

ИНСТРУМЕНТАЛЬНЫЙ МЕТОД МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ БАНКРОТСТВА КОМПАНИЙ

Александр Рустамович НЕВРЕДИНОВ

аспирант кафедры предпринимательства и внешнеэкономической деятельности,
Московский государственный технический университет им. Н.Э. Баумана (МГТУ),
Москва, Российская Федерация,
a.r.nevredinov@gmail.com
ORCID: отсутствует
SPIN-код: 9186-4690

История статьи:

Рег. № 317/2021
Получена 27.05.2021
Получена
в доработанном виде
10.06.2021
Одобрена 24.06.2021
Доступна онлайн
30.09.2021

УДК 338.27

JEL: C53, G3

Ключевые слова:

прогнозирование
банкротства,
машинное обучение,
анализ компаний,
искусственные
нейронные сети

Аннотация

Предмет. Оценка состояния компаний, методы прогнозирования банкротства.

Цели. Разработка инструментального метода на основе машинного обучения для прогнозирования банкротства. Исследование источников информации, выбор исходных параметров, изучение возможностей прогнозных моделей.

Методология. Используются методы анализа и синтеза, а также подходы систематизации, формализации, сравнительного анализа. Теоретические и методологические положения, содержащиеся в отечественных и зарубежных научных трудах по темам анализа компаний и прогнозированию банкротства.

Результаты. Предложен и апробирован инструментальный метод для прогнозирования банкротства. В частности, предложены авторские наборы показателей, выявленные на основе анализа ключевых показателей финансовой устойчивости, результативности и внешних факторов, влияющих на компании на рынке. Собрана обучающая выборка данных, включающая российские и зарубежные компании, разработаны модели на основе машинного обучения, обладающие высокой точностью предсказаний.

Выводы. Результаты развивают научно-практическое представление о методах прогнозирования банкротства и могут быть использованы для поддержки принятия управленческих решений в организации для автоматизации собственного анализа или анализа других организаций, с которыми оно взаимодействует.

© Издательский дом ФИНАНСЫ и КРЕДИТ, 2021

Для цитирования: Неврединов А.Р. Инструментальный метод машинного обучения для прогнозирования банкротства компаний // *Финансы и кредит*. — 2021. — Т. 27, № 9. — С. 2118 — 2138.

<https://doi.org/10.24891/fc.27.9.2118>

Вопросом прогнозирования банкротства компаний давно занимаются различные исследователи, еще в 1968 г. Эдвардом Альтманом была предложена модель прогнозирования вероятности банкротства, она

основывалась на данных финансового состояния всего 66 американских предприятий, половина из которых обанкротилась. На основе этих показателей была разработана пятифакторная модель, которая оценивала предприятие по пяти показателям с помощью весовых коэффициентов и интервальных интерпретаций оценок [1]. Позже стали появляться и другие модели, среди которых можно выделить, например, модели Дж. Олсона (1980 г.), М. Змиевского (1984 г.), Т. Шумвея (2001 г.). Сейчас такие модели часто называют параметрическими, поскольку они основаны на заранее введенных в модель весовых коэффициентах и детерминированных алгоритмах получения ответа.

Такие модели основывают на малом числе финансовых коэффициентов и легко рассчитывают вручную. О низкой точности модели Э. Альтмана (особенно спустя столько времени) на практике уже говорили многие исследования, тем не менее она остается одной из самых популярных и известных. Однако если обратиться к общему исследованию точности различных моделей, то увидим, что она колеблется в районе 70–80% при проверке на большом современном наборе данных [2]. Эту точность необходимо было повысить и в этом помогли непараметрические модели, то есть модели на основе машинного обучения, которые сами определяли значимость различных параметров, учитывали сложные зависимости данных и могли обработать большое число параметров.

Компания может эффективно функционировать только если принимаемые решения основываются на тщательном анализе альтернатив и оценке принимаемых решений. Прогнозирование является очень важным как при выборе краткосрочных стратегий, так и при построении стратегий развития организации, характер прогнозирования может быть разным: модели оценки и инструменты комплексного технологического прогнозирования [3]. Выбор методов и моделей является важным фактором, влияющим на получаемые результаты анализа данных. В системах поддержки принятия решений (СППР) часто применяются: методы регрессии, деревья решений, Data-Mining («добыча данных»), искусственные нейронные сети [4].

Технологии машинного обучения (МО) являются одним из направлений науки об искусственном интеллекте. Основной целью этой науки является создание машин, способных выполнять творческие функции, которые обычно являются прерогативой человека. Одним из наиболее перспективных реализаций машинного обучения являются искусственные нейронные сети (ИНС)¹, которые берут начало в работах Д. Хебба,

¹ Пупков К.А., Воронов Е.М., Гаврилов А.И., Крыжановская Т.Г. Нейросетевое моделирование: учеб. пособ. М.: МАМИ, 2011. 60 с.

Ф. Розенбатта, У. Маккалока, У. Питтса, М. Минского [5–9]. Д. Хебб еще в 1949 г. описал первые принципы обучения нейронов, а в 1958 г. Ф. Розенблатт предложил модель перцептрона, который моделировал работу человеческого глаза (хотя весьма неэффективно). А после разработки концепции глубокого обучения, берущей начало в трудах К. Фукусимы, Р. Дехтера, Д. Хинтона, Д. Хопфилда и др. в 1986 г., данные технологии получили значительно больше внимания и данное научное направление стало быстро развиваться, появились различные архитектуры, к таким работам можно отнести труды Т. Кохонена, Г. Дебока, Т. Хонкела, С. Бишопы, З. Хохрайтера, Ю. Шмидхубера, С. Хайкина, С. Осовского, М. Полла [10–16].

Сейчас данную технологию можно считать достаточно глубоко проработанной и апробированной, появляются различные платформы сотрудничества (например, Нейронет²). ИНС обладают очень широким функционалом и программирование модели значительно упрощено благодаря созданию специализированных библиотек машинного обучения, что избавляет исследователей от необходимости самостоятельно программировать весь процесс машинного обучения.

Основным преимуществом ИНС является невероятная гибкость, которая позволяет настраивать работу нейронов каждого слоя и адаптировать сеть к выполнению различных задач, так что сеть максимально соответствует необходимому пространству данных [6, 9]. Кроме того, необходимо отметить, что ИНС принадлежат к «мягким» методам вычисления, отличием которых от классических «жестких» (к которым относится обычный математический аппарат) является способность работы с нечеткими, частичными, вероятностными данными, давая в ответах такие же вероятностные, приблизительные оценки [17]. Для обычных методов искажения в данных неприемлемы, а попытка обработать очень сложную, многокритериальную систему потребует больших вычислительных мощностей (поэтому подобные модели обычно упрощают), тогда как мягкие методы способны выполнить ту же задачу значительно быстрее и проще. Помимо прочего, они позволяют искать в данных неочевидные закономерности и сложные нелинейные зависимости, которые не могли бы быть учтены классическими методами.

Нейронная сеть, по сути, строит неявную математическую модель и формализует знания (пусть и извлечь их из ИНС невозможно, поскольку матрицы весов не имеют никакого смысла сами по себе). И хотя проблема

² Документы и аналитические материалы отраслевого союза Нейронет. Меморандум о создании отраслевого союза. URL: <http://rusneuro.net/dokumenty>

«черного ящика» остается открытой и является основой для недоверия к ИНС (в особенности в отраслях, где важнее предсказуемость системы, вроде ракетно-космической отрасли), ведутся работы по интерпретации моделей ИНС [18].

Тем не менее нейронные сети уже успешно применяются на коммерческой основе. Конечной целью любой инновации является повышение экономической эффективности за счет снижения затрат или увеличения прибыли (например, за счет увеличения числа клиентов), и ИНС могут значительно помочь в бизнесе, иногда перспективы применения современных аналитических средств даже служат причиной для начала цифровизации бизнеса, куда некоторые компании могут инвестировать до 15—20% прибыли [19].

Отметим, что управление информационно-технологическими и схожими по типу научно-техническими проектами характеризуется быстрым развертыванием, ресурсоемкостью и большим средним сроком окупаемости. Во время проекта в него часто вносятся изменения, но увеличение гибкости при анализе и автоматизации процессов оправдывает сложность подобного проекта. В прикладных экономических задачах машинное обучение особенно актуально из-за сложности моделей и возможности работы с нечеткими данными [20].

Технологии искусственного интеллекта уже можно обнаружить в различных программных продуктах, сервисах или технике, они часто являются определяющим фактором привлекательности продукта, потому что способны обеспечить функционал, которого нет у конкурента, не применяющего эти технологии. По данным исследования компании PwC, наибольший вклад в ВВП страны от технологий машинного обучения получают в Китае (более 26%)³.

Необходимо отметить, что и техническая составляющая за последние десятилетия невероятно продвинулась, появилось специальное вычислительное оборудование, предназначенное для работы с нейронными сетями: TPU (тензорные процессоры), которые специально приспособлены для операций с «тензорами» — алгебраическими объектами, в данном контексте их можно просто описать как многомерные матрицы данных [21].

³ AI to drive GDP gains of \$15.7 trillion with productivity, personalisation improvements. PwC.
URL: https://www.pwc.com/gx/en/news-room/press-releases/2017/ai-to-drive-gdp-gains-of-15_7-trillion-with-productivity-personalisation-improvements.html

Интеграция таких систем в СППР организаций также не представляет проблем, поскольку ERP (Enterprise Resource Planning) системы имеют возможности расширения и интеграции с внешними моделями, при этом они служат основой для цифровизации бизнеса (и создания цифровых двойников компании, которые позволяют осуществлять мониторинг и управление всей компанией централизованно [22]), а значит, располагают всеми необходимыми данными.

Инструментами для быстрой программной реализации машинного обучения на основе искусственных нейронных сетей могут служить библиотеки для языков C++, R и Python. В *табл. 1* представлены наиболее известные и востребованные из этих библиотек⁴.

Поскольку основной инструмент для реализации поставленной задачи был рассмотрен, можно перейти к анализу реализации модели прогнозирования банкротства компании. Ключевыми факторами успеха при работе с ИНС являются:

- сбор обучающей выборки на основе релевантных данных;
- правильная подготовка обучающей выборки;
- моделирование архитектуры сети;
- процесс обучения, включающий подбор лучших параметров обучения и внесение корректировок в обучающую выборку для получения лучшего результата.

Создание выборки — важнейший этап при работе с машинным обучением, от него зависит качество результирующей модели. Проблемы формирования достаточной выборки часто возникает при разработке моделей на основе ИНС [23]. К выборке предъявляются следующие требования:

- она должна быть актуальной (отражать текущее положение вещей в предметной области, слишком старые данные могут дать модель, не подходящую для современных условий);
- в ней не должно быть прямых противоречий (они не обучат модель «знаниям» о частных случаях, только испортят точность);

⁴ Сквозная платформа машинного обучения с открытым исходным кодом. TensorFlow. URL: <https://www.tensorflow.org/>; Описание библиотеки Keras. URL: <https://keras.io/>; Описание библиотеки PyTorch. URL: <https://pytorch.org/>

- данные не должны быть слишком зашумлены (так как сеть научится работать с шумом и будет иметь меньшую точность на не зашумленных данных);
- желательно привести все показатели к одной размерности (обычно от 0 до 1 или от -1 до 1), поскольку ИНС склонны отдавать больший приоритет тем признакам, которые имеют большее значение, данный процесс называется нормализацией, тогда как изначально все данные должны оцениваться одинаково.

Необходимо отметить, что источники данных для анализа можно классифицировать по двум факторам. По характеру информация может быть:

- финансовой, имеющей объективное числовое представление (стоимость активов, капитала, выручка, стоимость акций и т.п.);
- нефинансовой, представляющей субъективную оценку по каким-либо важным факторам с помощью текстов на естественном языке.

По отношению к организации информацию можно также подразделить:

- на внутреннюю, определение которой в значительной степени зависит от управленческих решений менеджеров компании и успешности деятельности;
- на внешнюю, определяющую характеристики среды, в которой организация существует.

Анализ нефинансовых показателей прежде всего связывают с текстовым анализом, это самостоятельная обширная тема множества исследований, в данный момент мы затрагивать ее не будем. Рассмотрим финансовые показатели: обычно при анализе организаций используют только внутренние финансовые показатели, которые представлены бухгалтерской отчетностью организаций⁵, однако мы также введем в модель ряд внешних показателей, характеризующих рынок и обстановку в стране за соответствующий год, мы считаем, что это позволит повысить точность предсказаний модели. В модель необходимо загружать не чистые данные отчетности (которые сами по себе мало что говорят и модель с большой вероятностью будет оценивать не стабильность компании, а масштаб), а различные расчетные показатели и коэффициенты, поддающиеся анализу.

⁵ Шеремет А.Д., Козельцева Е.А. Финансовый анализ: учеб.-методич. пособ. М.: Экономический факультет МГУ имени М.В. Ломоносова, 2020. 200 с.

Рассмотрев работы со схожей тематикой, а также проведя ряд тестов с моделями, мы отобрали следующие расчетные финансовые показатели:

- рентабельность продаж (*PM*);
- рентабельность капитала (*ROE*);
- рентабельность задействованного капитала (*ROCE*);
- рентабельность активов (*ROA*);
- рентабельность суммарных активов (*ROTA*);
- оборачиваемость чистых активов;
- коэффициент покрытия процентов;
- оборачиваемость запасов;
- средний период погашения дебиторской задолженности (*COP*);
- средний период погашения кредиторской задолженности (*CRP*);
- текущая ликвидность;
- срочная ликвидность;
- коэффициент ликвидности доли акционеров (*SLR*);
- коэффициент автономии;
- коэффициент финансового рычага;
- размер компании (как натуральный логарифм от активов);
- коэффициент оборачиваемости денежных средств;
- чистый оборотный капитал;
- отношение денежных средств и эквивалентов к активам (*CTA*);
- отношение долгосрочных обязательств к капиталу и резервам (*LTS*).

Данный набор весьма необычен своим составом, поскольку содержит как некоторые широко известные показатели, так и коэффициенты, которые даже не имеют четкого названия (тем не менее представлены в приведенной зарубежной работе по предсказанию банкротства), вроде последних двух,

однако их исключение из моделей приводило к снижению точности на обучении. В обычном понимании, если рассматривать каждый показатель отдельно, они могут указывать на платежеспособность компании, финансовую устойчивость, эффективность деятельности и эффективность менеджмента организации. Мы не можем утверждать, что данный набор показателей оптимален и дальнейшее его улучшение невозможно, но он показывает неплохие результаты и позволяет выполнить научную задачу работы.

Внешние нефинансовые показатели также собирались исходя из анализа зарубежных работ и опытной оценки того, какие показатели чаще всего рассматривают, если говорят о рынке. Польза от включения внешних показателей в модель проверена эмпирически: точность моделей существенно (в среднем на 4%) падала при исключении данных показателей из выборки. Их не так много, но они важны для модели [24, 25]:

- базисная ставка;
- реальный ВВП;
- годовая инфляция;
- реальная средняя заработная плата по стране;
- уровень безработицы;
- EPU (индекс неопределенности экономической политики).

Используемые данные о внутренних показателях компаний получены с помощью базы данных Amadeus, из которой было выгружено и объединено в один массив множество срезов базы данных финансовой отчетности, а также информации о состоянии компаний за 2014–2019 год. Внешние показатели собраны из различных источников⁶. Поскольку для

⁶ World Development Indicators: DGP, PPP. DataBank.

URL: <https://databank.worldbank.org/reports.aspx?source=2&series=NY.GDP.MKTP.PP.CD&country=>;

World Development Indicators: Inflation (annual %). DataBank.

URL: <https://databank.worldbank.org/reports.aspx?source=2&series=FP.CPI.TOTL.ZG&country=>; World Development Indicators: Unemployment (% of total labor force). DataBank.

URL: <https://databank.worldbank.org/reports.aspx?source=2&series=SL.UEM.TOTL.ZS&country=>;

Global Wage Report 2018/19. URL: <https://databank.worldbank.org/reports.aspx?source=2&series=SL.UEM.TOTL.ZS&country=>;

Global Wage Report 2020-21.

URL: https://www.ilo.org/wcmsp5/groups/public/---dgreports/---dcomm/---publ/documents/publication/wcms_762534.pdf;

Доходность облигации, Испания, 10-летние. URL: <https://ru.investing.com/rates-bonds/spain-10-year-bond-yield-historical-data>;

Доходность облигации, Италия, 10-летние. URL: <https://ru.investing.com/rates-bonds/italy-10-year-bond-yield-historical-data>;

Доходность облигации,

исследования необходимо много данных о банкротствах, которых относительно мало среди компаний, только данных по России было недостаточно, поэтому также были выгружены данные об итальянских, испанских и французских компаниях (наиболее крупные экономики в Европе, кроме того, по этим странам много данных), помимо прочего, было решено выгружать данные не по всем отраслям экономики, а только наиболее ресурсоемким и современным: производство, строительство и ИТ, где достаточно высока доля банкротов.

Чтобы из загруженных массивов данных получить выборки для обучения, были разработаны алгоритмы, которые извлекали только необходимые данные (так, данные по обанкротившимся компаниям имеет смысл брать только за последний год), были добавлены внешние показатели, соответствующие различным странам и годам за выбранный период, а также введены формулы расчета всех приведенных финансовых показателей. Все строки, содержащие хотя бы одну ошибку вычисления, были удалены из выборки. Далее данные необходимо было сбалансировать, поскольку, как показывают исследования влияния несбалансированности выборки на аналогичной бинарной классификации, точность сети значительно падает, если соотношение хуже, чем 70 к 30, идеально же иметь соотношение 50 к 50 или близкое к нему, это обеспечивает наивысшую точность модели [26].

Самыми действенными методами балансировки, при этом не представляющими сложности, являются размножение класса меньшинства путем копирования экземпляров данных, а также уменьшение класса большинства до класса меньшинства. С учетом экстремально сильной несбалансированности (число банкротов очень мало), были применены оба подхода: класс меньшинства (банкроты) был размножен копированием пять раз, после чего из класса большинства (не банкротов) было случайным образом взято нужное число экземпляров, чтобы получить соотношение 50 к 50, далее выборка была случайным образом перемешана. Статус организации, если она банкрот, обозначен как «0», если она активна, то ее статус имеет метку «1». Таким образом, была получена выборка, содержащая около 9 300 строк данных.

Нормализация выборки для приведения всех показателей к одинаковой размерности, производилась одним из наиболее распространенных способов: Z-нормализацией, вычисляемой по формуле:

Россия, 10-летние. URL: <https://ru.investing.com/rates-bonds/russia-10-year-bond-yield-historical-data>;
Доходность облигации, Франция, 10-летние. URL: <https://ru.investing.com/rates-bonds/france-10-year-bond-yield-historical-data>

$$Norm_Data_l = \frac{Data_l - \overline{Data}}{Std(Data)}, \quad (1)$$

где $Norm_Data_l$ — нормированные данные показателя l ;

$Data_l$ — исходное значение показателя l ;

\overline{Data} — среднее значение показателя l ;

$Std(Data)$ — стандартное отклонение показателя l .

Если нормализацию не произвести, то нейронная сеть, вероятно, будет оценивать не столько сложные зависимости параметров, сколько изменения их масштаба [27].

Таким образом выборка для обучения была получена, теперь необходимо рассмотреть применяемые нейросетевые модели. Наиболее рациональным в данной задаче будет использование простой последовательной сети прямого распространения сигнала (FFNN), которую часто именуют многослойным перцептроном. Это классическая нейронная сеть, которая идеально подходит для получения прогностической модели. Реализация будет осуществляться с помощью связки TensorFlow и Keras на языке программирования Python.

Сеть получает на вход вектор из 26 показателей, которые подаются на первый слой сети, имеющий 2 048 нейронов и функцию активации SELU (масштабирования экспоненциальная линейная функция: при значениях меньше 0 применяется экспоненциальная часть, при больше 0 — линейная функция). Она не отсекает отрицательные значения (которые содержатся в выборке после Z-нормализации) и хорошо работает в данной ситуации (полученная точность выше чем на часто применяемой логистической (сигмоидальной) функции). Второй слой имеет меньшую размерность: 1 024 нейрона, функция активации — сигмоидальная (также называемая «гладкая ступенька»), кроме того, оба слоя осуществляют функцию dropout с коэффициентом 0,2, который на каждой эпохе обучения выключают нейроны с вероятностью 20% для каждого отдельного нейрона, это позволяет избежать переобучения сети из-за того, что нейроны второго слоя начинают работать на компенсацию ошибки первого, подстраиваясь под обучающую выборку.

Случайное исключение нейронов мешает такой адаптации и позволяет повысить точность модели. Выходной слой модели содержит 1 нейрон, функция активации сигмоидальная (в бинарной классификации всегда

используется данная функция активации на выходном нейроне), дающий ответ в диапазоне от 0 до 1, при приведении к классам (банкрот или не банкрот) значения больше 0,5 интерпретируются как класс «не банкрот», меньше — «банкрот». Чем ближе значение к нулю или единице, тем более сеть уверена в правильности своего ответа. Также этот вывод можно интерпретировать как вероятностную оценку, если инвертировать значение (из единицы вычесть вероятностный ответ модели), в таком случае значение, к примеру, 0,02 можно интерпретировать как вероятность банкротства 2% (сеть уверена, что компания при ее текущих показателях не станет банкротом), а показатель 0,99 — 99% скажет о том, что показатели компании идеально советуют характеристикам банкротов из обучающей выборки.

Примененной функцией потерь сети, которая используется алгоритмом обучения обратного распространения ошибки, является бинарная перекрестная энтропия⁷:

$$\text{LogLoss} = -\frac{1}{N} \sum_{i=1}^N y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i)), \quad (2)$$

где y — метка класса («0» или «1»);

$p(y)$ — вероятность, что ответ будет «1» для всех N экземпляров $i = 1..N$;

$1 - p(y)$ — вероятность, что ответ будет «0» для всех N экземпляров $i = 1..N$.

Эта функция потерь специально создана для задач бинарной классификации и является идеальной для этой задачи. Также мы использовали оптимизатор типа градиентного спуска «adam» (adaptive moment estimation) вместо использования фиксировано установленного параметра скорости обучения. Данный алгоритм очень эффективен и хорошо ведет себя на сложных топологиях (вроде нашей, содержащей множество параметров). Применение данного оптимизатора крайне полезно ввиду наличия нескольких проблем, свойственных обучению ИНС [28]:

- множество весовых коэффициентов в сети большого размера, из-за чего функция может застрять в локальном минимуме, таким образом уменьшив достигаемую точность модели;
- сложный ландшафт целевой функции с регионами сильной нелинейности;

⁷ *Godoe D.* Understanding binary cross-entropy / log loss: a visual explanation. Towards data science, 2018. URL: <https://towardsdatascience.com/understanding-binary-cross-entropy-log-loss-a-visual-explanation-a3ac6025181a>

- хотя ИНС как один из наиболее гибких алгоритмов машинного обучения может обнаруживать скрытые закономерности, некоторые параметры встречаются редко, и если сеть начнет придавать им высокое значение, это может привести к переобучению;
- применение оптимизатора значительно упрощает процесс подбора гиперпараметров сети, исключая необходимость подбора параметра скорости обучения, который при слишком низком значении приводит к застраиванию в локальном минимуме и долгому обучению, а при слишком высоком — к пропуску глобального минимума.

Также нами была применена функция библиотеки Keras, которая позволяет сохранять модель после каждой эпохи только в том случае, если ее точность на проверочной выборке возросла, это также позволяет избежать переобучения сети и потери точности при большом числе эпох обучения, которое благодаря применению dropout может позволить случайным образом найти лучшую версию модели. Число эпох обучения было установлено на значение 100.

Размер пакета (batch size), то есть число экземпляров выборки, которые загружаются в сеть перед обновлением весов сети, принято за 40. Этот параметр нужен, поскольку обновлять веса после каждого экземпляра не рационально — дает высокую нагрузку на сеть и также ведет к переобучению, а пропустить за один раз всю выборку целиком сложно и эффективность обновления коэффициентов будет значительно ниже, что потребует значительно больше эпох обучения и, как следствие, времени для достижения желаемой точности модели. В результате обучения был получен график изменения точности на проверочной и на обучающей выборке (рис. 1).

Как видно, точность на обучающей выборке продолжала расти в течение всего периода обучения, что говорит о том, что применение большого числа эпох обучения не было излишним.

Обученная нами модель достигла точности на проверочной выборке в 94,36% при AUC (Area under ROC curve) более 0,99. Данный показатель можно считать очень хорошим с учетом сложности модели, с которой производится работа. Как видно, точность данной непараметрической модели значительно превышает точность параметрических методов, вроде моделей Э. Альтмана, М. Змиевского или Дж. Олсона, в среднем на 10–15%, что является значительным преимуществом.

Таким образом, в результате исследования была собрана выборка данных о статистике банкротства компаний за недавние годы, выборка была подготовлена к использованию в алгоритмах машинного обучения. Также была разработана модель ИНС, которая обучилась на созданной выборке до весьма высокой точности, что при практическом ее применении позволило бы предсказывать банкротство компаний с достаточно высокой точностью только на основе внутренних показателей бухгалтерской отчетности и нескольких внешних рыночных показателей.

Таблица 1
Программные библиотеки, реализующие ИНС

Table 1
Program libraries running artificial neural networks

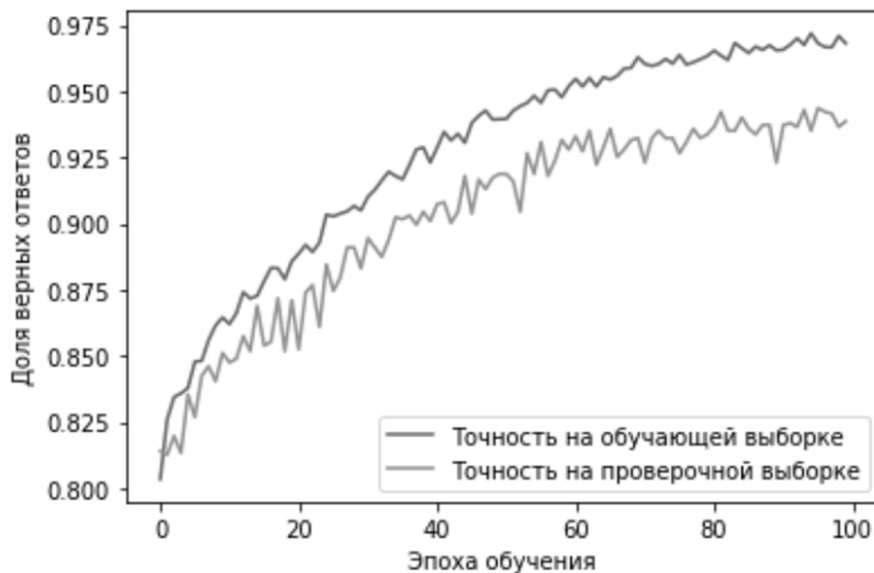
Название	Назначение и особенности библиотеки/фреймворка
TensorFlow	Низкоуровневая библиотека МО от Google может использовать TPU (тензорный процессор) для вычислений. Один из наиболее широко используемых программных инструментов в МО. Может применяться со множеством языков программирования. Также может использовать GPU (графический процессор), что упрощает использование вычислений на видеокартах
Keras	Высокоуровневая библиотека на языке Python, надстройка для TensorFlow, предназначенная для упрощения программирования ИНС
PyTorch	Высокоуровневая библиотека на языке Python и C++, однако самостоятельна, не требует TensorFlow, включает в себя Caffe2 — среду для глубокого обучения
Theano	Библиотека численного вычисления для Python. Может выполнять задачи МО, при этом способна работать с очень большими сетями
MLR, Caret, RandomForest	Различные библиотеки языка R (и некоторых других языков), реализующие различные функции машинного обучения

Источник: авторская разработка

Source: Authoring

Рисунок 1
График обучения ИНС

Figure 1
The Training schedule of the artificial neural network



Источник: авторская разработка

Source: Authoring

Список литературы

1. Altman E.I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 1968, vol. 23, iss. 4, pp. 589–609. URL: <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
2. Almaskati N., Bird R., Yeung D., Lu Y. A horse race of models and estimation methods for predicting bankruptcy. *Advances in Accounting*, 2021, vol. 52, 100513. URL: <https://doi.org/10.1016/j.adiac.2021.100513>
3. Горбачёв А.С., Дроговоз П.А. Прогнозирование как инструмент опережающего развития технологических компетенций в промышленности // Креативная экономика. 2020. Т. 14. № 12. С. 3427 — 3438. URL: <https://doi.org/10.18334/ce.14.12.111455>
4. Дроговоз П.А., Рассомгин А.С. Обзор современных методов интеллектуального анализа данных и их применение для принятия управленческих решений // Экономика и предпринимательство. 2017. № 3-1. С. 689 — 693.

5. *Hebb D.O.* The Organization of Behavior: A Neuropsychological Theory. Wiley, 1949.
6. *Каллан Р.* Основные концепции нейронных сетей. М.: Вильямс, 2017. 288 с.
7. *Горбачевская Е.Н., Краснов С.С.* История развития нейронных сетей // Вестник волжского университета им. В.Н. Татищева. 2015. № 1. С. 52—56.
8. *Хайкин С.* Нейронные сети: полный курс. 2-е изд. М.: Вильямс, 2006. 1104 с.
9. *Люгер Д.Ф.* Искусственный интеллект: стратегии и методы решения сложных проблем. М.: Вильямс, 2005. 864 с.
10. *Дебок Г., Кохонен Т.* Анализ финансовых данных с помощью самоорганизующихся карт. М.: Альпина Паблишер, 2001. 317 с.
11. *Краснов М.А.* Метод предсказания динамики финансовых временных рядов в инвестировании // *Terra Economicus*. 2009. Т. 7. № 1-2. С. 93—98. URL: <https://cyberleninka.ru/article/n/metod-predskazaniya-dinamiki-finansovyh-vremennyh-ryadov-v-investirovanii/viewer>
12. *Kohonen T.* Self-Organizing Maps. NY, Springer-Verlag, 2001, 502 p.
13. *Silva B., Marques N.* Ubiquitous Self-Organizing Map: Learning Concept-Drifting Data Streams. In: *Rocha A., Correia A., Costanzo S., Reis L. (eds) New Contributions in Information Systems and Technologies. Advances in Intelligent Systems and Computing, Springer, Cham, 2015, vol. 353.* URL: https://doi.org/10.1007/978-3-319-16486-1_70
14. *Загоруйко Н.Г., Кутненко О.А.* Цензурирование обучающей выборки // Вестник Томского государственного университета. Управление, вычислительная техника и информатика. 2013. № 1. С. 66—73. URL: <https://cyberleninka.ru/article/n/tsenzurovanie-obuchayuschey-vyborki/viewer>
15. *Bishop C.M., Svensen M., Williams C.K.I.* Developments of the generative topographic mapping. *Neurocomputing*, 1998, vol. 21, iss. 1, pp. 203–224. URL: [https://doi.org/10.1016/S0925-2312\(98\)00043-5](https://doi.org/10.1016/S0925-2312(98)00043-5)
16. *Hochreiter S., Schmidhuber J.* Long short-term memory. *Neural Computation*, 1997, vol. 9, iss. 8, pp. 1735–1780. URL: <https://doi.org/10.1162/neco.1997.9.8.1735>

17. Горбатков С.А. и др. Методологические основы разработки нейросетевых моделей экономических объектов в условиях неопределенности. М.: Экономическая газета, 2012. 494 с.
18. Коротеев М.В. Обзор некоторых современных тенденций и технологий машинного обучения // *E-Management*. 2018. Т. 1. № 1. С. 26—35.
URL: <https://doi.org/10.26425/2658-3445-2018-1-26-35>
19. Bughin J., Hazan E., Ramaswamy S. et al. *Artificial Intelligence: The Next Digital Frontier?* McKinsey Global Institute, 2017, 80 p.
20. Дроговоз П.А., Коренькова Д.А. Современный инструментарий гибкого управления ИТ-проектами и перспективы его совершенствования с использованием технологий искусственного интеллекта // *Экономика и предпринимательство*. 2019. № 10. С. 829—833.
21. Биконов Д.В., Бражкин А.А., Пузиков А.Д. и др. Высокоуровневая система параллельного программирования многоядерного гибридного процессора // *Наноиндустрия*. 2020. Т. 13. № S4. С. 94—96.
URL: <https://doi.org/10.22184/1993-8578.2020.13.4s.94.96>
22. Макаров В.Л., Бахтизин А.Р., Бекларян Г.Л. Разработка цифровых двойников для производственных предприятий // *Бизнес-информатика*. 2019. Т. 13. № 4. С. 7—16. URL: <https://doi.org/10.17323/1998-0663.2019.4.7.16>
23. Кафтанников И.Л., Парасич А.В. Проблемы формирования обучающей выборки в задачах машинного обучения // *Вестник Южно-уральского государственного университета*. Серия: Компьютерные технологии, управление, радиоэлектроника. 2016. Т. 16. № 3. С. 15—24.
24. Santoro E., Gaffeo E. Business Failures, Macroeconomic Risk and the Effect of Recessions on Long-Run Growth: A Panel Cointegration Approach. *Journal of Economics and Business*, 2009, vol. 61, iss. 6, pp. 435–452.
URL: <https://doi.org/10.1016/j.jeconbus.2009.05.001>
25. Platt H.D., Platt M.B., Pedersen J.G. Bankruptcy discrimination with real variables. *Journal of Business Finance & Accounting*, 1994, vol. 21, iss. 4, pp. 491–510. URL: <https://doi.org/10.1111/j.1468-5957.1994.tb00332.x>
26. Veganzones D., Séverin E. An investigation of bankruptcy prediction in imbalanced datasets. *Decision Support Systems*, 2018, vol. 112, pp. 111–124. URL: <https://doi.org/10.1016/j.dss.2018.06.011>
27. Большаков М.А. Подготовка данных системы мониторинга ИТ-инфраструктуры для моделей выявления критических состояний

на основе нейросетей // Научные технологии в космических исследованиях Земли. 2019. Т. 11. № 4. С. 65—71.

URL: <https://cyberleninka.ru/article/n/podgotovka-dannyh-sistemy-monitoringa-it-infrastruktury-dlya-modeley-vyyavleniya-kriticheskikh-sostoyaniy-na-osnove-neyrosetey/viewer>

28. *Goodfellow L., Bengio Y., Courville A.* Deep Learning (Adaptive Computation and Machine Learning Series). The MIT Press, 2016, 800 p.

Информация о конфликте интересов

Я, автор данной статьи, со всей ответственностью заявляю о частичном и полном отсутствии фактического или потенциального конфликта интересов с какой бы то ни было третьей стороной, который может возникнуть вследствие публикации данной статьи. Настоящее заявление относится к проведению научной работы, сбору и обработке данных, написанию и подготовке статьи, принятию решения о публикации рукописи.

THE INSTRUMENTAL MACHINE LEARNING METHODS FOR CORPORATE BANKRUPTCY PREDICTION

Aleksandr R. NEVREDINOV

Bauman Moscow State Technical University (BMSTU),
Moscow, Russian Federation
a.r.nevredinov@gmail.com
ORCID: not available

Article history:

Article No. 317/2021
Received 27 May 2021
Received in revised form 10 June 2021
Accepted 24 June 2021
Available online
30 September 2021

JEL classification:
C53, G3

Keywords: bankruptcy
forecast, machine
learning, company
analysis, artificial
neural networks

Abstract

Subject. It is very important for corporate governance and a choice of partners to evaluate the company's position. Therefore, bankruptcy forecast methods have been actively studied in theoretical and practical proceedings for a long time. Recurring crises and high market dynamics make the subject especially relevant.

Objectives. I develop the instrumental method based on machine learning to predict corporate bankruptcy. The study also reviews data sources, the potential of forecasting models, and chooses inputs for company analysis.

Methods. I applied methods of analysis and synthesis, and the systematization, formalization, comparative analysis. I referred to theoretical and methodological principles set forth in national and foreign proceedings on the company analysis and bankruptcy prediction. I investigate issues of data compilation, and building the artificial neural network for teaching the model.

Results. I proposed and tested the instrumental method to predict bankruptcy. I suggest using my own sets of indicators for forecasting, which I selected by analyzing key indicators of financial sustainability, efficacy, and key external factors influencing market actors. The article presents a data sample for teaching purposes, which includes both the Russian and foreign companies, thus expanding its size. I devised machine learning models generating high-precision forecasts.

Conclusions and Relevance. The findings contribute to bankruptcy prediction methods and can be used for administrative decision-making to automate their own analysis or analyze other entities, which the company cooperates with.

© Publishing house FINANCE and CREDIT, 2021

Please cite this article as: Nevredinov A.R. The Instrumental Machine Learning Methods for Corporate Bankruptcy Prediction. *Finance and Credit*, 2021, vol. 27, iss. 9, pp. 2118–2138. <https://doi.org/10.24891/fc.27.9.2118>

References

1. Altman E.I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 1968, vol. 23, iss. 4, pp. 589–609. URL: <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>

2. Almaskati N., Bird R., Yeung D., Lu Y. A Horse Race of Models and Estimation Methods for Predicting Bankruptcy. *Advances in Accounting*, 2021, vol. 52, 100513. URL: <https://doi.org/10.1016/j.adiac.2021.100513>
3. Gorbachev A.S., Drogovoz P.A. [Forecasting as a tool for advanced development of technological competencies in industry]. *Kreativnaya ekonomika = Creative Economy*, 2020, vol. 14, no. 12, pp. 3427–3438. (In Russ.) URL: <https://doi.org/10.18334/ce.14.12.111455>
4. Drogovoz P.A., Rassomgin A.S. [Review of modern methods of data analysis and their usage for management problem solving]. *Ekonomika i predprinimatel'stvo = Journal of Economy and Entrepreneurship*, 2017, no. 3-1, pp. 689–693. (In Russ.)
5. Hebb D.O. *The Organization of Behavior: A Neuropsychological Theory*. Wiley, 1949.
6. Callan R. *Osnovnye kontseptsii neironnykh setei* [The Essence of Neural Networks]. Moscow, Vil'yams Publ., 2017, 288 p.
7. Gorbachevskaya E.N., Krasnov S.S. [The history of the development of neural networks]. *Vestnik volzhskogo universiteta im. V.N. Tatishcheva = Vestnik of Volzhsky University after V.N. Tatishchev*, 2015, no. 1, pp. 52–56. (In Russ.)
8. Haykin S. *Neironnye seti: polnyi kurs* [Neural Networks: A Comprehensive Foundation]. 2nd ed. Moscow, Vil'yams Publ., 2006, 1104 p.
9. Luger D.F. *Iskusstvennyi intellekt: strategii i metody resheniya slozhnykh problem* [Artificial Intelligence: Structures and Strategies for Complex Problem Solving]. Moscow, Vil'yams Publ., 2005, 864 p.
10. Debok G., Kohonen T. *Analiz finansovykh dannykh s pomoshch'yu samoorganizuyushchikhsya kart* [Russian edition. The analysis of financial data through self-organizing maps]. Moscow, Al'pina Publisher Publ., 2001, 317 p.
11. Krasnov M.A. [The method for predicting the dynamics of financial time series in investing]. *Terra Economicus*, 2009, vol. 7, no. 1-2, pp. 93–98. URL: <https://cyberleninka.ru/article/n/metod-predskazaniya-dinamiki-finansovyh-vremennyh-ryadov-v-investirovanii/viewer> (In Russ.)
12. Kohonen T. *Self-Organizing Maps*. NY, Springer-Verlag, 2001, 502 p.
13. Silva B., Marques N. Ubiquitous Self-Organizing Map: Learning Concept-Drifting Data Streams. In: Rocha A., Correia A., Costanzo S., Reis L. (eds) *New Contributions in Information Systems and Technologies*. Advances

- in *Intelligent Systems and Computing*, Springer, Cham, 2015, vol. 353.
URL: https://doi.org/10.1007/978-3-319-16486-1_70
14. Zagoruiko N.G., Kutnenko O.A. [Training dataset censoring]. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naya tekhnika i informatika = Tomsk State University Journal of Control and Computer Science*, 2013, no. 1, pp. 66–73.
URL: <https://cyberleninka.ru/article/n/tsenzurovanie-obuchayushey-vyborki/viewer> (In Russ.)
15. Bishop C.M., Svensen M., Williams C.K.I. Developments of the Generative Topographic Mapping. *Neurocomputing*, 1998, vol. 21, iss. 1-3, pp. 203–224.
URL: [https://doi.org/10.1016/S0925-2312\(98\)00043-5](https://doi.org/10.1016/S0925-2312(98)00043-5)
16. Hochreiter S., Schmidhuber J. Long Short-term Memory. *Neural Computation*, 1997, vol. 9, iss. 8, pp. 1735–1780.
URL: <https://doi.org/10.1162/neco.1997.9.8.1735>
17. Gorbalkov S.A. et al. *Metodologicheskie osnovy razrabotki neirosetyvykh modelei ekonomicheskikh ob"ektov v usloviyakh neopredelennosti* [Methodological foundations for the development of neural network models of economic objects in conditions of uncertainty]. Moscow, Ekonomicheskaya gazeta Publ., 2012, 494 p.
18. Koroteev M.V. [Review of some contemporary trends in machine learning technology]. *E-Management*, 2018, vol. 1, no. 1, pp. 26–35. (In Russ.)
URL: <https://doi.org/10.26425/2658-3445-2018-1-26-35>
19. Bughin J., Hazan E., Ramaswamy S. et al. *Artificial Intelligence: The Next Digital Frontier?* McKinsey Global Institute, 2017, 80 p.
20. Drogovoz P.A., Koren'kova D.A. [Modern tools for agile management of IT projects and prospects for its improvement using artificial intelligence technologies]. *Ekonomika i predprinimatel'stvo = Journal of Economy and Entrepreneurship*, 2019, no. 10, pp. 829–833. (In Russ.)
21. Bikonov D.V., Brazhkin A.A., Puzikov A.D. et al. [High-level parallel programming system for multicore hybrid processor]. *Nanoindustriya = Nanoindustry*, 2020, vol. 13, no. S4, pp. 94–96. (In Russ.)
URL: <https://doi.org/10.22184/1993-8578.2020.13.4s.94.96>
22. Makarov V.L., Bakhtizin A.R., Beklaryan G.L. [Developing digital twins for production enterprises]. *Biznes-informatika = Business Informatics*, 2019, vol. 13, no. 4, pp. 7–16. (In Russ.)
URL: <https://doi.org/10.17323/1998-0663.2019.4.7.16>

23. Kaftannikov I.L., Parasich A.V. [Problems of training sample formation in machine learning problems]. *Vestnik Yuzhno-ural'skogo gosudarstvennogo universiteta. Seriya: Komp'yuternye tekhnologii, upravlenie, radioelektronika = Bulletin of South Ural State University. Series: Computer Technologies, Automatic Control, Radioelectronics*, 2016, vol. 16, no. 3, pp. 15–24. (In Russ.)
24. Santoro E., Gaffeo E. Business Failures, Macroeconomic Risk and the Effect of Recessions on Long-Run Growth: A Panel Cointegration Approach. *Journal of Economics and Business*, 2009, vol. 61, iss. 6, pp. 435–452. URL: <https://doi.org/10.1016/j.jeconbus.2009.05.001>
25. Platt H.D., Platt M.B., Pedersen J.G. Bankruptcy Discrimination with Real Variables. *Journal of Business Finance & Accounting*, 1994, vol. 21, iss. 4, pp. 491–510. URL: <https://doi.org/10.1111/j.1468-5957.1994.tb00332.x>
26. Veganzones D., Séverin E. An Investigation of Bankruptcy Prediction in Imbalanced Datasets. *Decision Support Systems*, 2018, vol. 112, pp. 111–124. URL: <https://doi.org/10.1016/j.dss.2018.06.011>
27. Bol'shakov M.A. [Preparation of data monitoring system of IT infrastructure for critical state detection model based on neural networks]. *Naukoemkie tekhnologii v kosmicheskikh issledovaniyakh Zemli = H&ES Research*, 2019, vol. 11, no. 4, pp. 65–71. URL: <https://cyberleninka.ru/article/n/podgotovka-dannyh-sistemy-monitoringa-it-infrastruktury-dlya-modeley-vyyavleniya-kriticheskikh-sostoyaniy-na-osnove-neyrosetey/viewer> (In Russ.)
28. Goodfellow L., Bengio Y., Courville A. *Deep Learning (Adaptive Computation and Machine Learning Series)*. The MIT Press, 2016, 800 p.

Conflict-of-interest notification

I, the author of this article, bindingly and explicitly declare of the partial and total lack of actual or potential conflict of interest with any other third party whatsoever, which may arise as a result of the publication of this article. This statement relates to the study, data collection and interpretation, writing and preparation of the article, and the decision to submit the manuscript for publication.