-66, 85-88, 119, 125), 10 относящихся к классу ВВВ (записи 25-28, 101, 111-115), 11 записей из класса А (записи 2-5, 21, 22, 24, 137-140), относящихся к классу АА 9 (номера 50-53, 82, 95, 96, 98, 109) и 10 записей относящихся к классу ААА (номера строк 73, 79-81, 91-94, 99, 100)), тестовое множество (17 записей исследуемых предприятий (номера строк 7,8, 15, 30, 31, 56-58, 81, 85, 107, 108, 129, 130)) и контрольное множество (64 записи).

Для назначения одного из типов множества, *Контрольное – Verification*, *Обучающее – Training*, *Неучитываемое – Ignored*, *Тестовое – Test*, необходимо нажать правой кнопкой мыши на метку строки необходимого наблюдения и выбрать, соответствующий тип из контекстного меню.

Также настроить тип переменных можно выбрав пункт *Правка – Edit* на ленте, затем выбрав подпункт *Наблюдения – Cases...* или *Переменные – Variables...*


3.3 Создание сети

Для построения и обучения нейронной сети необходимо преобразовывать исходные данные к правильному виду на вход сети, а выходные данные к виду, нормальному для толкования. Преобразование данных для нейронной сети происходит в слоях пре- и пост-процессирования.

При этом названия категорий изменяются в числовую форму, а числовые значения преобразуются в подходящий диапазон. Для каждого набора

входных и выходных переменных указывается имя и тип, как в изначальном наборе данных пре- и пост-процессирования.

Для исследования был выбран тип нейронной сети – многослойный персептрон. Количество слоев в сети равно 3, промежуточный слой (Y_j) содержит 10 элементов ($j = 10$). По итогам проведения множества численных экспериментов, выбранная структура сети была признана наиболее предпочтительной, так как увеличение числа промежуточных слоев не повышало качество сети, а уменьшение числа слоев приводило к недообучению сети. Поскольку число элементов слоя рекомендуется брать равным не менее половины числа элементов предыдущего слоя, то на первом слое (X_i) – 15 характеристик предприятий ($i = 15$): L1, L3, P1, F1, F2, F3, F4, A2, A4, A5, A6, R1, R2, R3, R4, на промежуточном слое – 10, а на последнем – 6 выходных элементов (Q_k , $k = 6$).

Пакет Statistica Neural Networks программы Statistica предоставляет несколько способов для создания сети. Создать нейронную сеть можно выбрав на ленте пункт *Файл – File*, затем выбрав подпункт *Новый – New* и опцию *Сеть – Network...* в результате чего появится диалоговое окно Создать сеть – Create network либо с использованием автоматического конструктора сети (с помощью кнопки  в ленте быстрого доступа).

Диалоговое окно *Создать сеть – Create Network* показано на рисунке 3.6.

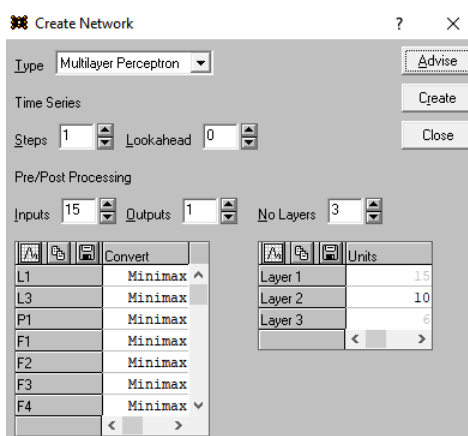


Рисунок 3.6 – Окно создания сети

Далее в появившемся диалоговом окне *Создать сеть – Create Network* необходимо выбрать из списка тип сети *Tun – Type*. В нашем исследовании это *Многослойный персептрон – Multilayer Perceptron*, который был установлен по дефолту. Далее необходимо нажать кнопку *Совет – Advise*. Программа подберет и установит параметры по умолчанию, основываясь на типе переменных исходных данных, для конфигурации сети. Число слоев в сети равно 3, промежуточный слой (Y_j) содержит 10 элементов ($j = 10$). Поскольку число элементов слоя рекомендуется брать равным не менее половины числа элементов предыдущего слоя, то на первом слое (X_i) – 15 характеристик предприятий ($i = 15$): L1, L3, P1, F1, F2, F3, F4, A2, A4, A5, A6, R1, R2, R3, R4, на промежуточном слое – 10, а на последнем – 6 выходных элементов (Q_k , $k = 6$). В пакете Statistica Neural Networks программы Statistica на экран также выдается число элементов во входном и выходном слоях. Однако два последних параметра полностью определяются числом входных и выходных переменных, и их нельзя менять (они отображены серым цветом).

Для подтверждения конфигурации сети и ее создания необходимо нажать кнопку *Создать – Create* в результате чего будет создана новая сеть, названная «ОКП», изображенная на рисунке 3.7.




Рисунок 3.7 – Схема созданной сети

Рассмотрим более подробно структуру созданной нейронной сети прямого распространения сигнала.

Формулы срабатывания нейрона:

$$\Theta = F(\langle W^T | X \rangle) = F\left(\sum_{i=1}^n W_i * X_i\right),$$

$$\theta = \begin{cases} 1, & \langle W^T | X \rangle \geq 0 \\ 0, & \text{иначе} \end{cases}$$

$$F(\langle W | X \rangle) = \frac{1}{1 + e^{-W^T X}}$$


Обозначим θ – порог срабатывания; X_i , $i = 15$ – вектор входов; F – униполярная сигмоидальная функция активации; $W = (W_1, \dots, W_n)$, $n = 10$ – вектор весов; Q_k , $k = 6$ – вектор выходов.

После того, как мы создали набор данных и сеть, необходимо сохранить результаты работы, чтобы в дальнейшем была возможность их использовать. В SNN сеть и набор данных сохраняются в разных файлах – для этого используются диалоговые окна *Сохранить сеть – Save Network* и *Сохранить набор данных – Save Data Set*.

Необходимо открыть окно *Сохранить набор данных – Save Data Set* с помощью команды *Набор данных – Data Set...* из меню *Файл-Сохранить как – File-Save as*. После в поле *Имя Файла – File Name* ввести имя файла и нажать кнопку *Сохранить – Save*.

Способом описанным выше также сохраняется сеть через окно *Сохранить сеть – Save Network*.

3.4 Обучение сети

После того как сеть создана, перед тем как начать процесс ее обучения необходимо задать значения параметров классификации определением порогов принятия (Accept) и отвержения (Reject). Для сети «ОКП» использовалось бинарное кодирование с порогом отвержения и принятия, равными 0,5. Для этого на ленте выберем пункт *Редактировать – Edit*, затем выбираем подпункт *Пре-/Пост Процессирование – Pre-/Post Processing...* в результате чего будет открыто диалоговое окно *Редактор Пре-/Пост Процессирования – Pre/Post Processing Editor* изображенное на рисунке 3.8. Также данное окно может быть открыто с помощью кнопки  на ленте быстрого доступа.

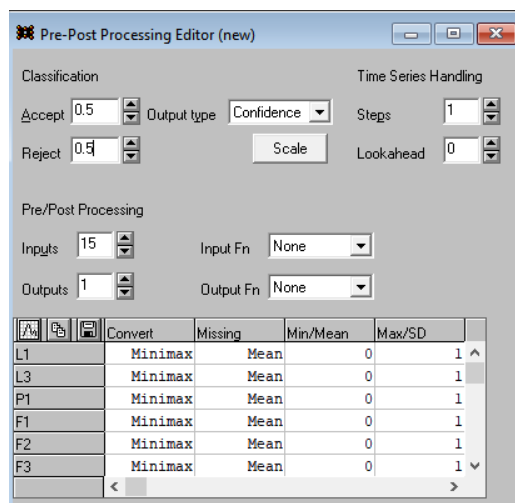



Рисунок 3.8 – Задание порогов принятия и отвержения

В пакете Statistica Neural Networks программы Statistica реализованы основные алгоритмы обучения многослойных персептронов. После того, как сеть построена, следующим шагом будет ее обучение на имеющихся данных. В данной работе для обучения сети на имеющихся данных был использован метод обратного распространения. Чтобы иметь возможность следить за работой алгоритма во время обучения сети, в данном пакете предусмотрено большое количество инструментов для анализа, одним из таких инструментов является график ошибки обучения, для доступа к данному инструменту требуется выполнить следующие шаги:

1) Открыть меню *Статистики – Statistics* на ленте и выбрать подпункт *График обучения... – Training Graph...* После чего на экране появится окно *График ошибки обучения – Training Error Graph* изображенное на рисунке 3.9, также данное окно можно открыть с помощью кнопки  в ленте быстрого доступа.





Рисунок 3.9 – График ошибки обучения

2) С помощью меню *Обучение – Train* на ленте выбрать пункт *Многослойный перцептрон – Multilayer Perceptrons* и подпункт *Обратное распространение... – Back Propagation...*, после чего будет открыто диалоговое окно *Обратное распространение – Back Propagation*, изображенное на рисунке 3.10, данное окно может быть открыто и с помощью кнопки  в ленте быстрого доступа.

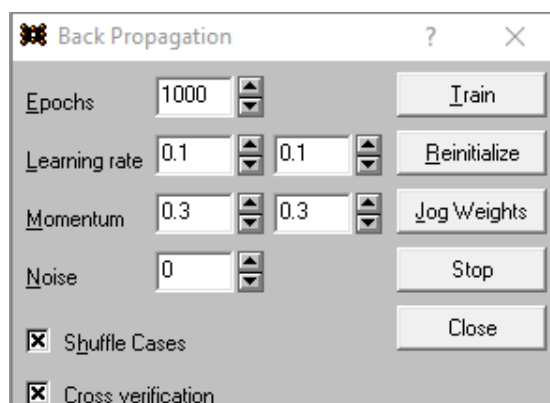


Рисунок 3.10 – Окно обучения сети обратным распространением

3) Определить необходимые для конкретной сети параметры обучения и нажать кнопку *Обучить – Train* в диалоговом окне *Обратное распространение – Back Propagation* после чего будет запущен алгоритм

обучения. При этом в окне *График ошибки обучения – Training Error Graph* график будет отрисовываться график ошибки для обучающего (синий) и контрольного множества (красный) с указанием ошибки по оси ординат и количества эпох по оси абсцисс.

4) Нажимать кнопку *Обучить – Train* снова и снова, чтобы алгоритм переходил к очередным эпохам.

Для обучения сети методами обратного распространения были взяты следующие стартовые значения основных параметров:

- число эпох обучения взято равным 100, что позволило нам наблюдать за развитием обучения сети по эпохам;
- скорость обучения была взята равной 0,1. Если скорость обучения больше 0,1, то, по итогам результатов, уже после первой итерации сеть переобучается;
- инерция равна 0,3, что придает алгоритму дополнительную устойчивость.

При наличии контрольного множества в процессе обучения сети есть вероятность заметить на начальных этапах немного меньшую ошибку контрольного множества по сравнению с ошибкой обучающего множества. Данное явление объясняется тем, что ошибка обучения сети на обучающем множестве суммируется по мере обработки каждого последующего предприятия, в то время как ошибка контрольного множества рассчитывается по окончании каждой эпохи.

На графике можно наблюдать, что ошибка убывает, пускай и достаточно медленно. Если на первоначальном этапе обучения среднеквадратичная ошибка на контрольном множестве – была 0,1743, то после тысячи итераций она уменьшилась до 0,02476; на обучающем множестве была 0,1754, стала – 0,02367.

В окне *График ошибки обучения – Training Error Graph* выводится суммарная ошибка сети. Но иногда может возникнуть необходимость проследить за тем, как алгоритм обучения воспринимает отдельные

наблюдения. В пакете Statistica Neural Networks это можно сделать, открыв на ленте меню *Статистики – Statistics* и выбрав подпункт *Ошибки наблюдений... – Case errors...* Ошибки на отдельных наблюдениях выводятся в виде гистограммы, показанной на рисунке 3.11. По завершении сеанса обучения ошибки пересчитываются, но имеется также возможность следить за тем, как ошибки наблюдений меняются в ходе обучения – для этого существует функция *Пересчитывать по ходу – Real-time update* окна *Ошибки наблюдений – Case Errors*; ее нужно активизировать перед тем как начать обучение алгоритмом обратного распространения.

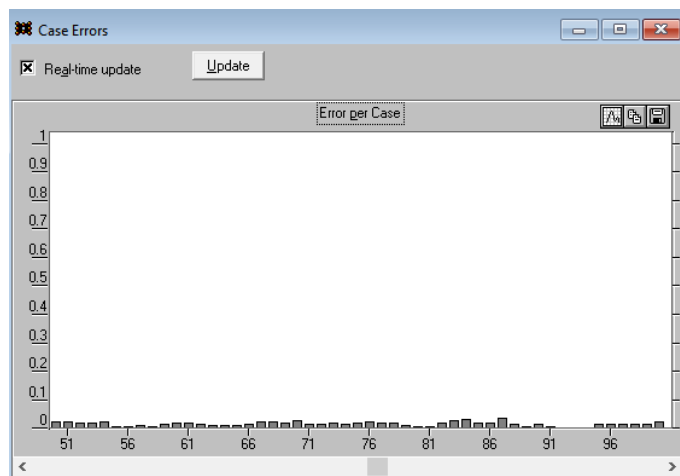





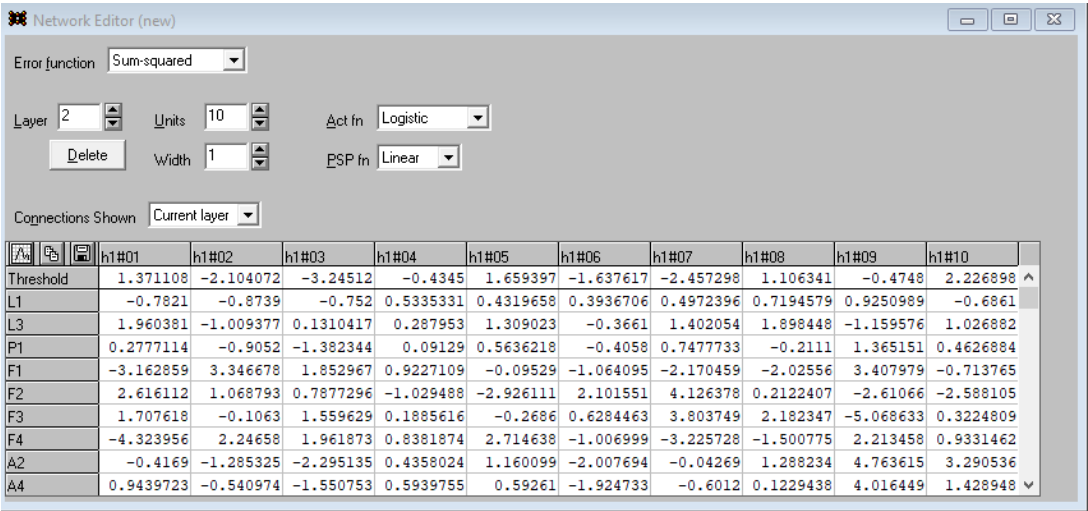
Рисунок 3.11 – Ошибки наблюдений

Чтобы посмотреть результат обработки отдельного наблюдения из набора данных необходимо открыть меню *Запуск – Run* на ленте, затем выбрать подпункт *Одно наблюдение... – Single Case...* или нажать кнопку  в ленте быстрого доступа после чего откроется окно *Прогнать одно наблюдение – Run Single Case*. В поле *Номер наблюдения – Case No* указывается номер наблюдения для обработки. Для того чтобы начать обработку текущего наблюдения, необходимо нажать кнопку *Запуск – Run*, для обработки какого-либо другого наблюдения следует ввести необходимый номер в поле *Номер наблюдения – Case No* и нажать клавишу *Run*.

Чтобы протестировать сеть на всем наборе данных необходимо открыть окно *Прогнать набор данных – Run Data Set* с помощью кнопки  в ленте быстрого доступа, либо с помощью меню *Запуск – Run* и пункта *Набор данных... – Data Set...* Затем в открывшемся окне также нужно нажать кнопку *Запуск – Run*, чтобы начать тестирование сети – результаты данного тестирования будут выведены в таблицу.

Иногда также появляется необходимость протестировать сеть на отдельном наблюдении, не включенных в какой-либо набор данных. Тестирование таких наблюдений возможно провести из окна *Прогнать отдельное наблюдение – Run One-off Case* открыть которое можно выбрав пункт *Отдельное наблюдение... – One-off...* меню *Запуск – Run*.

Определим функции ошибок (сумма квадратов), пороги и веса для второго слоя, задающиеся алгоритмом обучения. Откроем диалоговое окно *Редактор сети – Network editor*, изображенное на рисунке 3.12. Для этого необходимо выбрать пункт *Сеть... – Network...* меню *Правка – Edit* или же нажав кнопку  в ленте быстрого доступа.



Network Editor (new)

Error function: Sum-squared

Layer: 2 Units: 10 Act fn: Logistic PSP fn: Linear

Connections Shown: Current layer


	h1#01	h1#02	h1#03	h1#04	h1#05	h1#06	h1#07	h1#08	h1#09	h1#10
Threshold	1.371108	-2.104072	-3.24512	-0.4345	1.659397	-1.637617	-2.457298	1.106341	-0.4748	2.226898
L1	-0.7821	-0.8739	-0.752	0.5335331	0.4319658	0.3936706	0.4972396	0.7194579	0.9250989	-0.6861
L3	1.960381	-1.009377	0.1310417	0.287953	1.309023	-0.3661	1.402054	1.898448	-1.159576	1.026882
P1	0.2777114	-0.9052	-1.382344	0.09129	0.5636218	-0.4058	0.7477733	-0.2111	1.365151	0.4626884
F1	-3.162859	3.346678	1.852967	0.9227109	-0.09529	-1.064095	-2.170459	-2.02556	3.407979	-0.713765
F2	2.616112	1.068793	0.7877296	-1.029488	-2.926111	2.101551	4.126378	0.2122407	-2.61066	-2.588105
F3	1.707618	-0.1063	1.559629	0.1885616	-0.2686	0.6284463	3.803749	2.182347	-5.068633	0.3224809
F4	-4.323956	2.24658	1.961873	0.8381874	2.714638	-1.006999	-3.225728	-1.500775	2.213458	0.9331462
A2	-0.4169	-1.285325	-2.295135	0.4358024	1.160099	-2.007694	-0.04269	1.288234	4.763615	3.290536
A4	0.9439723	-0.540974	-1.550753	0.5939755	0.59261	-1.924733	-0.6012	0.1229438	4.016449	1.428948

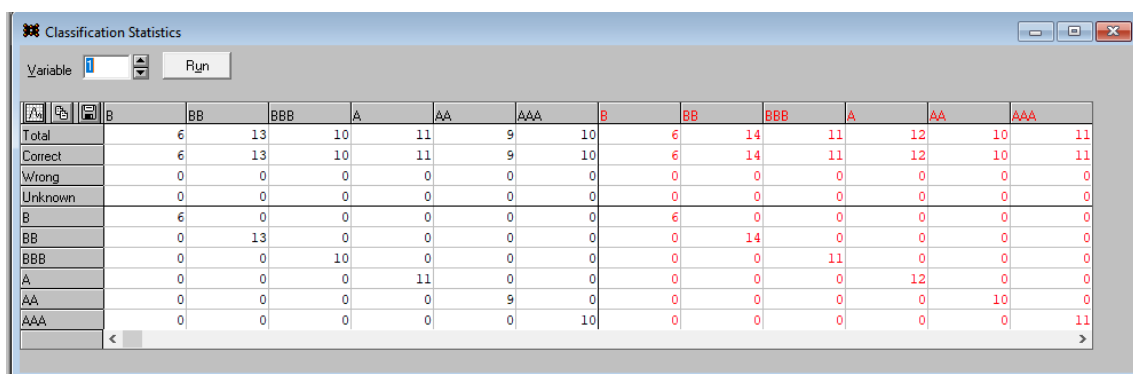
Рисунок 3.12 – Веса и пороги скрытого слоя сети

В первой строке данной таблицы подсчитаны пороговые значения для всех десяти нейронов скрытого слоя. В остальных строках указаны значения

весов соответствующей переменной для каждого нейрона скрытого слоя. По сути эти данные определяют работу сети «ОКП».

3.5 Анализ обученной сети

Последним этапом, после обучения сети, необходимо проверить, как хорошо она работает. Лишь грубой мерой производительности является среднеквадратичная ошибка, которую выдает график ошибки обучения. Для большей наглядности может быть использована таблица со статистиками, отражающими результаты и качество классификации, которую можно вывести в окне *Статистики классификации* – *Classification Statistics* с помощью кнопкой  на ленте быстрого доступа или из меню *Статистики* – *Statistics* и подпункта *Классификация...* – *Classification...* Данное окно изображено на рисунке 3.13.



	B	BB	BBB	A	AA	AAA	B	BB	BBB	A	AA	AAA
Total	6	13	10	11	9	10	6	14	11	12	10	11
Correct	6	13	10	11	9	10	6	14	11	12	10	11
Wrong	0	0	0	0	0	0	0	0	0	0	0	0
Unknown	0	0	0	0	0	0	0	0	0	0	0	0
B	6	0	0	0	0	0	6	0	0	0	0	0
BB	0	13	0	0	0	0	0	14	0	0	0	0
BBB	0	0	10	0	0	0	0	0	11	0	0	0
A	0	0	0	11	0	0	0	0	0	12	0	0
AA	0	0	0	0	9	0	0	0	0	0	10	0
AAA	0	0	0	0	0	10	0	0	0	0	0	11

Рисунок 3.13 – Статистики классификации

Таблица содержит сведения о том, сколько предприятий каждого класса было классифицировано правильно, сколько неправильно, и сколько предприятий сеть не смогла однозначно отнести к какому-либо классу, также здесь указываются детальные данные об ошибках классификации.

Статистики показываются отдельно для контрольного и обучающего множества. В верху таблицы можно наблюдать суммарные статистики, а в нижней ее части – кросс-результаты классификации.

Чтобы определить роль каждого скрытого элемента созданной нейронной сети следует проанализировать внутренние активации элементов сети, которые выводятся в окне *Активации сети* – *Network Activations* и представлены в виде гистограммы и таблицы чисел на рисунке 3.14 для нужного предприятия по слоям (1–2–3). Данное окно можно открыть с помощью меню *Запуск* – *Run* и подменю *Активации...* – *Activations...*

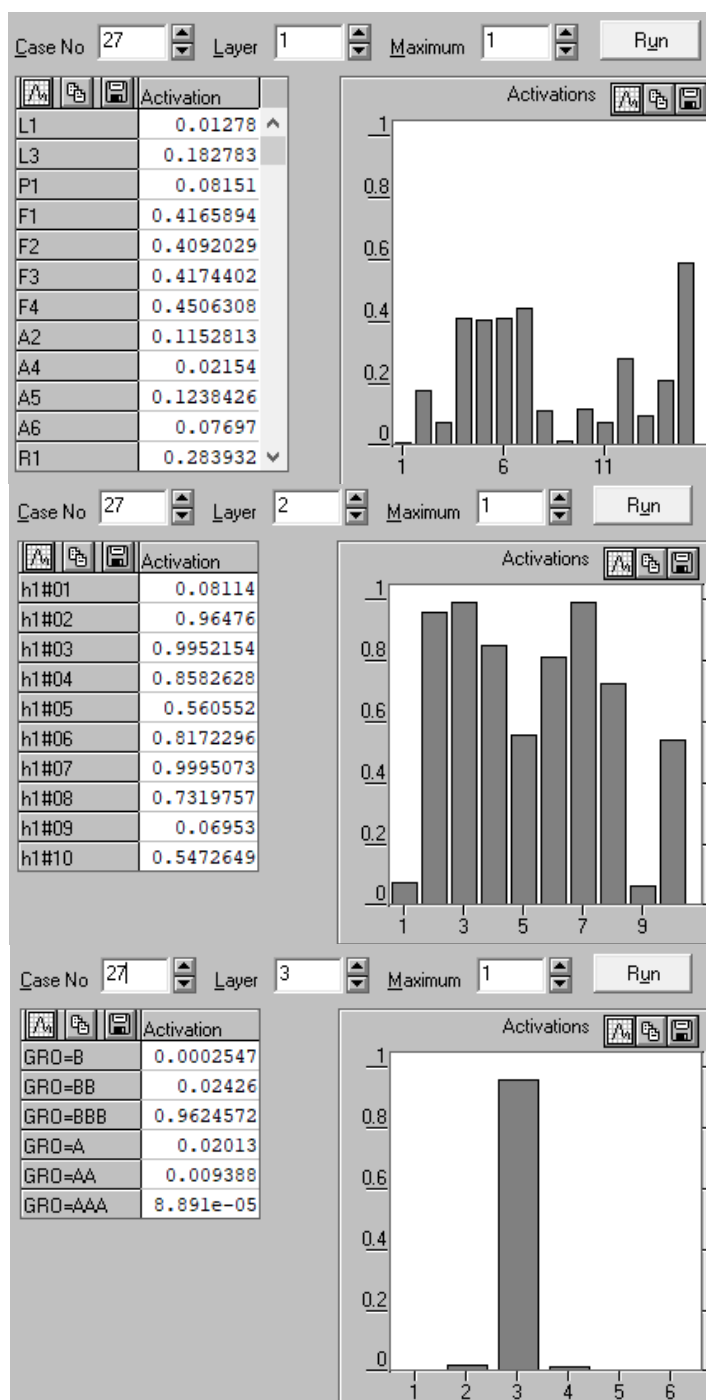


Рисунок 3.14 – Внутренние активации сети для слоя 1-2-3

Наблюдая за всеми этими данными можно делать выводы о том, насколько правильно обучена сеть и может ли она использоваться для решения поставленных задач.

В таблице 3.1 показана итоговая категория, определенная нейронной сетью и оценка, выставленная рейтинговым агентством, а также ошибка нейронной сети для наблюдений тестовой выборки:

Таблица 3.1 – Сравнение полученных результатов с ожидаемыми

Предприятие	Группа	Оценка агентства	Соответствие	Ошибка
Группа продовольствие 2018	B	B	Right	0.03167
ГТЛК 2019	AA	AA	Right	0.02558
ИСКЧ 2021	A	A	Right	0.05836
Кокс 2020	A	A	Right	0.01489
Кокс 2021	A	A	Right	0.07678
Лента 2018	A	A	Right	0.09287
Лента 2019	A	A	Right	0.0863
Лента 2020	AA	AA	Right	0.08634
ОР 2020	BB	BB	Right	0.03659
ПАО Газпром 2018	AAA	AAA	Right	0.0213833
ПАО Газпром 2020	AAA	AAA	Right	0.02102
Самолет 2021	B	B	Right	0.02028
ТерГенКом 2018	BBB	BBB	Right	0.02134
ТерГенКом 2019	BBB	BBB	Right	0.02185
ТерГенКом 2020	BBB	BBB	Right	0.02253
ТФН 2020	BB	BB	Right	0.03166
Феррони 2021	B	B	Right	0.03362

ЗАКЛЮЧЕНИЕ

Реализованная нейронная сеть для оценки кредитоспособности предприятия не является конечным вариантом и остается открытой для модернизации.

Помимо обычного использования нейронной сети самой по себе, имеются также следующие возможности для модернизации:

- Интеграция созданной сети с имеющийся на предприятии системой сбора и обработки финансовой отчетности, для эффективного анализа деятельности предприятием;
- Создание отдельного программного продукта для упрощения и увеличения привлекательности данного метода оценки кредитоспособности потенциальным пользователем;
- Создание программного продукта, комбинирующего в себе дополнительный функционал для оценки кредитоспособности предприятия с целью увеличения точности и адекватности отнесения предприятия к тому или иному классу кредитоспособности.

В результате проделанной выпускной работы были достигнуты следующие результаты:

- проанализированы существующие методы и модели анализа кредитоспособности предприятия;
- проанализированы модели нейронных и методы обучения;
- изучена национальная рейтинговая шкала и система оценки;
- собраны и обработаны финансовые показатели 50 предприятий за 1-4 года деятельности;
- освоен инструментарий пакета Statistica Neural Networks программы Statistical;
- создана и обучена нейронная сеть для оценки финансово-экономического состояния предприятия и его отнесения к той или иной категории кредитоспособности.

На основании вышеизложенного, можно заключить, что внедрение в инструментарий для анализа предприятия такого современного метода как нейронная сеть, может сыграть большую роль в повышении качества определения финансово-экономического состояния предприятия в соответствии с национальной рейтинговой шкалой оценки кредитоспособности, ввиду достаточно высокой степени точности (97% предприятий из представленного набора отнесены к соответствующей категории кредитоспособности). К тому же реализованная система потенциально может оказаться коммерчески выгодной разработкой. Разработку приложения для использования данной сети можно аргументировать высоким спросом на оценку кредитоспособности предприятия не только среди самих предприятий, но также и среди инвесторов и кредиторов.

В конечном счете в Российской Федерации применение нейронных сетей незаслуженно недооценено и, соответственно, еще не нашло широкого распространения. Нейронные сети используются для работы в относительно узких областях, и непонятно, доверят ли им когда-нибудь решение вопросов, которые требуют осознания общественного контекста. Но стоит заметить, что использование подобной разработки предприятиями малого бизнеса может стать одним из первых шагов для увеличения заинтересованности и спроса в подобных технологиях.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Коваленко А.В. Математические модели и инструментальные средства комплексной оценки финансово-экономического состояния предприятия: дис... канд. экон. наук: 08.00.13 / А.В. Коваленко, Кубан. гос. аграр. ун-т. – Краснодар, 2009. – 321 с.
2. Ендовицкий, Д.А. Анализ и оценка кредитоспособности заёмщика: уч.-практ. пос./ Д.А. Ендовицкий, И.В. Бочарова. - М.: Кнорус, 2005. -272 с.
3. Гиляровская, Л.Т. Комплексный экономический анализ хозяйственной деятельности: учебник для вузов / Л.Т. Гиляровская, Д.В. Лысенко, Д.А. Ендовицкий. – М.: Велби, 2006. – 360с.
4. Кирисюк, Г.М. Оценка банком кредитоспособности заёмщика/ Г.М. Кирисюк, В.С. Ляховский // Деньги и кредит. - 1993. -№4. - С. 10-14.
5. Коваленко, А.В. Нейронная сеть и нечёткие множества, как инструмент оценки кредитоспособности заёмщика / А.В. Коваленко // Прикладная математика XXI века: Материалы VI объединённой научной конференции студентов и аспирантов факультета прикладной математики. - Краснодар: КубГУ, 2006. - С. 56-58.
6. Лаврушин О.И. Банковское дело: Современная система кредитования: Учеб. пособие для вузов / О.И. Лаврушин, О.Н. Афанасьева, С.Л. Корниенко; под ред. Лаврушина О.И. - 3-е изд., перераб. и доп. - М.: КНОРУС, 2005. - 256 с.
7. Илларионов, А. В. Разработка математических моделей и алгоритмов принятия решения по кредитованию предприятий малого (среднего) бизнеса на основе аппарата теории нечётких множеств: дис. ... канд. экон. наук / А. В. Илларионов. - Владимир, 2006. - 231с
8. Эйтингон, В.Н. Прогнозирование банкротства: основные методики и проблемы / В.Н. Эйтингон, С.А. Анохин // Содействие. - 1999. - №7. - С. 8-14.

9. Недосекин, А.О. Методологические основы моделирования финансовой деятельности с использованием нечетко-множественных описаний: дис. ... д. экон. наук / А.О. Недосекин. - СПб., 2003. - 280 с.
10. Недосекин, А.О. Сводный финансовый анализ российских предприятий за 2000 - 2003 гг. / А.О. Недосекин, Д.Н. Бессонов, А.В. Лукашев // Аудит и финансовый анализ. - 2005, - № 1. С. 53 - 60.
11. Бухгалтерская отчетность предприятий РФ [Электронный ресурс]. – Режим доступа: https://www.audit-it.ru/buh_otchet/ (дата обращения: 20.05.2022).
12. Государственный информационный ресурс бухгалтерской (финансовой) отчетности [Электронный ресурс]. – Режим доступа: <https://bo.nalog.ru/> (дата обращения: 20.05.2022).
13. Рейтинговое агентство АКРА. Официальный сайт [Электронный ресурс]. – Режим доступа: <https://www.acra-ratings.ru/> (дата обращения: 20.05.2022).
14. Рейтинговое агентство «Эксперт РА» - рейтинги, исследования, обзоры, конференции [Электронный ресурс]. – Режим доступа: <https://www.raexpert.ru/> (дата обращения: 20.05.2022).
15. Заенцев И. Нейронные сети: основные модели: [учебное пособие] / И. Заенцев. – Воронеж, 1999. – 76 с.
16. Хайкин С. Нейронные сети: полный курс. – 2-е издание / Пер. с англ. – М. : Издательский дом «Вильямс», 2006. – 1104 с.

ПРИЛОЖЕНИЕ А

Основные показатели финансово-экономического состояния предприятия

А.1 Показатели ликвидности и платежеспособности предприятия

Коэффициенты ликвидности показывают способность предприятия своевременно исполнить свои краткосрочные финансовые обязательства. Коэффициенты платежеспособности показывают возможность предприятия расплачиваться по своим обязательствам.

Для вычисления значения платежеспособности предприятия используется бухгалтерский баланс предприятия: 2-ой раздел актива баланса, описывает размер текущих активов в начале и конце отчётного года, а в 5-ом разделе пассива баланса указаны данные о краткосрочных обязательствах предприятия. Определение платежеспособности организации, учитывая ликвидность его активов, состоит в сопоставлении величины средств по активу, сгруппированных по степени их ликвидности, с совокупностью обязательств по пассиву, сгруппированными по срокам их погашения.

Ликвидность баланса – это степень покрытия обязательств предприятия такими активами, срок превращения которых в денежные средства соответствует сроку погашения обязательств.

В группу критериев платежеспособности и ликвидности входят: Коэффициент быстрой ликвидности, обозначим его (L_1), который показывает отношение наиболее ликвидных активов предприятия и дебиторской задолженности к текущим обязательствам. Этот коэффициент отражает платежные возможности предприятия для своевременного и быстрого погашения своей задолженности. По смысловому назначению показатель аналогичен коэффициенту текущей ликвидности; однако исчисляется по более узкому кругу текущих активов, когда из расчета исключена наименее ликвидная их часть – производственные запасы. Данный коэффициент

вычисляется соотношением. В данном соотношении, и далее по тексту, в скобках указаны строки баланса (формы 1) предприятия.

$$L1 = \frac{\begin{aligned} &\text{Оборотные активы(1200)} - \\ &\text{—Дебиторская задолженность (свыше 12 месяцев)(1230)} - \\ &\text{—Запасы(1210)} - \\ &\text{—Налог на добавленную стоимость(1220)} \end{aligned}}{\begin{aligned} &\text{Краткосрочные обязательства(1500)} - \\ &\text{—Доходы будущих периодов(1530)} \end{aligned}}$$

Текущий коэффициент ликвидности (P1) описывающий долю текущих обязательств, которая оплачиваемую не только посредством наличности, но и за счёт предполагаемых поступлений за реализованный товар, осуществленные работы или предоставленные услуги. Текущий коэффициент ликвидности представляет единую оценку ликвидности активов, показывая, сколько рублей текущих активов предприятия приходится на один рубль текущих обязательств. Суть вычисления данного параметра состоит в том, что организация погашает краткосрочные обязательства в основном за счет текущих активов; следовательно, если текущие активы превышают по величине текущие обязательства, предприятие может рассматриваться как успешно функционирующее. Текущий коэффициент ликвидности вычисляется следующим соотношением:

$$P1 = \frac{\begin{aligned} &\text{Оборотные активы(1200)} - \\ &\text{—Дебиторская задолженность(более 12 месяцев)(1230)} \end{aligned}}{\begin{aligned} &\text{Краткосрочные обязательства(1500)} - \\ &\text{Доходы будущих периодов(1530)} \end{aligned}}$$

Коэффициент покрытия запасов (L3), показывает ценой каких средств были получены запасы, а также издержки организации. Коэффициент покрытия запасов рассчитывается по следующей формуле:

$$L3 = \frac{\begin{aligned} &\text{Оборотные активы(1200)} - \\ &- \text{Долгосрочные обязательства(1400)} - \\ &- \text{Краткосрочные обязательства(1500)} + \\ &+ \text{Доходы будущих периодов(1530)} + \\ &\text{Займы и кредиты(1230)} \end{aligned}}{\text{Запасы(1210)}} * 100\%$$

А.2 Показатели финансовой устойчивости предприятия

Финансовая устойчивость организации выражается зависимостью от заемных средств и возможностью свободно управлять личным капиталом, без риска компенсации избыточных процентов за невыплату, либо частичную уплату кредиторской задолженности своевременно.

В категорию показателей финансовой устойчивости входят:

Коэффициент финансовой зависимости (F1), который является обратным к показателю концентрации личного капитала и означает процент собственников организации в единой совокупности средств, авансированных в ее работу. Рост этого показателя в динамике означает рост заемных средств.

Коэффициент финансовой зависимости организации обозначает, в какой мере активы организации финансируются заемными средствами. Представляет собой безразмерную величину и вычисляется следующим соотношением:

$$F1 = \frac{\begin{aligned} &\text{Долгосрочные обязательства(1400)} + \\ &+ \text{Краткосрочные обязательства(1500)} - \\ &- \text{Доходы будущих периодов(1530)} \end{aligned}}{\begin{aligned} &\text{Капитал и резервы(1300)} - \\ &- \text{Целевые финансирование и поступления(1350)} + \\ &+ \text{Доходы будущих периодов (1530)} \end{aligned}}$$

Коэффициент автономии собственных средств (F2) показывает часть личных средств в единой совокупности общих средств организации.

Представляет собой безразмерную величину и определяется следующим соотношением:

$$F2 = \frac{\begin{aligned} &\text{Доходы будущих периодов(1530)} + \\ &\text{+Капитал и резервы(1300)} - \\ &\text{—Целевые финансирование и поступление(1350)} + \end{aligned}}{\begin{aligned} &\text{Оборотные активы(1200)} + \\ &\text{+Внеоборотные активы(1100)} \end{aligned}}$$

Коэффициент обеспеченности запасов собственными оборотными средствами (F3) определяется как отношение разности между объемами источников собственных средств и физической стоимостью основных средств и прочих внеоборотных активов к фактической стоимости находящихся в наличии у предприятия оборотных средств в виде производственных запасов. Коэффициент обеспеченности представляет собой безразмерную величину и вычисляется следующим соотношением:

$$F3 = \frac{\begin{aligned} &\text{Доходы будущих периодов(1530)} - \\ &\text{—Внеоборотные активы(1100)} + \\ &\text{+Капитал и резервы(1300)} - \\ &\text{—Целевые финансирование и поступление(1350)} \end{aligned}}{\text{Запасы(1210)}}$$

Индекс постоянного актива (F4) это размер основных средств и внеоборотных активов в источниках личных средств. Является величиной безразмерной и рассчитывается по следующей формуле:

$$F4 = \frac{\begin{aligned} &\text{Внеоборотные активы(1100)} + \\ &\text{+Дебиторская задолженность (свыше 12 месяцев)(1230)} \end{aligned}}{\begin{aligned} &\text{Капитал и резервы(1300)} - \\ &\text{—Целевые финансирование и поступление(1350)} + \\ &\text{+Доходы будущих периодов(1530)} \end{aligned}}$$

А.3 Показатели деловой активности предприятия

Результативность хозяйственной деятельности вычисляется одним из двух методов, показывающих эффективность функционирования организации сравнительно либо размера авансированных средств, либо меры их расходования (издержек) в ходе производства.

Деловая активность предприятия в финансовом аспекте проявляется, прежде всего, в скорости оборота его средств. Рентабельность организации показывает меру доходности его деятельности. Анализ деловой активности и рентабельности заключается в исследовании уровней и динамики разнообразных финансовых коэффициентов оборачиваемости и рентабельности, которые являются относительными показателями финансовых результатов деятельности предприятия.

Коэффициенты деловой активности позволяют проанализировать, насколько эффективно организация использует свои средства. Данные параметры описываются числом оборотов того либо иного ресурса организации за квартал.

В категорию показателей деловой активности входят:

Коэффициент оборачиваемости активов (A2), который описывает результативность применения организацией всех имеющихся в распоряжении ресурсов, независимо от источников их привлечения. Данный коэффициент показывает сколько раз за квартал совершается полный цикл производства и обращения, приносящий соответствующий эффект в виде прибыли. Оборачиваемость активов – финансовый показатель, рассчитываемый как отношение оборота компании к среднегодовой величине суммарных активов. Коэффициент, отражающий скорость оборачиваемости активов предприятия, рассчитывается как частное от деления выручки от реализации на среднюю величину совокупных активов следующим соотношением:

$$A2 = \frac{\text{Выручка (нетто) от продажи товаров(2110)}}{\text{Актив(1600)}}$$

Коэффициент оборачиваемости кредиторской задолженности (A4) – параметр, соотносящий сумму денег, которую организация должна вернуть кредиторам (в основном, поставщикам) к определенному сроку, и текущую величину закупок либо приобретенных у кредиторов товаров/услуг. Высокая доля кредиторской задолженности снижает финансовую устойчивость и платежеспособность организации, однако кредиторская задолженность дает возможность организации пользоваться "бесплатными" деньгами на время ее существования.

$$A4 = \frac{\begin{array}{l} \text{Выручка (нетто) от продажи товаров(2110)} - \\ - \text{Коммерческие расходы(2210)} - \\ - \text{Управленческие расходы(2220)} \end{array}}{\text{Кредиторская задолженность(1520)}}$$

Коэффициент оборачиваемости дебиторской задолженности (A5) – параметр, описывающий темпы оборота дебиторской задолженности, вычисляемый как частное оборота предприятия к среднеквартальному значению дебиторской задолженности. Отношение выручки от реализации продукции (работ, услуг) к среднему за период значению дебиторской задолженности показывает вынужденное или добровольное расширение или снижение коммерческого кредита, предоставляемого организацией. Коэффициент описывается по формуле:

$$A5 = \frac{\text{Выручка (нетто) от продажи товаров(2110)}}{\text{Дебиторская задолженность(1230)}}$$

Коэффициент оборачиваемости запасов (A6) – коэффициент, описывающий темпы использования или сбыта сырья, или резервов. Отношение, показывающее, сколько раз был продан (использован для производства) средний объем запасов в течение квартала. Показатель рассчитывается по формуле:

$$A6 = \frac{\text{Себестоимость проданных товаров, услуг, работ}(2120)}{\text{Запасы}(1210)}$$

А.4 Показатели рентабельности предприятия

Рентабельность – параметр экономической продуктивности организации, характеризующий пропорции прибыли и расходов за конкретный период времени. Эффективность работы предприятия, исчисляемая в виде отношения прибыли к издержкам производства. Это один из ключевых стоимостных параметров результативности производства, определяющих степень эффективности затрат и меру эксплуатации ресурсов в процессе производства и реализации товара.

Показатели рентабельности определяются следующим соотношением:

$$R = \frac{\Pi}{R_{\text{сии}}},$$

где $R_{\text{сии}}$ – доходность того или иного имущества предприятия и его источников Π - прибыль (чистая либо балансовая).

Показатели рентабельности более полно, чем прибыль, характеризуют окончательные результаты хозяйствования, потому что их величина показывает соотношение эффекта с наличными или использованными ресурсами. Их применяют для оценки деятельности предприятия и как инструмент определения стратегии вложения средств и регулирования цен.

В группу критериев рентабельности входят:

Коэффициент общей рентабельности (R_1), который вычисляется как частное дохода за вычетом налогов и выручки от реализации товаров, работ и услуг. Данный коэффициент описывается выражением:

$$R1 = \frac{\text{Прибыль (убыток) до налогообложения(2300)} - \text{Налог на прибыль(2410)}}{\text{Прочие внереализационные доходы(2340)} + \text{Выручка (нетто) от продажи товаров(2110)}}$$

Коэффициент рентабельности активов (R2) вычисляется как частное чистой прибыли и всех активов организации. Коэффициент описывается выражением:

$$R2 = \frac{\text{Чистая прибыль(2400)}}{\text{Актив(1600)}}$$

Коэффициент рентабельности собственного капитала (R3) демонстрирует результативность применения капитала, вложенного предприятием за счет личного источника финансирования. Отношение чистой прибыли за вычетом налогов к чистому собственному капиталу акционерного общества. Показывает меру дохода на вложения держателей акций. Формула расчета:

$$R3 = \frac{\text{Чистая прибыль(2400)}}{\text{Доходы будущих периодов(1530)} - \text{Целевое финансирование и поступления(1350)} + \text{Капитал и резервы(1300)}}$$

Коэффициент рентабельности продукции (продаж) (R4) – характеризует эффективность предпринимательской деятельности: сколько прибыли имеет предприятие с рубля продаж. Показатель, характеризующий эффективность затрат предприятия на изготовление и на сбыт товаров (осуществление услуг, работ). Вычисляется как частное дохода от сбыта товаров (осуществления услуг, работ) к общему числу затрат на производство и реализацию продукции. Данный показатель вычисляется как частное дохода от сбыта

продукции (выполнения услуг, работ) к общему числу затрат на производство и сбыт продукции (в процентах) и означает эффективность расходов предприятия на сбыт товара и его изготовление. Коэффициент R4 рассчитывается по следующей формуле:

$$R4 = \frac{\text{Прибыль (убыток) от продаж(2200)}}{\text{Выручка (нетто) от продажи товаров(2110)}}$$

Приведённые выше количественные характеристики предприятий использованы для оценки финансового состояния предприятия в 3 главе выпускной квалификационной работы.

ПРИЛОЖЕНИЕ Б

Таблица рассчитанных коэффициентов для нейронной сети.

	Наименование	L1	L3	PL	F1	F2	F3	F4	A2	A4	A5	A6	R1	R2	R3	R4	Рейтинг
1	Альфа дон 2021	-0,50461	-13,0325	-0,65881	4,313327	-0,39048	-8,70723	3,349359	-0,10854	-0,76741	-0,72808	-2,00006	-26,3226	-5,99145	-16,1688	-92,1174	В
2	АО Арх ЦБК 2018	0,920774	455,5599	0,380124	1,263726	0,87392	1,591776	0,373375	-0,08728	0,800314	-3,75351	-6,58879	9,822609	16,35591	18,18671	5,973292	А
3	АО Арх ЦБК 2019	1,005886	455,5562	0,410023	1,262063	0,876367	1,591773	0,372747	-0,30255	1,770379	-4,47544	-6,59475	9,286288	15,73859	18,0418	5,824271	А
4	АО Арх ЦБК 2020	0,979733	455,5598	0,406319	1,25983	0,879891	1,59179	0,372601	-0,29274	1,317178	-4,17939	-6,59115	9,458174	15,32691	17,94742	5,819995	А
5	АО Арх ЦБК 2021	0,976935	455,6238	0,368072	1,254186	0,890252	1,592138	0,374078	-0,13935	1,141262	-4,97469	-6,57084	9,593162	16,58404	18,17261	5,99468	А
6	АСПЭК 2020	-0,51162	-12,1586	-0,63177	4,228636	-0,35743	-8,69642	3,451538	-0,11917	-0,79523	-0,90291	-2,0062	-26,3248	-6,05579	-16,5357	-87,116	В
7	АСПЭК 2021	-0,50097	-12,1567	-0,60161	4,205513	-0,34173	-8,69639	3,414843	-0,11843	-0,78197	-0,8992	-2,00619	-26,3225	-6,05433	-16,5427	-88,2741	В
8	БКЕ 2019	5,312392	654,1103	3,071057	0,644663	0,965467	3,314227	-0,09107	3,063109	13,93066	25,01603	28,93582	40,47244	28,67083	36,45479	48,94165	АА
9	БКЕ 2020	6,275756	654,1659	3,182537	0,643155	0,967766	3,314653	-0,09099	3,0845	14,05637	24,56049	28,94894	40,50932	28,69875	36,4571	48,94195	АА
10	БКЕ 2021	3,283394	654,1311	2,823861	0,656033	0,951423	3,314138	-0,08746	3,157739	13,618	22,80078	28,99054	40,42584	28,41616	36,41507	48,88492	АА
11	Газпром межрег 2020	4,217087	860,2369	5,229705	-0,00956	1,090453	5,09792	-0,56204	6,945161	27,50939	50,39999	66,54828	72,59929	41,85415	55,43025	93,39274	ААА
12	Газпром межрег 2021	4,473407	859,631	5,255402	0,003092	1,063117	5,095265	-0,56125	7,190976	27,43058	51,48235	66,9646	72,56148	41,50596	55,36488	93,39644	ААА
13	Газпромнефть 2018	4,366212	858,6699	5,245501	0,11299	1,003537	5,090384	-0,55278	7,334757	27,03506	53,36448	66,58407	72,6791	42,08275	55,64912	93,39593	ААА
14	Газпромнефть 2019	4,278816	858,7619	5,235573	0,078364	1,011353	5,090441	-0,55869	7,205278	27,05804	53,51118	66,24087	75,3936	42,63114	55,87343	93,39177	ААА
15	Газпромнефть 2020	4,335075	858,5807	5,241345	0,090197	1,00825	5,089531	-0,55992	6,96618	26,89396	53,16486	66,18175	72,70352	42,33746	55,75508	93,3659	ААА
16	Газпромнефть 2021	4,384782	858,8561	5,244898	0,09589	1,006935	5,091158	-0,5594	7,263048	26,93499	54,72127	66,1379	73,94138	42,75657	56,00865	93,43251	ААА
17	Группа продовольствие 2018	-0,51025	-12,1727	-0,68283	4,217407	-0,35038	-8,69612	3,448025	-0,00873	-0,71864	-0,45855	-1,99419	-26,3252	-6,03884	-16,4878	-93,6293	В
18	Группа продовольствие 2019	-0,51164	-12,1436	-0,67827	4,159912	-0,28945	-8,69589	3,364618	-0,02514	-0,64559	-0,42413	-1,99336	-26,3252	-6,03764	-16,5328	-93,5661	В
19	группа продовольствие 2020	-0,5131	-12,2051	-0,66521	4,221103	-0,35281	-8,69653	3,421701	-0,06335	-0,75558	-0,6297	-2,00392	-26,3145	-6,02892	-16,4528	-93,4289	В
20	Группа продовольствие 2021	-0,51002	-12,2238	-0,67523	4,341396	-0,39704	-8,69664	3,557744	-0,06998	-0,76404	-0,68837	-2,00381	-26,3174	-6,04438	-16,4169	-93,4583	В
21	ГТЛК 2018	1,570276	280,88	0,397347	1,375222	0,819569	0,637418	0,393297	-0,82032	0,359188	-7,35702	6,822764	9,149379	14,85715	17,86337	6,055423	А
22	ГТЛК 2019	1,047461	294,0129	0,338805	1,400812	0,815872	0,626206	0,413777	-0,67001	0,937149	-7,23074	51,58048	9,151537	14,85739	17,86679	6,011392	А
23	ГТЛК 2021	3,352357	628,4407	2,820691	0,77249	0,90724	3,168409	-0,05613	2,674736	14,96268	20,32356	31,80899	40,35142	28,04992	36,32115	49,21072	АА
24	ГТЛК2020	1,531599	355,0497	0,388458	1,405695	0,815275	1,026722	0,408728	-0,82653	3,755235	-7,55231	4,124908	9,148053	14,82786	17,8444	6,018067	А
25	ЗТЗ 2018	0,155019	145,1816	0,218954	2,970344	0,155964	-2,24414	1,648693	0,062748	0,207963	0,532135	0,479479	1,827701	-1,09289	-0,66091	16,19028	ВВВ
26	ЗТЗ 2019	0,131888	145,2188	0,198527	2,002114	0,18389	-2,24399	1,404376	0,062349	0,209462	0,448132	0,47939	1,828222	-1,02625	-0,53324	16,95667	ВВВ

27	ЗТЗ 2020	0,129151	145,2408	0,197377	1,798749	0,221906	-2,24385	1,289561	0,060421	0,215024	0,433611	0,479273	1,832821	-1,02363	-0,88299	17,09886	BBB
28	ЗТЗ 2021	0,150034	145,1544	0,205337	1,90932	0,195323	-2,24431	1,336758	0,055414	0,204213	0,485308	0,479261	1,822436	-1,16276	-1,58337	15,70569	BBB
29	инвестгео 2018	0,140825	144,9561	0,180309	1,824313	0,213577	-2,24582	1,316809	0,056677	0,21154	0,399114	0,482065	1,823846	-1,16236	-1,50027	14,69512	BBB
30	инвестгео 2019	-0,1818	66,33136	-0,25435	3,021767	-0,07606	-5,47394	2,354516	-0,02698	-0,28712	-0,21356	-0,76363	-12,244	-3,5535	-8,76034	-37,9424	BB
31	инвестгео 2020	-0,18277	66,32524	-0,25595	3,019078	-0,07495	-5,47394	2,356773	-0,02967	-0,29152	-0,23099	-0,76405	-12,25	-3,59198	-8,91607	-37,9314	BB
32	инвестгео 2021	-0,18453	66,27984	-0,2575	3,067788	-0,0914	-5,47453	2,393852	-0,02954	-0,29331	-0,23041	-0,76353	-12,2535	-3,63463	-9,11963	-39,3141	BB
33	ИСКЧ 2018	-0,19145	65,13935	-0,26902	2,912226	0,022049	-5,48467	2,23068	-0,03836	-0,30043	-0,27081	-0,76486	-12,2465	-3,5793	-8,90982	-50,278	BB
34	ИСКЧ 2019	-0,18402	64,41198	-0,2597	2,913442	0,019697	-5,49055	2,231156	-0,03871	-0,30189	-0,27695	-0,76497	-12,2492	-3,51089	-8,78148	-58,1975	BB
35	ИСКЧ 2020	-0,15544	65,86208	-0,22005	2,921364	0,005758	-5,47774	2,224205	-0,03876	-0,30194	-0,27349	-0,7659	-12,2513	-3,5962	-8,94029	-60,3499	BB
36	ИСКЧ 2021	-0,13372	64,25651	-0,21178	2,891218	0,075357	-5,48516	2,217208	-0,03898	-0,30159	-0,27673	-0,76563	-12,2432	-3,57467	-8,91192	-44,3007	BB
37	Кокс 2020	1,741376	454,5602	0,419175	5,059016	0,792664	1,587358	0,865865	-0,22342	0,162036	-5,4127	-6,20221	9,14239	13,55195	-1,28428	5,867957	A
38	Кокс 2021	0,926862	455,4421	0,342159	1,374169	0,819745	1,591221	0,408144	0,132363	0,313496	-5,86431	-6,34312	9,197801	16,29848	18,80855	5,883032	A
39	Лента 2018	1,298495	455,5088	0,423946	1,35515	0,823356	1,59161	0,375579	0,8449	0,478934	19,67273	-6,52699	9,195347	14,98344	17,9343	5,648669	A
40	Лента 2019	1,45608	455,5047	0,41667	1,348832	0,824768	1,59167	0,374076	0,685748	0,536057	24,28622	-6,52256	9,203669	15,078	17,98306	5,653942	A
41	Лента 2020	1,080487	455,5438	0,389625	1,303907	0,840066	1,591762	0,372683	1,13721	0,501688	19,45123	-6,53053	9,214663	15,3244	18,03278	5,662204	A
42	Лента 2021	2,709644	654,1486	2,808274	0,692439	0,927024	3,313802	-0,08826	4,550167	13,65356	39,5929	28,82763	40,35843	28,1277	36,35059	48,82016	AA
43	Линк 2018	-0,14973	19,73818	-0,22129	2,879503	0,121433	-5,70108	2,221089	-0,02953	-0,24312	-0,01809	0,441716	-10,2934	-3,2446	-8,52505	-31,3492	BB
44	Линк 2019	-0,17438	8,905818	-0,25362	2,893876	0,066935	-5,88005	2,231025	-0,03252	-0,26709	-0,11058	-0,61022	-6,1673	-3,39053	-8,63851	-32,5713	BB
45	Линк 2020	-0,15825	4,497527	-0,23721	2,958433	-0,03827	-5,92001	2,255842	-0,03619	-0,28142	-0,17435	-0,73791	-12,1189	-3,50655	-8,68926	-32,0177	BB
46	Линк 2021	-0,1929	-23,7791	-0,27242	3,101401	-0,09944	-6,13634	2,259249	-0,03557	-0,26999	-0,19287	-0,72414	-12,2586	-3,88933	-10,5763	-32,8918	BB
47	Литана 2021	-0,50849	-11,2139	-0,69734	4,204033	-0,34055	-8,68871	3,503486	-0,11217	-0,7913	-0,88453	-2,00115	-26,3231	-6,05962	-16,5587	-92,9733	B
48	Максима 2020	0,201525	145,1108	0,265582	1,968666	0,187374	-2,2444	1,353199	0,0564	0,211766	0,421276	0,479725	1,822327	-1,14227	-1,48283	15,992	BBB
49	Максима 2021	0,190538	145,1231	0,262217	2,129163	0,174561	-2,24444	1,440837	0,055548	0,210849	0,413372	0,479588	1,828159	-1,07039	-0,78812	13,86833	BBB
50	Мегафон 2018	2,910069	642,4762	2,773561	0,72009	0,917479	3,253961	-0,08045	3,106731	13,54021	30,69296	33,97428	40,3995	28,25991	36,42786	48,94217	AA
51	Мегафон 2019	2,950464	630,444	2,776149	0,730525	0,91484	3,193438	-0,07552	3,067224	13,45866	28,23555	38,84071	40,37241	28,08634	36,34022	48,91044	AA
52	Мегафон 2020	2,69302	638,0249	2,747367	0,722405	0,916858	3,230007	-0,07494	3,055171	13,5412	29,74677	35,56136	40,36939	28,09326	36,34247	48,8822	AA
53	Мегафон 2021	2,749481	649,0444	2,754238	0,700505	0,923755	3,288516	-0,07666	3,130719	13,63697	28,61417	31,6935	40,37345	29,2021	36,82468	48,86867	AA
54	Медиасети2020	-0,19539	64,60871	-0,27169	2,974648	-0,05089	-5,48689	2,27379	-0,03403	-0,29557	-0,23325	-0,76261	-12,2468	-3,5945	-8,93098	-37,126	BB
55	Мосэнерго 2018	5,836833	859,5216	5,493692	-0,01256	1,099621	5,09404	-0,56788	6,87639	29,78144	53,48124	65,51534	72,67724	42,32584	55,49844	93,53139	AAA
56	Мосэнерго 2019	6,767316	859,47	5,614946	-0,01018	1,092239	5,093831	-0,56854	6,78696	29,58877	54,02042	65,48149	72,67616	42,09534	55,46791	93,48134	AAA
57	Мосэнерго 2020	6,540551	859,479	5,572756	-0,01031	1,092626	5,093873	-0,56873	6,75502	28,48667	53,87656	65,46247	72,65807	42,03991	55,45899	93,47334	AAA
58	Мосэнерго 2021	5,87514	859,4829	5,465629	-0,01122	1,095344	5,093857	-0,56919	6,788542	29,11003	55,80131	65,55468	72,63127	42,06059	55,46097	93,48933	AAA
59	Новотранс 2018	0,861035	402,4996	0,311229	1,41863	0,813824	1,149765	0,385547	-0,56033	-0,49153	-3,44379	8,102854	9,221218	16,61155	19,32371	6,117478	A
60	Новотранс 2019	0,910418	415,843	0,316837	1,305199	0,839432	1,312759	0,372118	-0,53273	-0,24718	1,569998	4,819994	9,457526	16,21499	18,37985	6,152439	A
61	Новотранс 2020	0,871551	454,5701	0,319302	1,30091	0,841601	1,585785	0,369621	-0,66674	-0,49957	5,564934	-6,47609	9,304419	15,31128	18,02208	5,950976	A
62	Новотранс 2021	0,865923	444,8253	0,312708	1,300797	0,841661	1,528137	0,37029	-0,62149	-0,39528	0,286505	-4,22195	10,76849	15,37857	18,04674	6,043673	A
63	НПК ОВК 2018	-0,08093	18,34451	-0,1606	2,878733	0,125104	-5,71564	2,209417	-0,03883	-0,26795	-0,19669	-0,71213	-13,1234	-4,07958	-9,51134	-42,4466	BB
64	НПК ОВК 2019	-0,19352	-13,0779	-0,27324	2,87732	0,132099	-6,05683	2,210925	-0,03872	-0,25904	-0,20525	-0,67419	-12,3368	-3,9302	-9,32654	-40,6878	BB
65	НПК ОВК 2020	-0,18637	40,53716	-0,26601	2,878133	0,128032	-5,66511	2,217406	-0,03789	-0,2269	-0,19864	-0,6795	-19,1188	-4,704	-10,2316	-38,2569	BB
66	НПК ОВК 2021	-0,17024	42,91841	-0,2499	2,877658	0,130397	-5,60506	2,216862	-0,03816	-0,24266	-0,2412	-0,65411	-12,2465	-3,52633	-8,86305	-38,1908	BB
67	ОР 2018	0,158108	145,2948	0,374318	1,684121	0,312078	-2,24343	1,186187	0,050963	0,211372	0,3839	0,478841	1,835284	-1,07642	-1,19712	17,87439	BBB
68	ОР 2019	0,138559	145,2866	0,344053	1,705442	0,282313	-2,24351	1,182605	0,050135	0,205416	0,386967	0,478824	1,835232	-1,09092	-1,2156	17,49511	BBB
69	ОР 2020	0,131867	145,2824	0,333352	1,723046	0,264666	-2,24354	1,17921	0,049716	0,203616	0,392409	0,47882	1,825876	-1,12789	-1,30918	16,64174	BBB
70	ОР 2021	-0,19423	66,52471	-0,1524	3,132188	-0,10528	-5,47264	2,310236	-0,03648	-0,2997	-0,24822	-0,76618	-12,2563	-3,79494	-10,1652	-39,9705	BB
71	ПАО Газпром 2018	4,533152	859,3329	5,288284	-0,0014	1,071224	5,092996	-0,5682	6,525367	27,02948	51,33159	65,33102	72,61499	42,1576	55,49333	93,58672	AAA
72	ПАО Газпром 2019	4,341059	859,3484	5,273825	-0,00237	1,073156	5,093026	-0,56852	6,495144	27,07787	51,42502	65,30328	72,61229	42,01559	55,46491	93,5212	AAA
73	ПАО Газпром 2020	4,352824	859,3161	5,267899	0,000673	1,067302	5,092885	-0,56774	6,455035	26,94035	50,75734	65,31297	72,57213	41,35535	55,33661	93,39172	AAA
74	ПАО Газпром 2021	4,597507	859,346	5,285306	-0,00061	1,069679	5,093128	-0,5673	6,510753	27,27943	50,83491	65,32905	72,63197	42,71674	55,60377	93,69543	AAA
75	ПАО Магнит 2018	6,527483	711,7209	3,172038	0,624901	1,010472	4,019139	-0,09298	2,584835	12,58273	20,14527	28,80316	41,57993	29,67317	36,55064	48,39003	AA

76	ПАО Магнит 2019	4,404878	533,9977	2,936139	0,636959	0,978692	3,135025	-0,0934	2,585224	12,57223	20,30159	28,83024	43,83587	29,55126	36,60403	47,34021	AA
77	ПАО Магнит 2021	3,612073	590,7325	2,848078	0,652474	0,955286	3,14866	-0,09277	2,584836	12,57814	20,1671	28,70015	44,8011	29,79131	36,75567	47,44432	AA
78	ПАО Магнит2020	4,008076	553,3567	2,892076	0,649104	0,95936	3,006096	-0,09305	2,585277	12,58262	20,21386	28,72711	88,71614	28,96675	36,53619	48,47079	AA
79	Почта России 2019	4,853711	859,273	5,297662	0,399624	0,985005	5,092772	-0,55129	6,387641	26,69228	51,10037	65,3152	72,59317	41,71454	55,42892	93,43647	AAA
80	Почта России 2020	4,834669	859,2342	5,295442	0,356588	0,986123	5,092622	-0,55332	6,86727	27,30209	55,88424	65,63286	72,59195	41,75876	55,49693	93,41766	AAA
81	Почта России 2021	4,803017	859,1901	5,291551	0,419679	0,984554	5,092229	-0,55164	6,76423	27,10733	55,08218	65,59953	72,59094	41,70672	55,41561	93,42721	AAA
82	Распадская 2021	2,382852	647,4836	2,712301	0,649224	0,959207	3,278298	-0,08751	2,759591	12,75809	20,88114	30,17915	41,65925	31,86806	37,22937	49,37526	AA
83	Регион продукт 2021	-0,48573	-12,3319	-0,61821	4,172072	-0,30755	-8,69747	3,330688	-0,11093	-0,76926	-0,82075	-2,00533	-26,3239	-6,04331	-16,5352	-93,1836	B
84	Регион продукт2020	-0,49974	-12,3112	-0,63858	4,163588	-0,29537	-8,69728	3,312688	-0,11137	-0,77318	-0,78934	-2,00569	-26,3241	-6,04546	-16,5458	-92,8189	B
85	Редсофт 2018	0,244672	65,53703	0,174908	2,893135	0,069222	-5,47275	2,213222	-0,03491	-0,27236	-0,00347	-0,76126	-12,2511	-3,5986	-8,94595	-37,0459	BB
86	Редсофт 2019	0,015494	14,97346	-0,06435	2,901886	0,044867	-5,20324	2,212906	-0,03343	0,453387	0,116013	-0,50024	-12,1921	-3,47409	-8,7418	-34,1739	BB
87	Редсофт 2020	-0,04467	-33,7341	-0,12456	2,916937	0,013266	-2,81192	2,231536	-0,03097	-0,28663	-0,14104	1,150011	-12,2314	-3,49724	-8,74877	-36,4425	BB
88	Редсофт 2021	0,161223	-50,7938	0,081357	2,90728	0,032291	-4,62733	2,213485	-0,03	-0,27686	0,324989	-0,06583	-12,1007	-3,48252	-8,74293	-35,9632	BB
89	РКС 2020	1,364993	461,3899	0,367589	1,241965	0,923832	1,612966	0,369471	-0,87835	-2,04424	-7,28662	-4,48435	9,201129	15,91172	17,99446	4,551767	A
90	РКС 2021	2,033209	472,1884	0,44145	1,246524	0,908936	1,763239	0,370403	-0,74377	0,494365	-6,35735	18,23548	9,18076	15,40919	17,93437	5,349282	A
91	Россети 2021	8,158111	897,3091	5,658996	-0,0155	1,110102	5,699415	-0,5707	6,226711	31,85552	50,02327	76,6007	72,59417	42,13581	55,46527	94,10939	AAA
92	Россети 2021	12,6756	1017,929	6,160941	-0,01607	1,112348	6,761357	-0,57061	6,249563	36,53205	50,47596	85,6937	72,56407	41,07398	55,32132	94,2123	AAA
93	Россети 2021	39,51362	847,6501	9,143273	-0,0142	1,105267	5,797405	-0,57096	6,26693	40,42041	56,93213	85,41139	72,58252	41,47159	55,37319	94,21734	AAA
94	Россети 2021	49,73033	1021,705	10,27886	-0,01685	1,115525	6,45381	-0,57047	6,277037	46,19343	50,74143	80,49143	72,60695	43,82341	55,68511	94,27087	AAA
95	Ростелеком 2018	2,493337	653,0796	2,731105	0,667785	0,941113	3,307734	-0,08855	3,089627	13,34084	25,39001	29,64319	40,36109	28,11145	36,33737	48,85858	AA
96	Ростелеком 2019	2,680239	653,0069	2,753564	0,674509	0,936474	3,307623	-0,08833	3,064205	13,36318	26,2763	29,61972	40,34738	28,00375	36,30284	48,83539	AA
97	Ростелеком 2020	2,610929	652,8016	2,748462	0,683505	0,931289	3,305961	-0,08834	3,018886	13,54411	26,90234	27,6951	40,34708	27,95305	36,28258	48,82646	AA
98	Ростелеком 2021	2,67044	652,7807	2,752529	0,689558	0,928317	3,306032	-0,08776	2,985767	13,4957	25,65034	29,58168	40,36549	28,19896	36,37786	48,80926	AA
99	Русгидро 2020	5,263523	859,473	5,346818	-0,00888	1,088581	5,093814	-0,56861	6,356591	29,50416	50,05269	65,67412	72,71744	41,95106	55,44642	93,80803	AAA
100	Русгидро 2021	4,360551	859,4141	5,241924	-0,00896	1,088787	5,093285	-0,56845	6,363311	26,9876	50,02424	65,68558	72,84551	42,04443	55,46151	93,78917	AAA
101	Самолет 2020	0,1672	120,3975	0,202228	1,7278	0,260647	-2,41682	1,181297	0,046573	0,200285	0,342215	0,47896	1,826575	-1,14203	-1,35079	17,89498	BBB
102	Самолет 2021	1,584177	317,6199	0,391792	1,518453	0,806669	0,919948	0,384948	-0,89355	-0,51269	-7,61113	-6,70623	9,212726	15,08257	18,15615	6,025057	A
103	Сибнефтехимтрейд 2021	-0,51347	-12,1973	-0,67901	4,329867	-0,39451	-8,69649	3,600672	-0,02354	-0,63838	-0,55796	-2,00083	-26,3091	-6,0422	-16,4134	-93,5563	B
104	СибСтекло 2021	-0,18205	66,36798	-0,22407	3,184204	-0,1129	-5,47372	2,427359	-0,02955	-0,29031	-0,21693	-0,76552	-12,2512	-3,55719	-8,63618	-36,7012	BB
105	сити 2021	-0,18827	64,26612	-0,26797	2,92308	0,003019	-5,56617	2,324307	-0,03773	-0,28692	-0,26654	-0,75745	-12,2376	-3,58788	-8,92301	-37,2758	BB
106	СУЭК 2018	2,405836	647,0298	2,716631	0,666576	0,942031	3,245051	-0,09063	2,982654	13,53806	25,07364	36,21461	53,02025	29,53965	36,77471	48,84246	AA
107	СУЭК 2019	2,383867	647,4426	2,713846	0,654683	0,95284	3,277525	-0,09075	2,952557	13,75441	23,70224	33,22833	40,4468	29,17729	36,61105	48,8493	AA
108	СУЭК 2020	1,438969	444,7652	0,376736	1,297304	0,843583	1,541775	0,370768	-0,6236	1,197878	-3,05422	-2,53855	9,049639	14,7557	17,81741	5,679954	A
109	СУЭК 2021	2,684819	638,5816	2,745561	0,687017	0,92952	3,233722	-0,0914	2,721526	14,02489	22,93874	30,8835	40,88623	28,31379	36,42066	48,86901	AA
110	Татнефтехим 2021	-0,18301	66,53757	-0,13943	2,909482	0,027591	-5,4725	2,253099	-0,01593	-0,145	-0,08842	-0,76524	-12,2277	-3,53958	-8,83987	-38,2773	BB
111	ТД РЖД 2020	0,128173	148,2985	0,162364	2,467996	0,162808	-2,22143	2,601828	0,04992	0,200589	0,348457	0,51654	1,830236	-1,11256	-1,23055	16,15398	BBB
112	ТД РЖД2018	0,136107	149,4395	0,170289	2,446144	0,163287	-2,22178	2,431752	0,048202	0,199983	0,344497	0,512611	1,850655	-1,10853	-1,16224	17,0124	BBB
113	ТД РЖД2019	0,134308	146,2951	0,168877	2,291498	0,167524	-2,23554	2,229935	0,048741	0,200197	0,345853	0,486978	1,834533	-1,10517	-1,13473	17,29035	BBB
114	ТД РЖД2021	0,132092	146,4986	0,166501	2,166841	0,172578	-2,2323	2,068614	0,04772	0,199634	0,342891	0,482886	1,830347	-1,10983	-1,2134	15,53834	BBB
115	ТерГенКом 2018	0,137325	145,1436	0,1928	1,681651	0,316375	-2,24477	1,170895	0,057609	0,228814	0,514127	0,48047	1,829172	-1,10826	-1,26058	15,82854	BBB
116	ТерГенКом 2019	0,13928	145,1601	0,202273	1,675872	0,327341	-2,24459	1,158274	0,057538	0,227936	0,604254	0,480154	1,830145	-1,08791	-1,22437	15,80108	BBB
117	ТерГенКом 2020	0,144944	145,1749	0,207181	1,673336	0,332607	-2,24441	1,154563	0,057378	0,222863	0,667545	0,480018	1,829048	-1,09033	-1,23001	15,72854	BBB
118	ТерГенКом 2021	0,149757	145,1501	0,205912	1,671568	0,33646	-2,24452	1,154671	0,057392	0,217548	0,683893	0,480315	1,829519	-1,09313	-1,23574	15,43123	BBB
119	ТФН 2020	-0,19546	66,56026	-0,18923	2,940431	-0,02027	-5,47236	2,317479	-0,01347	-0,25212	-0,16447	-0,76561	-12,2512	-3,55957	-8,85063	-38,9387	BB
120	ТФН 2021	-0,18867	66,55603	-0,19622	2,961877	-0,04119	-5,47237	2,340576	-0,01001	-0,2508	-0,15188	-0,76548	-12,2513	-3,56586	-8,85112	-38,5406	BB

121	уралкалий 2018	1,17095	453,5165	0,349667	1,287935	0,849547	1,581194	0,371347	-0,71589	1,40805	-4,12356	-6,52567	9,093805	14,77651	17,82658	6,113856	A
122	уралкалий 2019	1,02472	454,3791	0,337233	1,272088	0,863482	1,585218	0,3714	-0,7035	1,293727	-4,76569	-6,57445	9,227416	15,58206	18,03719	6,145002	A
123	уралкалий 2020	1,702242	454,0484	0,411365	1,564362	0,804717	1,584085	0,400752	-0,61854	1,131583	-5,80321	-6,51325	9,31259	14,85458	17,88366	5,543553	A
124	Уралкалий 2021	1,167563	454,0742	0,35331	1,376811	0,819307	1,583425	0,38122	-0,4569	2,222502	-4,21462	-6,52822	9,680732	16,49101	18,95199	5,570369	A
125	Феррони 2021	-0,19606	66,47935	-0,21062	3,145958	-0,10754	-5,47295	2,324564	0,002538	-0,26694	0,214049	-0,76513	-12,2496	-3,56873	-8,74417	-38,8556	BB
126	Флай 2020	-0,46165	-12,2403	-0,61867	4,209208	-0,34457	-8,69655	3,38391	-0,11866	-0,79647	-0,89852	-2,00618	-26,3251	-6,07755	-16,6101	-87,1643	B
127	Флай 2021	-0,4764	-12,1769	-0,66217	4,186358	-0,32437	-8,69552	3,392584	-0,11922	-0,79717	-0,90282	-2,00607	-26,3244	-6,01747	-16,4594	-97,5112	B
128	Фэс агро 2021	0,137308	145,2753	0,225053	1,890293	0,198526	-2,24354	1,39732	0,059396	0,208756	0,405634	0,479109	1,828728	-1,08154	-1,06931	15,97621	BBB
129	Фэс агро 2019	0,135854	145,2716	0,226621	1,937527	0,191211	-2,24356	1,414262	0,060232	0,207058	0,415723	0,479101	1,828352	-1,07384	-0,98339	15,80943	BBB
130	Фэс агро 2020	0,137289	145,2729	0,217611	1,907766	0,19557	-2,24354	1,413188	0,061477	0,208714	0,415975	0,479182	1,829095	-1,07858	-1,0385	15,90942	BBB
131	центр резерв 2021	-0,46239	-12,1938	-0,50788	4,129522	-0,21653	-8,69646	3,307854	-0,10765	-0,75528	-0,50816	-2,00587	-26,3198	-5,89334	-16,3579	-91,114	B
132	ЭБИС 2020	-0,1828	66,53759	-0,05401	2,956484	-0,03655	-5,47251	2,317541	-0,02421	-0,13479	-0,20567	-0,7657	-12,2494	-3,48688	-8,63921	-37,8441	BB
133	ЭБИС 2021	-0,16909	66,46715	-0,16358	2,984321	-0,05724	-5,47293	2,294964	-0,03003	-0,17159	-0,21138	-0,76579	-12,251	-3,53406	-8,7313	-36,4159	BB
134	ЭКО 2020	0,129759	145,2718	0,204514	1,772553	0,232797	-2,24364	1,294511	0,062897	0,22349	0,425354	0,479369	1,829498	-1,05348	-1,04283	16,18505	BBB
135	ЭКО 2021	0,147138	145,1605	0,203149	1,782282	0,228415	-2,24436	1,264049	0,069084	0,232396	0,54739	0,480574	1,8284	-1,0402	-0,97849	15,80644	BBB
136	Электроаппарат 2021	-0,48912	-12,2087	-0,6669	4,364217	-0,40148	-8,69614	3,606768	-0,08478	-0,74434	-0,76571	-2,00221	-26,323	-5,83622	-15,1342	-92,3103	B
137	ЯТЭК 2018	1,35705	454,9996	0,369345	1,296532	0,844028	1,590241	0,374604	-0,6737	-0,67902	-6,30119	-6,5641	9,195317	15,08052	17,9323	5,906921	A
138	ЯТЭК 2019	1,59247	454,9967	0,395731	1,297513	0,843464	1,590881	0,370007	-0,69354	-0,56373	-2,67588	-6,59494	9,160679	14,89815	17,86819	5,909572	A
139	ЯТЭК 2020	1,821446	455,2476	0,448023	1,277737	0,857808	1,590261	0,371821	-0,62902	-0,19666	-4,85418	-6,62655	9,165474	14,93473	17,87276	6,025441	A
140	ЯТЭК 2021	2,500616	455,2328	0,516782	1,284009	0,852472	1,590456	0,373053	-0,62242	0,095514	-5,34865	-6,61839	9,188891	15,29867	17,98618	5,991153	A

СПРАВКА

Кубанский Государственный университет









о результатах проверки текстового документа
на наличие заимствований

ПРОВЕРКА ВЫПОЛНЕНА В СИСТЕМЕ АНТИПЛАГИАТ.ВУЗ

Автор работы: Колесниченко Никита Юрьевич
Самоцитирование
рассчитано для: Колесниченко Никита Юрьевич
Название работы: ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ
ОЦЕНКИ КРЕДИТОСПОСОБНОСТИ ПРЕДПРИЯТИЙ
Тип работы: Магистерская диссертация
Подразделение: ФКТиПМ, кафедра анализа данных и искусственного интеллекта

РЕЗУЛЬТАТЫ

■ ОТЧЕТ О ПРОВЕРКЕ КОРРЕКТИРОВАЛСЯ: НИЖЕ ПРЕДСТАВЛЕНЫ РЕЗУЛЬТАТЫ ПРОВЕРКИ ДО КОРРЕКТИРОВКИ

ЗАИМСТВОВАНИЯ		25.03%	ЗАИМСТВОВАНИЯ		25.03%
ОРИГИНАЛЬНОСТЬ		67.9%	ОРИГИНАЛЬНОСТЬ		67.9%
ЦИТИРОВАНИЯ		7.07%	ЦИТИРОВАНИЯ		7.07%
САМОЦИТИРОВАНИЯ		0%	САМОЦИТИРОВАНИЯ		0%

ДАТА ПОСЛЕДНЕЙ ПРОВЕРКИ: 15.06.2022

ДАТА И ВРЕМЯ КОРРЕКТИРОВКИ: 15.06.2022 10:52

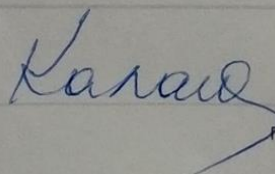
Модули поиска: ИПС Адилет; Библиография; Сводная коллекция ЭБС; Интернет Плюс; Сводная коллекция РГБ; Цитирование; Переводные заимствования (RuEn); Переводные заимствования по eLIBRARY.RU (EnRu); Переводные заимствования по Интернету (EnRu); Переводные заимствования издательства Wiley (RuEn); eLIBRARY.RU; СПС ГАРАНТ; Модуль поиска "КубГУ"; Медицина; Диссертации НББ; Патенты СССР, РФ, СНГ; СМИ России и СНГ; Кольцо вузов; Издательство Wiley; Переводные заимствования

Работу проверил: Калайдина Г В

ФИО проверяющего

Дата подписи:

15.06.2022



Подпись проверяющего



Чтобы убедиться
в подлинности справки, используйте QR-код,
который содержит ссылку на отчет.

Ответ на вопрос, является ли обнаруженное заимствование
корректным, система оставляет на усмотрение проверяющего.
Предоставленная информация не подлежит использованию
в коммерческих целях.

Отзыв

на выпускную квалификационную работу студента факультета компьютерных технологий и прикладной математики Колесниченко Н.Ю.

«Использование методов машинного обучения и искусственного интеллекта для оценки кредитоспособности предприятий»

Данная работа посвящена изучению финансового состояния предприятия, а также разработке нейронной сети, позволяющей оценить кредитоспособность предприятия в соответствии с национальной рейтинговой шкалой. Актуальность данной работы обусловлена тем, что в условиях рыночной экономики вопрос кредитования предприятий стоит особо остро, а методы оценки и анализа финансового состояния предприятий продолжает непрерывное развитие.

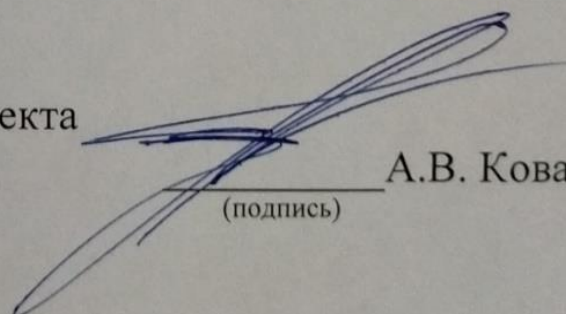
В ходе работы над проектом автором был произведен анализ предметной области, в частности изучена специфика оценки финансового состояния предприятия.

Колесниченко Н.Ю. была разработана нейронная сеть, основной функцией которой является отнесение предприятия к одному из представленных в национальной рейтинговой шкале классов. Нейронная сеть разработана с использованием пакета Statistica Neural Networks, для анализа качества разработанной сети были использованы встроенные средства программы Statistica.

Колесниченко Н.Ю. проявил высокий уровень самостоятельности; умение находить необходимую информацию; проявил профессионализм и хорошую подготовленность в области прикладной информатики.

Существенных замечаний к работе нет. Работа выполнена и оформлена в соответствии с действующими требованиями. Считаю, что работа «Использование методов машинного обучения и искусственного интеллекта для оценки кредитоспособности предприятий» Колесниченко Н.Ю. заслуживает оценки « *отл* »

Заведующий кафедрой
анализа данных и искусственного интеллекта
д-р тех. наук, доцент


А.В. Коваленко
(подпись)

15.06.22

Рецензия
на выпускную квалификационную работу (магистерская диссертация)
Колесниченко Никиты Юрьевича
по направлению подготовки 01.04.02
«Математическое и информационное обеспечение экономической деятельности»

Выпускная квалификационная работа Колесниченко Н.Ю. выполнена на актуальную на сегодняшний день тему, поскольку проблема оценки кредитоспособности предприятия является достаточно актуальной в современных реалиях. Автором разработана и программно реализована нейронная сеть по оценке кредитоспособности предприятия и его отнесения его к одной из категорий в соответствии с национальной рейтинговой шкалой.

Колесниченко Н.Ю. обработано большое количество научного материала, на высоком теоретическом и методологическом уровне проведено исследование предметной области. Материал в выпускной квалификационной работе логически структурирован, написан научным стилем изложения.

В первой главе выпускной квалификационной работы автором проведен достаточно подробный и квалифицированный анализ теоретических основ анализа кредитоспособности предприятия. Детально раскрыты методы анализа. Определены цели и методика анализа кредитоспособности предприятия.

Во второй главе работы автором представлена краткая техническая характеристика нейронных сетей. Показаны основные этапы программной реализации разработки.

В третьей главе представлен анализ финансовых результатов при практическом применении разработки на основе финансовых данных предприятий.

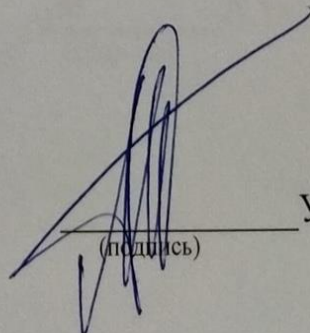
Автор выпускной квалификационной работы показал отличную способность формулировать собственную точку зрения по рассматриваемой проблеме. Сформулированные в работе выводы достаточно обоснованы и могут быть использованы в практической деятельности.

В ходе подготовки и защиты ВКР Колесниченко Н.Ю. показал высокий уровень сформированности необходимых компетенций.

ВКР не содержит существенных недостатков.

Выпускная квалификационная работа соответствует требованиям, предъявляемым к выпускным квалификационным работам, и может быть рекомендована к защите на заседании государственной аттестационной комиссии. Работа заслуживает оценки хорошо.

профессор кафедры прикладной математики,
д-р физ.-мат. наук



Уртенов М.Х.

(подпись)