

САНКТ–ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ

ВИКТОРОВА Анна Романовна

Выпускная квалификационная работа

***Нейросетевой анализ
финансовой устойчивости предприятия***

уровень образования: бакалавриат

Направление 02.03.02

«Фундаментальная информатика и информационные технологии»

ООП «Программирование и информационные технологии»

Научный руководитель:

к.т.н., старший преподаватель

кафедры моделирования

социально–экономических систем

Новожилова Л.М.

Рецензент:

к. ф.–м. н., доцент кафедры

моделирования экономических

систем

Ковшов А.М.

Санкт–Петербург

2019

Содержание

Введение	3
Постановка задачи разработки нейросетевой модели прогнозирования финансовой неустойчивости	5
Обзор литературы	6
Глава 1. Теоретические основы прогнозирования банкротства	8
1.1. Понятие банкротства.....	8
1.2. Обзор основных методов прогнозирования финансовой неустойчивости .	9
1.3. Нейронные сети как инструмент прогнозирования банкротства	16
Глава 2. Построение, обучение и тестирование нейронной сети для прогнозирования банкротства	18
2.1. Математическая постановка задачи, подготовка данных и среды разработки	18
2.2. Обучение нейронной сети.....	19
2.3. Тестирование нейронной сети	26
Глава 3. Анализ работы программы.....	27
Выводы	29
Заключение	31
Литература	32

Введение

Проблема предсказания банкротства на предприятии была актуальна всегда. За всё время её существования было разработано множество способов её решения, прогнозирующих наступление банкротства организации с той или иной вероятностью. Однако, эта задача до сих пор не решена. Методов, прогнозирующих наступление состояния финансовой неустойчивости предприятия с достаточно высокой точностью, практически нет. К тому же, большая часть популярных методик показали свою несостоятельность во время мирового финансового кризиса, начавшегося в 2008 году. [1, 2, 3]

В актуальных исследованиях по теме прогнозирования банкротства преобладают работы, изучающие деятельность фирм, развитых и крупнейших развивающихся стран. Российские компании в научных работах рассматриваются крайне редко. К тому же, доказан тот факт, что применение моделей, разработанных на данных компаний развитых стран к компаниям развивающихся, существенно снижает предсказательную способность. Чтобы создать модель предсказания банкротства на российском рынке, работающую с точностью, превышающей стандартный финансовый анализ, необходимо использовать национальные данные. [4]

Все способы прогнозирования можно разделить на 3 класса: статистические модели, модели искусственного интеллекта и теоретические модели. На данный момент нет ответа на вопрос, какая методология прогнозирования банкротства является лучшей. В этом исследовании мы будем работать именно с нейросетевыми моделями предсказания банкротства, поскольку применение информационных технологий не только исключает человеческий фактор (ошибки в вычислениях), но и в дальнейшей перспективе позволит достигнуть наиболее высокой точности прогнозирования.

Нейронные сети (НС) применяются для решения широкого спектра задач и прогнозирование лишь одна из их возможностей. НС используют для

прогноза финансовой неустойчивости такие корпорации, как General Electric, American Airlines, Coca Cola, Procter&Gamble и другие.

Цель данной выпускной квалификационной работы бакалавра: составление нейронной сети для прогнозирования банкротства, в основе которой лежит математическая модель предсказания банкротства, разработанная для реалий России.

Объектом исследования является институт финансовой неустойчивости (банкротства). Предмет исследования — нейросетевой метод предсказания финансовой неустойчивости предприятия.

В данной работе нам предстоит решить такие проблемы как: выбор наилучшего статистического метода диагностики финансовой неустойчивости; сбор достаточного количества качественных данных (финансовой отчетности обанкротившихся и финансово устойчивых предприятий); разработка и обучение нейронной сети; тестирование нейронной сети; информационный анализ полученных результатов.

Структура работы выглядит следующим образом. После введения дан обзор литературы по изучаемой теме и сформулирована постановка задачи на естественном языке. В первой главе представлены необходимые теоретические выкладки по теме банкротства и существующих моделей (методов) его прогнозирования, сделан выбор статистической модели, показатели которой станут основой нейронной сети. Вторая глава посвящена подготовке данных, обучению и тестированию нейронной сети. В третьей главе представлены полученные результаты работы по решению задачи выпускной квалификационной работы. В разделе «Выводы» проводится анализ полученных результатов и оценка возможности улучшения разработанной сети. В заключении подведены итоги проведенной работы.

Постановка задачи разработки нейросетевой модели прогнозирования финансовой неустойчивости

Основная цель данной работы — разработать нейронную сеть, которая на вход получает несколько коэффициентов финансовой отчётности за определенный временной промежуток, а на выходе возвращает целое число (класс банкротства) от 0 до 3. Если 0, то предприятие финансово устойчиво, если 1–3, то предприятие обанкротится в ближайшие 1–3 года соответственно.

Для достижения этой цели поставлены следующие задачи:

- 1) изучить предметную область;
- 2) дать обзор и провести анализ существующих методик оценки банкротства;
- 3) выбрать наилучшую математическую модель, разработанную для реалий России;
- 4) собрать необходимые для обучения и тестирования сети данные;
- 5) разработать нейросетевую модель, на основе математической модели и провести её обучение и тестирование;
- 6) осуществить анализ полученных результатов.

Обзор литературы

В рамках исследования было изучено большое количество материалов по созданию нейронных сетей, финансовому анализу и прогнозированию банкротства, что позволило сформировать конструктивный подход к решению поставленной задачи.

Статистические модели диагностики банкротства

1. Т.М. Жукова, К.С. Кондратьева. Современные особенности применения экономических моделей диагностики вероятности наступления банкротства. В статье проанализированы вопросы, связанные с применением математических моделей прогнозирования банкротства. Авторы дают обширный обзор на существующие модели–предсказатели банкротства. Данная работа является скорее теоретическим обзором, в ней не даётся оценка существующих моделей авторами. [5]

2. Е.А. Фёдорова, С.Е. Долженко, Ф.Ю. Фёдоров. Модели прогнозирования банкротства российских предприятий: отраслевые особенности. Статья дает базу показателей для разрабатываемой нейросети, в ней на основе анализа финансовой отчётности 8537 предприятий, разработана статистическая восьмифакторная модель прогнозирования банкротства с отраслевыми пороговыми значениями. Именно эта модель легла в основу разработанной в рамках данного исследования нейронной сети. Точность этой модели достигает 91,4% на выборке компаний–банкротов. Что является наилучшим межотраслевым результатом среди отечественных моделей. В статье продемонстрировано преимущество разработанной модели перед другими отечественными моделями, но не указано дальнейшие возможности развития данной модели. [6]

Также стоит отметить полезные интернет ресурсы по данной теме. Источники [7] и [8] являются полезным теоретическим пособием по моделям

статистическим моделям прогнозирования банкротства, как отечественным, так и зарубежным.

Нейросетевые модели диагностики банкротства

3. Д.С.Корнеев. Использование аппарата нейронных сетей для создания модели оценки и управления рисками предприятия.

В работе рассматривается один из подходов к прогнозированию банкротства, основанный на применении нейронных сетей. Д.С. Корнеев приводит области прогнозирования рисков, в которых применение нейронных сетей является необходимым. Автор выделяет преимущества и недостатки нейронных сетей для таких задач как прогнозирование и классификация. В статье изложено большое количество теоретической и практической информации по теме прогнозирования банкротства предприятия с помощью нейронных сетей. Несмотря на то, что данная работа написана в 2007 году, она всё ещё актуальна. [9]

4. Tarh Rashid. Make Your Own Neural Network.

Данная книга — практическое пособие по нейронным сетям. В ней пошагово рассказывается как разрабатывать НС на языке Python. [10]

5. Никифорова Н.А., Донцов Е.В. Применение нейросетевого моделирования для прогнозирования финансового состояния предприятий. В статье рассматриваются вопросы прогнозирования финансовой несостоятельности предприятия с помощью применения двухслойной нейронной сети. Статья оказалась крайне полезной, так как авторы разработали программу, прогнозирующую финансовое состояние предприятия на следующий отчетный период. [11]

Также следует отметить ещё несколько материалов по данной теме, а именно [12], [13] и [14]. В этих источниках изложено много интересных особенностей применения нейронных сетей в области прогнозирования банкротства предприятия.

Глава 1. Теоретические основы прогнозирования банкротства

1.1. Понятие банкротства

Термин «банкротство» происходит от итальянского словосочетания «*banca rotta*», что переводится как «сломанная скамья». Он происходит от тех времен, когда ростовщики совершали свои сделки сидя на скамьях, которые называли банками. Если ростовщик разорялся, он ломал свою скамью, тем самым объявляя свою деятельность оконченной. [15]

Банкротство (несостоятельность) — это невозможность лица оплачивать свои долги и обязательные (налоговые и другие) платежи. При этом долги должны тянуться на срок, более чем 3 месяца, а у физических лиц сумма задолженности должна быть не меньше 500 000 рублей. Статус банкрота присваивается человеку или организации после завершения судебной процедуры, описанной в федеральном законе №127–ФЗ «О несостоятельности (банкротстве) от 27.09.2002». [15, 16]

В рамках данной работы понятие «банкротство» рассматривается как наступление состояния финансовой неустойчивости предприятия. В такой ситуации затрагиваются интересы как руководства и работников предприятия, так и его кредиторов, партнеров и инвесторов. Отслеживание вероятности наступления банкротства фирмы очень важно всегда. Так как это помогает минимизировать финансовые потери от краха фирмы, а иногда и вовсе предотвратить наступление банкротства.

Цель прогнозирования банкротства — управление финансовой устойчивостью и кредитоспособностью предприятия. Регулярное проведение диагностики предприятия с целью выявить приближающееся банкротство — один из самых эффективных методов в управлении организацией. Грамотная политика управления ресурсами фирмы особенно необходима в случаях, когда

возникает необходимость приспособливаться неустойчивому состоянию экономики в условиях мирового кризиса.

1.2. Обзор основных методов прогнозирования финансовой неустойчивости

Несмотря на то, что на сегодняшний день существует большое количество моделей прогнозирования банкротства, их число продолжает расти. Это связано с тем, что место общепринятой модели ещё пусто. В большинстве стран экономическая ситуация, модель составления финансовой отчётности и законодательство различны. Поэтому каждая страна разрабатывает свои или адаптирует зарубежные модели, делая их более адекватными для национальных условий.

Что касается России, то многочисленные попытки адаптировать зарубежные модели по отношению к национальным условиям не приносят достаточно точных результатов. Институт банкротства в нашей стране очень молод, поэтому отсутствие статистики банкротств предприятий существенно затрудняет разработки национальной модели.

Нами будут рассмотрены и проанализированы наиболее популярные зарубежные и российские модели прогнозирования банкротства.

Первые исследования в области прогнозирования банкротства проводились в 1930–х годах в США. Именно тогда был сделан вывод о том, что определенные финансовые показатели фирм, оказавшихся банкротами, и фирм, удержавшихся на плаву, имеют различия уже за несколько лет до наступления банкротства. Первые методы прогнозирования банкротства предложены в 1966 году У. Бивером и в 1968 году Э. Альтманом.

Модель Бивера. У. Х. Бивер первый проанализировал соотношение коэффициентов финансовой отчётности и заметил их влияние на наступление банкротства. По его системе показателей, отношение чистого денежного потока к сумме долга, определяет риск наступления банкротства организации.

Главное отличие метода Бивера от других способов диагностики банкротства — не учитывается вес каждого отдельного коэффициента. По этому методу мы сравниваем значение нескольких коэффициентов с нормой и в результате присваиваем предприятию одно из трёх значений:

- 1) предприятие финансово устойчиво;
- 2) вероятное наступление банкротства в течение 5 лет;
- 3) вероятное банкротство в течении одного года.

В (табл. 1) приведены все значения, на которые необходимо ориентироваться при прогнозировании банкротства по методу Бивера. [7]

Таблица 1. Таблица Бивера [7]

Финансовый показатель:	1	2	3
Коэффициент Бивера (отношение суммы чистой прибыли и амортизации к текущим обязательствам)	0.4–0.45	0.17	–0.15
Коэффициент рентабельности активов, %	6–8	4	–22
Коэффициент финансового «рычага»	<0.37	<0.5	<0.8
Коэффициент покрытия активов чистым оборотным капиталом	0.4	<0.3	–0.06
Коэффициент покрытия	<3.2	<2	<1

Модель Альтмана. Эдвард Альтман известен за создание математической формулы оценки вероятности банкротства. Альтман выявил общие признаки банкротства компаний, путём рассмотрения финансовых показателей предприятий, которые обанкротились, несмотря на положительный финансовый анализ.

Альтман применил статистический метод дискриминантного анализа к набору данных производителей. Первоначально оценка была основана на данных, полученных от открытых производителей, но с тех пор была

переоценена на основе других наборов данных для частных производственных, непроизводственных и сервисных компаний.

Первоначальная формула Z-показателя была следующей:

$$Z = 1,2 * X_1 + 1,4 * X_2 + 3,3 * X_3 + 0,6 * X_4 + 1,0 * X_5$$

• X_1 — оборотный капитал / общая сумма активов;

• X_2 — нераспределенная прибыль / общая сумма активов;

• X_3 — прибыль до вычета процентов и налогов / общая сумма активов;

• X_4 — рыночная стоимость капитала / балансовая стоимость совокупных обязательств, добавляет рыночное измерение, которое может отображать колебания цен на ценные бумаги.

• X_5 — продажи / общие активы, стандартная мера для общего оборота активов (сильно варьируется от отрасли к отрасли). [7]

Альтман обнаружил, что размер отношения для предприятий–банкротов снизился до среднего значения $-0,25$, а для финансово устойчивой группы до среднего значения $+4,48$.

На основе моделей Альтмана построен ряд дискриминантных моделей других экономистов, в том числе модель Спрингейта и модель Беликова–Давыдовой, о которых мы поговорим дальше.

Модель Спрингейта. Разработанная Гордоном Спрингейтом в 1978 году, эта модель использует пошаговый дискриминантный анализ и выдает итоговые оценки для каждой компании. Компании с оценкой Springate ниже $0,862$ классифицируются как «финансово неустойчивые». Эта модель изначально была выпущена компанией Springate для 40 компаний с точностью $92,5\%$. В более поздних тестах, проведенных другими академическими исследователями, тест 50 компаний (со средними активами $2,5$ млн.) показал точность 88% , а тест 24 компаний (со средними активами $63,4$ млн.) показал 83% точности.

Формула модели:

$$Z = 1,03 * A + 3,07 * B + 0,66 * C + 0,4 * D$$

- A — оборотный капитал/ сумма активов;
- B — не распределенная прибыль/сумма активов;
- C — прибыль до налогообложения/текущие обязательства;
- D — прибыль до налогообложения/сумма активов.

При $Z < 0,862$ — высокая вероятность наступления финансовой неустойчивости (банкротства). [7]

Модель Чессера. Чессер, опираясь на статистическую выборку по 40 успешно обслуженным ссудам и 40 ссудам, обслуживание которых было несвоевременным, вывел данную модель, используя показатели финансовой отчётности компаний–заёмщиков. Модель уникальна тем, что оценивает не только вероятность невозврата кредита, но и вероятность просрочки платежей.

Формула модели:

$$Y = -2,0434 - 5,24 * X_1 + 0,0053 * X_2 - 6,6507 * X_3 + \\ 4,4009 * X_4 - 0,0791 * X_5 - 0,1220 * X_6$$

- X_1 — (денежные средства + ценные бумаги) / совокупные активы;
- X_2 — продажи(нетто) / (денежные средства + быстрореализуемые ценные бумаги);
- X_3 — доходы(брутто) / совокупные активы;
- X_4 — совокупная задолженность / совокупные активы;
- X_5 — основной капитал / чистые активы;
- X_6 — оборотный капитал / продажи(нетто).

Итоговый показатель: $Z = 1 / [1 + e^{-Y}]$, где e — 2,71828 (число Эйлера — основание натуральных логарифмов). [12]

Во всех случаях, когда $Z \geq 0,5$, контрагент не выполнит условий договора. В течение эксперимента, продлившегося в банке в течение года, модель Чессера показала точность 75%. [12]

Выше мы рассмотрели зарубежные модели, которые лежат в основе большинства существующих моделей прогнозирования банкротства. Теперь остановимся на российских моделях.

Модель Беликова–Давыдовой. А.Ю. Беликов был одним из первых в России, кто разработал свою модель предсказания банкротства предприятия. В 1998 году он представил свою диссертацию, в которой описал разработанную им модель. Г.В. Давыдова была его научным руководителем. Формула модели — регрессионная:

$$Z = 8.38 * K_1 + 1 * K_2 + 0.054 * K_3 + 0.63 * K_4$$

Таблица 2. Формулы расчётов коэффициентов модели Беликова–Давыдовой [8]

Коэффициент	Формула расчета
K_1	$K_1 = \text{Оборотный капитал} / \text{Активы}$
K_2	$K_2 = \text{Чистая прибыль} / \text{Собственный капитал}$
K_3	$K_3 = \text{Выручка} / \text{Активы}$
K_4	$K_4 = \text{Чистая прибыль} / \text{Себестоимость}$

Оценка состояния предприятия по данной модели:

- вероятность банкротства 90–100% при $Z < 0$;
- вероятность банкротства 60–80% при $0 < Z < 0.18$;
- вероятность банкротства 35–50% при $0.18 < Z < 0.32$;
- вероятность банкротства 15–20% при $0.32 < Z < 0.42$;
- риск банкротства минимальный (до 10%) при $Z > 0.42$. [8]

Модель Зайцевой. Модель была предложена в 1998 году профессором Сибирского университета потребительской коммерции О.П. Зайцевой. Формула:

$$K_{\text{факт}} = 0.25 * K_1 + 0.1 * K_2 + 0.2 * K_3 + 0.25 * K_4 + 0.1 * K_5 + 0.1 * K_6$$

Таблица 3. Формулы расчётов коэффициентов модели Зайцевой [8]

Коэффициент	Формула расчета	Норматив
K_1	$K_1 =$ Прибыль (убыток) до налогообложения / Собственный капитал	$K_1 = 0$
K_2	$K_2 =$ Кредиторская задолженность / Дебиторская задолженность	$K_2 = 1$
K_3	$K_3 =$ Краткосрочные обязательства / Наиболее ликвидные активы	$K_3 = 7$
K_4	$K_4 =$ Прибыль до налогообложения / Выручка	$K_4 = 0$
K_5	$K_5 =$ Заемный капитал / Собственный капитал	$K_5 = 0,7$
K_6	$K_6 =$ Активы / Выручка	$K_6 = K_{\text{бпрошлого года}}$

Из (табл. 3) видно, что если коэффициент K_1 отличен от нормы, то это сигнализирует о том, что предприятие становится убыточным.

Для определения вероятности банкротства предприятия необходимо произвести сравнение фактическое значение интегрального показателя с нормативным. $K_{\text{факт}}$ сравнивается с $K_{\text{норматив}}$. Нормативное значение $K_{\text{норматив}}$ рассчитывается по следующей формуле:

$$K_{\text{норматив}} = 1.57 + 0.1 * K_{\text{бпрошлого года}}$$

Если $K_{\text{факт}} > K_{\text{норматив}}$, то высока вероятность банкротства предприятия.

Если наоборот, то риск банкротства незначительный. [8]

Модель Федоровой–Гиленко–Довженко (МФГД). Группа авторов на основе анализа отчетности 8573 российских компаний разработала десятифакторную модель банкротства с отраслевыми пороговыми значениями, обладающую сравнительно высокой межотраслевой прогностической способностью. Формула:

$$Z = -6,2 * K_1 - 5,649 * K_2 - 0,818 * K_3 - 1,08 * K_4 - 0,638 * K_5 - 1,932 * K_6 - 0,928 * K_7 - 2,249 * K_8 + 10,3$$

- K_1 — денежные средства / оборотные средства;
- K_2 — чистая прибыль / (краткосрочные + долгосрочные обязательства);
- K_3 — десятичный логарифм материальных активов;
- K_4 — коэффициент ликвидности при мобилизации средств (запасы/краткосрочные обязательства);
- K_5 — выручка / (краткосрочные + долгосрочные обязательства);
- K_6 — внеоборотные активы / стоимость всех активов;
- K_7 — валовая прибыль / себестоимость;
- K_8 — оборотные средства / (краткосрочные + долгосрочные обязательства);

Если $Z > 0$, то существует высокая вероятность наступления банкротства, если $Z < 0$, то предприятие финансово устойчиво.

Данная модель является самой точной среди отечественных моделей, существующих на данный момент. Её прогнозная точность составляет 84,8% для здоровых компаний и 91,6% для компаний банкротов. [6]

1.3. Нейронные сети как инструмент прогнозирования банкротства

В настоящее время существует несколько типов моделей, которые можно отнести к 3–м группам (рис. 1).

В пункте 1.2. мы рассмотрели только статистические модели, дело в том, что к статистическим относится больше половины всех существующих моделей прогнозирования банкротства и все самые популярные модели. Хотя точность моделей искусственного интеллекта превосходит результаты статистических моделей, нейросетевые и другие модели машинного обучения занимают лишь 1/6 всех методик. Главная причина этого в том, что модели искусственного интеллекта появились сравнительно недавно и только начинают занимать свою нишу на рынке.



Рис. 1. Типы моделей прогнозирования банкротства

Нейронные сети — это аналитические методы, разработанные как аналогия принципов обучения мозга. Они позволяют прогнозировать значения части переменных в новых данных по уже изученным данным после прохождения этапа обучения.

Искусственные нейронные сети изменяют свое поведение в зависимости от внешней среды. После предоставления входных сигналов, иногда вместе с необходимыми выходами, сети самонастраиваются, чтобы обеспечивать реакцию, которая требуется.

Искусственные нейронные сети (ИНС) представляют собой систему соединенных и взаимодействующих между собой простых процессоров (искусственных нейронов). [11]

Нейронные сети не программируются, а обучаются. Именно возможность обучения является одним из главных преимуществ НС перед другими алгоритмами. В процессе обучения нейронная сеть способна выявлять сложные зависимости между входными данными и выходными, а также выполнять обобщение. [11]

После обучения сеть способна предсказывать будущее значение некой переменной или их последовательности на основе полученных данных.

Глава 2. Построение, обучение и тестирование нейронной сети для прогнозирования банкротства

1.2. Математическая постановка задачи, подготовка данных и среды разработки

Даны k коэффициентов из финансовой отчетности предприятия:

$$x_1, x_2, \dots, x_k.$$

Необходимо найти функцию, которая будет являться зависимостью между данным вектором и вероятностью наступления банкротства предприятия в ближайшие 3 года:

$$y = f(x_1, x_2, \dots, x_k).$$

Данная задача является задачей классификации — на выходе должен выводиться класс банкротства предприятия.

Для того, чтобы построить нейронную сеть, необходимо разработать ее архитектуру, выбрать способы обучения и тестирования. Кроме того, для обучения нужны входные данные — выборка компаний с достоверной финансовой отчетностью и рассчитанные на ее основе коэффициенты. На основании анализа задачи было принято решение остановиться на модели двухслойного персептрона (рис. 2) и алгоритме обучения — обратное распространение ошибки — процедура многократной корректировки весов, чтобы минимизировать разницу между фактическим и желаемым выходом.

При проектировании сети были использованы следующие параметры:

- алгоритм обучения — обратного распространения ошибки;
- инициализация весов — автоматическая;
- количество входных нейронов — 8;
- количество нейронов на скрытом слое — 8;
- количество обучающих примеров — 60.

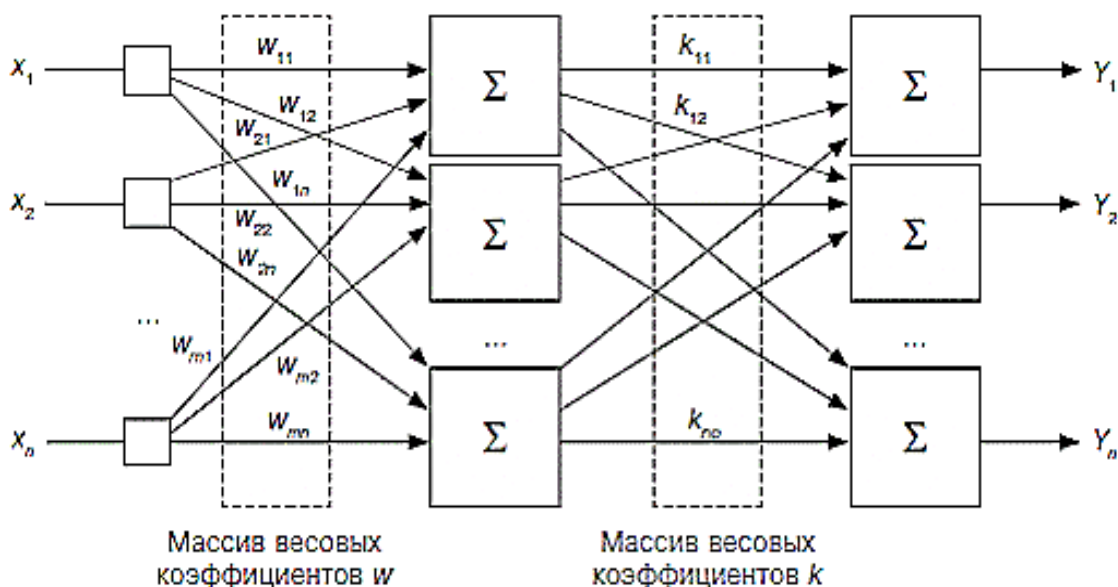


Рис. 2. Двухслойная нейронная сеть [11]

При приведении данного исследования использовалась публичная финансовая отчётность 100 компаний за последние 3 года (2015–2018 года). На её основании составлена таблица 100×8 , где 100 — число строк (предприятий), а 8 — число столбцов (показателей финансовой отчётности). Мы разделим нашу выборку данных на две — обучающую и тестовую — 60% и 40% соответственно.

Программная часть реализована на языке Python 3. Для работы с данными нам потребовались следующие библиотеки:

- NumPy — библиотека для создания и работы с массивами данных;
- Pandas — библиотека для работы с числовыми таблицами, работает поверх библиотеки NumPy;
- scikit-learn — инструменты для решения задач классификации, кластеризации и регрессии, а также начальной обработки данных.

2.2. Обучение нейронной сети

Цель данного обучения — подстроить веса так, чтобы взвешивание некоторого множества X приводило к требуемому множеству Y .

Входные сигналы x_1, x_2, \dots, x_n подаются на искусственный нейрон X (рис. 3). Вектор W — множество весов, на которые умножается каждый сигнал w_1, w_2, \dots, w_n . Результат отправляется на суммирующий блок Σ . [9]

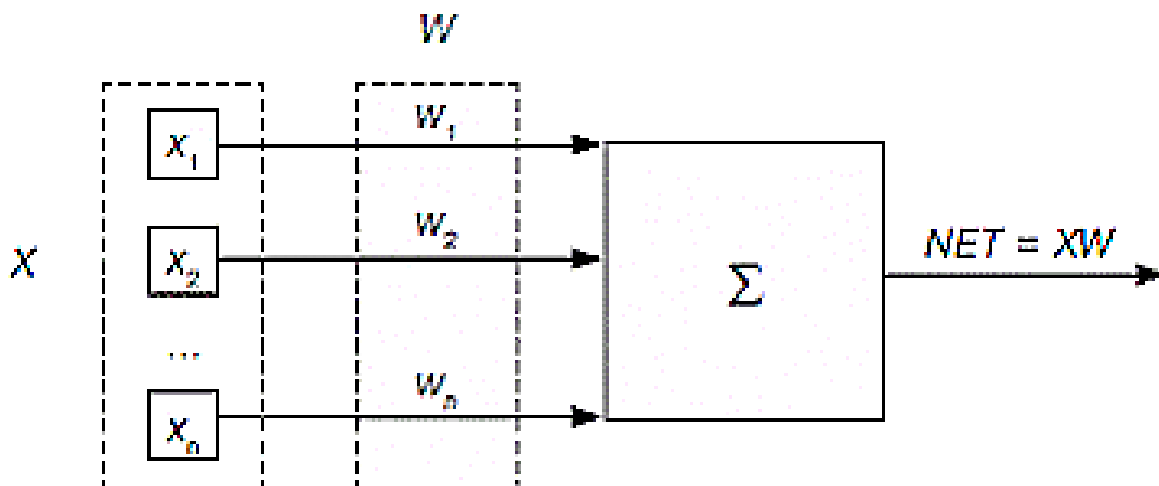


Рис.3. Искусственный нейрон [11]

Нейрон — это математическая функция. В качестве входных данных требуется несколько чисел. В нашем случае их 8. Для каждого входа каждого x_n НС назначает другой номер w_n . Вектор, состоящий из этих чисел w_n называется вектором весов. Именно эти веса делают каждый нейрон уникальным. Они фиксируются во время тестирования, но во время обучения — это цифры, которые мы собираемся изменить, чтобы «настроить» нашу сеть.

Суммирующий блок складывает взвешенные входы, формируя выход, который будем называть NET . Запишем это в векторных обозначениях:

$$NET = XW$$

Формула выше — это то, что называется линейной комбинацией. Мы собираемся взять входные данные, умножить их на соответствующие веса и суммировать все вместе. Результатом этого является число. Наш следующий шаг — применить какую-то нелинейную функцию поверх нее. Наиболее

популярная функция, которая используется сегодня, это сигмоидальная функция. Формула следующая:

$$F(x) = \frac{1}{1 + e^{-x}}$$

Таким образом,

$$OUT = \frac{1}{1 + e^{-NET}}$$

На (рис. 3) квадратами обозначены вычисляющие нейроны. Каждый элемент из множества входов X отдельным весом соединен с каждым искусственным нейроном, который выдает взвешенную сумму входов в сеть.

Будем считать веса элементами матрицы W . Матрица $m \times n$, где m — число входов, а n — число нейронов в скрытом слое. Например, $w_{2,1}$ — это вес, связывающий первый вход со вторым нейроном.

Когда мы начинаем работу сети, мы инициализируем наши веса случайным образом. Очевидно, это не даст нам очень хороших результатов. В процессе обучения мы начнём с плохо работающей нейронной сети и постепенно будем приходить к сети с высокой точностью. Что касается функции потерь, мы хотим, чтобы наша функция потерь была как можно ниже в конце обучения. Мы хотим найти другую функцию, которая работает лучше, чем первоначальная. Проблема обучения эквивалентна проблеме минимизации функции потерь.

Обучающей парой будем называть пару из обучающего множества $\{(x,y) | \forall x \in X, \exists y \in Y\}$, где x — элемент из множества X , а y — соответствующий ему элемент из множества Y .

Обучение сети алгоритмом прямого распространения ошибки требует выполнения следующих шагов:

- 1) выбрать очередную обучающую пару;
- 2) подать входной вектор на вход сети;

- 3) вычислить значение выхода сети;
- 4) вычислить разность между полученным и требуемым выходом сети;
- 5) изменить веса сети так, чтобы достичь минимальной ошибки;
- 6) повторять шаги с 1 по 4 для каждой обучающей пары до определенного предела или пока ошибка на всем множестве не достигнет приемлемого уровня. [11]

Шаги 1–2 являются алгоритмом прямого распространения ошибки, так как сигнал распространяется по сети от входа к выходу. Шаги 3 и 4 являются алгоритмом обратного распространения ошибки (вычисляемый сигнал ошибки распространяется обратно по сети и используется для подстройки весов). Рассмотрим эти алгоритмы подробнее. [11]

Алгоритм прямого распространения ошибки. Вычисления будут проводиться над вектором X , чтобы получить выходные значения Y .

Вычисления в многослойных сетях выполняются последовательно, начиная с ближайшего к входу слоя. Величина NET каждого нейрона первого слоя вычисляется как взвешенная сумма входов нейрона. Затем функция активации F «сжимает» NET и дает величину OUT для каждого нейрона в этом слое. Когда множество выходов слоя получено, оно является входным множеством для следующего слоя. Процесс повторяется до тех пор, пока не будет получено заключительное множество Y .

Поскольку веса между нейронами мы рассматриваем как матрицу W , то NET -вектор слоя N может быть выражен как произведение X и W . Путём поэлементного воздействия функции F на входной NET -вектор N получаем выходной вектор O .

Для получения выходных сигналов скрытого слоя мы просто применяем к каждому из них сигмоидальную функцию активации:

$$O = F(XW)$$

В плане программирования это реализуется с помощью библиотеки `scipy` в Python. Она содержит набор специальных функций, в том числе сигмоидальную, которая называется «`expit`».

Алгоритм обратного распространения ошибки. Рассмотрим процесс подбора веса от нейрона p в скрытом слое j к нейрону q в выходном слое k .

При вычитании выходного нейрона слоя k из целевого значения ($Target$), мы получим сигнал ошибки. Затем, умножив этот сигнал на производную функции F , $OUT(1 - OUT)$, найденную для данного нейрона, получим величину $\delta = OUT(1 - OUT)(Target - OUT)$.

Умножив δ на OUT нейрона j , из которого выходит рассматриваемый вес, и на коэффициент скорости обучения η , в нашем случае 0,3, после чего прибавим это произведение к весу. Данная процедура будет выполняться для каждого подобного веса.

Запишем в виде уравнений:

$$\Delta w_{pq,k} = \eta \delta_{q,k} OUT, \quad (1)$$

$$w_{pq,k}(n + 1) = w_{pq,k}(n) + \Delta w_{pq,k}, \quad (2)$$

здесь $w_{pq,k}(n)$ — величина веса на шаге n (до коррекции), k относится к слою, в котором заканчивается этот вес, $w_{pq,k}(n + 1)$ — значение веса на шаге $n + 1$ (после корреляции), $\delta_{q,k}$ — величина δ для нейрона q в выходном слое k ; $OUT_{p,q}$ — величина OUT для нейрона p в скрытом слое j .

Подстройка весов скрытого слоя. Рассмотрим один нейрон в скрытом слое, предшествующем выходному слою. Выходной сигнал от этого нейрона переходит к нейронам выходного слоя через соединяющие их веса. Во время обучения эти веса работают в обратном направлении. Каждый из этих весов умножается на величину δ нейрона, к которому он присоединен в выходном слое. Величина δ находится как:

$$\delta_{q,k} = OUT_{p,j}(1 - OUT_{p,j}) \left[\sum_q \delta_{q,k} w_{pq,k} \right]$$

После вычисления δ , веса, питающие данный скрытый уровень, могут быть изменены с помощью уравнений (1) и (2), где индексы изменяются в зависимости от слоя. Этот процесс повторяется слой за слоем от выхода к входу, пока все веса не будут подстроены (рис. 4).

Обучение сети будем считать оконченным, когда будет достигнута минимальная удовлетворяющая нас ошибка. [11]

Входным вектором нейронной сети являются показатели финансовой отчётности, отобранные авторами модели Федоровой–Гиленко–Довженко.

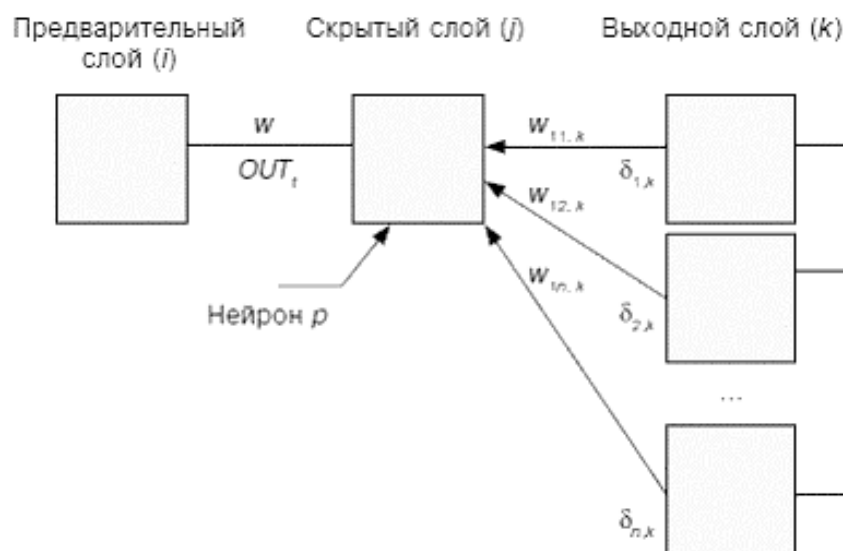


Рис. 4. Настройка веса в скрытом слое

Для обучения нейронной сети необходим вектор выходных данных. В нашем случае им будет значения классов предприятий за следующий год.




Рис. 5. График сходимости ошибки обучения

Для определения класса финансового состояния множества предприятий необходимо подать на вход программе .xlsx файл (таблица), содержащий значения определенных строк финансовой отчетности. Каждая строка файла — определённая организация. Выходной файл будет содержать вычисленный класс банкротства.

По итогу обучения суммарная точность работы программы составила 93%. Суммарная точность снижена из-за низкой прогностной способности сети для предприятий, сохранивших свою финансовую устойчивость. В случае с предприятиями, обанкротившимся через год, после даты предоставления финансовой отчетности точность модели составила — 96%. Более подробно результаты точности на обучающей выборке описаны в (табл. 4).

Как видно из графика сходимости ошибки обучения (рис. 5) — точность работы программы растёт с увеличением выборки обучающих данных (ось x).

2.3. Тестирование нейронной сети

Для проверки точности работы НС было проведено определение погрешности модели на тестирующем множестве. Тестирование модели осуществлялось на данных финансовой отчётности 40 компаний за 2017 год.

Ошибка тестирования составила 9% для класса предприятий, которые обанкротились через год, 12% для предприятий, обанкротившихся через 2 года, и 14% для предприятий, обанкротившихся через 3 года. Результаты прогнозирования приближены к действительным значениям и при округлении дают точные прогнозы в 87 % случаев.

Обобщающие свойства сети были проверены методом Cross-Validation (перекрестная проверка). Обучающее и тестирующее множества были объединены и разбиты на обучающее и тестирующее по-другому четыре раза.

Перекрестная проверка — это процедура повторной выборки, используемая для оценки моделей машинного обучения на ограниченной выборке данных. Процедура имеет единственный параметр, называемый k , который относится к числу групп, на которые следует разбить данную выборку данных. В нашем случае $k = 2$.

Глава 3. Анализ работы программы

В рассматриваемой задаче прогнозирования банкротства наряду с выбором математической модели и архитектуры сети, важным моментом является сбор данных финансовой отчетности предприятий. Стоит учитывать тот факт, что если бы мы взяли данные одной отрасли рынка за определенный временной промежуток, то точность нейронной сети была бы близка к 100%, но только для компаний этой отрасли. Если такую сеть применить к оценке предприятия другой отрасли, то точность была бы весьма низкой. В данном исследовании мы применяли обобщенную обучающую выборку, поэтому достигнутая нами точность не так высока, как ожидалось.

Для обучения сети использовалась финансовая отчетность 60 предприятий за 2015–2016 год. На данном множестве было проведено обучение нейросети. Цель теста была увидеть, насколько хорошо модель прогнозирует состояние организации через год, через 2 года и через 3 года. На основании финансовой отчетности оставшихся 40 предприятий было сформировано тестирующее покрывающее множество, которое использовалось для оценки предсказательной способности модели.

Модель показала сравнительно высокие результаты для обучающего и тестирующего множеств. Но точность на обучающем множестве существе выше, чем на тестовом, причиной этого может быть недостаточный размер обучающей выборки.

Также стоит отметить, что модель лучше прогнозирует скорое наступление финансовой неустойчивости предприятия нежели банкротство, ожидаемое через 3 года. Требуется дальнейшее исследование для определения причин этого явления. Разработанная нами модель не отстает по точности прогнозирования от популярных статистических моделей, но предел точности не достигнут. Дальнейшие эксперименты с выбором отрасли рынка из которой

берутся данные для составления обучающей выборки, а также с размером выборки, могут позволить достигнуть точности близкой к 100%.

Ниже приведена таблица результатов работы, разработанной нами нейросетевой модели прогнозирования финансовой неустойчивости предприятия (см. табл. 4).

Точность считалась как отношение числа правильно угаданных программой классов к общему числу выборки. В случае с обучающим множеством программа верно распознала классы 54 предприятий из 60. А для тестовой выборки 34 из 40.

Таблица 4. Точность прогнозирования банкротства нейронной сетью

Обучающее множество				
Суммарная точность	Класс 0	Класс 1	Класс 2	Класс 3
93%	86%	96%	93%	90%
Тестирующее множество				
Суммарная точность	Класс 0	Класс 1	Класс 2	Класс 3
87%	83%	91%	88%	86%

Давая общую оценку проделанной нами работы, хочу подчеркнуть, что при создании нейронной сети с помощью Python мы использовали лишь самые простые концепции. И тем не менее с помощью нашей нейронной сети нам, даже без использования каких-либо дополнительных математических ухищрений, удалось получить вполне достойные результаты, сравнимые с результатами статистических моделей, который разрабатывались с помощью фундаментальных знаний математики и статистического анализа.

Выводы

Целью исследования было построить нейросетевую модель прогнозирующую банкротство предприятий, показать её адекватность и перспективы увеличения точности.

Данная модель не отстает от статистических моделей предсказания банкротства, но и не превосходит их.

Разработанная модель прогнозирует банкротство с суммарной точностью 93% на обучающей выборке и 85% на тестовой выборке. Точность модели росла с увеличением обучающей выборки, но предел не достигнут. Значит можно сделать вывод, что дальнейшее увеличение обучающей выборки данных позволит усовершенствовать модель.

Также стоит отметить, что в данном исследовании мы использовали межотраслевую выборку данных, но если проводить исследование в рамках узкой области рынка (к примеру, нефтегазовый сектор), то можно будет достигнуть ещё более высокой точности прогнозирования. Но в таком случае, станет проблемой поиск достаточной базы данных финансовой отчётности.

Модели, построенные с помощью нейронных сетей, обладают существенными преимуществами перед математическими моделями: отсутствие проблемы размерности данных; скорость обучения (за счет одновременной обработки большим количеством нейронов); простота, в отличие от математических методов требующих фундаментальных знаний, скорость получения результатов. [13]

Но есть и недостатки в применении НС, такие как: необходимость начинать строить архитектуру с нуля (большинство стандартных алгоритмов еще не разработано).

В нынешних условиях маленьким предприятиям придется затратить слишком много ресурсов для решения задачи прогнозирования с помощью НС. В то время как у них уже отлажено проведение стандартного анализа

финансовой отчётности. Но когда крупные предприятия заинтересуются точностью прогнозирования данного подхода и будет создана база универсальных алгоритмов, это решение станет повсеместно распространенным для всех. [3, 17]

Заключение

В данной выпускной квалификационной работе бакалавра нами решены все поставленные задачи. Была выбрана одна из самых точных статических моделей диагностики банкротства, а именно модель Федоровой–Гиленко–Довженко. Коэффициенты, которые авторы отобрали как наиболее важные для диагностики банкротства стали входными данными для нашей нейронной сети.

Далее был произведен сбор необходимого для обучения и тестирования сети количества качественных данных (финансовой отчётности обанкротившихся и финансово устойчивых предприятий). Собраны данные о финансовой отчётности 100 предприятий, выборка поделена на 2 части — обучающая и тестовая — 60% и 40% соответственно.

Когда подготовительные работы были закончены, была произведена разработка и обучение нейронной сети. Обучение нейронной сети завершилось с суммарной точностью модели — 93%. При дальнейшем тестировании точность снизилась до 87%, что не уступает другим моделям прогнозирования банкротства, а значит, разработанная модель адекватна.

Проведя информационный анализ полученных результатов, сделан вывод о необходимости увеличения обучающей выборки данных.

Созданная нейросетевая модель прогнозирования банкротства может быть использована фирмами как методика проведения внутреннего финансового анализа. Применение такого способа диагностики позволит грамотно оценивать и минимизировать риски. Так, разработанная нами нейросетевая модель может предупреждать о риске возникновения состояния финансовой неустойчивости и обращать внимание руководства на необходимость совершенствования деятельности предприятия.

Литература

1. Клейнер Г.Б. Стратегии бизнеса: аналитический справочник. КОНСЭКО, 1998. 480 с.
2. Викторова А.Р., Новожилова Л.М., Юсупов С.А. Сравнительный анализ мировых систем оценочных показателей финансовой отчетности. Научный взгляд в будущее. 2018. 3(11–03), С.33-37.
3. Викторова А.Р., Новожилова Л.М., Шамсов Ф.М. Нейросетевые модели прогнозирования банкротства предприятия // Парадигмальный характер фундаментальных и прикладных научных исследований, их генезис. СПб.: 2019. №42 С.32–33.
4. Викторова А.Р., Новожилова Л.М., Шамсов Ф.М. Анализ методов кластеризации информации // Парадигмальный характер фундаментальных и прикладных научных исследований, их генезис. СПб.: 2019. №2. С.31–32.
5. Т.М. Жукова, К.С. Кондратьева. Современные особенности применения экономических моделей диагностики вероятности наступления банкротства // Вестник Пермского университета. 2014. №1. С.194–205
6. Федорова, Е. А., Гиленко, Е. В., Довженко, С. Е. Модели прогнозирования банкротства: особенности российских предприятий. // Проблемы прогнозирования. 2013. №2. С. 85-92.
7. Модели банкротства (диагностика и оценка вероятности банкротства) // finance-m.info URL: http://finance-m.info/bankruptcy_models.html (дата обращения: 13.02.2019).
8. Модели прогнозирования банкротства предприятия (mda-модели) // Finzz.ru URL: <http://finzz.ru/modeli-prognozirovaniya-bankrotstva-rossijskix-predpriyatij-mda-modeli.html> (дата обращения: 12.02.2019).
9. Д.С.Корнеев. Использование аппарата нейронных сетей для создания модели оценки и управления рисками предприятия. 2007. 22 с.
10. Tarh Rashid. Make Your Own Neural Network. Вильямс, 2018. 218 с.

11. Никифорова Н.А., Донцов Е.В. Применение нейросетевого моделирования для прогнозирования финансового состояния предприятий // Управленческий учёт. 2015. №4. С.36–46.

12. Ясницкий Л.Н. Введение в искусственный интеллект. 3-е изд. – М.: Издательский центр «Академия», 2010. 176 с., с. 61.

13. Kasgari A.A., Salehnezhad S.H., Ebadi F. The Bankruptcy Prediction by Neural Networks and Logistic Regression // International Journal of Academic Research in Accounting, Finance and Management Sciences. 2013. №4. С. 146–152.

14. Rezaiedolatabadi, H. et al.. Modeling and Forecasting Stock Prices Using an Artificial Neural Network and Imperialist Competitive Algorithm. Neural networks, International Journal of Academic Research in Accounting, Finance and Management Sciences, 2013. №3(1), С. 296-302.

15. Что такое банкротство: обзор всех видов и вариантов, причины и последствия для должника, стоимость процедуры // <https://myrouble.ru/> URL: <https://myrouble.ru/chto-takoe-bankrotstvo/> (дата обращения: 22.04.2019).

16. Закон Российской Федерации "О несостоятельности (банкротстве) " от 27.09.2002 № 127 // Российская газета. 2002. С.209-210.

17. Новожилова Л.М. К проблеме оптимизации системы оценочных показателей конкурентоспособности предприятия // Перспективы инновации в науке, образовании, производстве и на транспорте'2011. Украина, Одесса: 2012. 7 с.