

DOI: 10.14451/1.234.508

Подходы к прогнозированию финансовых показателей с помощью нейронных сетей

© 2024 Пыркин Алексей Германович

финансовый директор, ООО «Дзен Платформа», г. Москва

E-mail: apyrkin@mail.ru

Ключевые слова: прогноз, нейронная сеть, финансовые показатели, модель.

В статье рассмотрены современные подходы к прогнозированию финансовых показателей с использованием инструментария нейронных сетей. Отдельное внимание уделено теоретико-методическим аспектам применения нейронных сетей для составления финансовых прогнозов. Также в статье представлена модель прогнозирования эффективности работы компании с использованием глубокой нейронной сети убеждений. Формализована структура нейронной сети и процесс ее обучения. Эмпирически доказана эффективность модели.

Финансовые показатели – это комплексное отражение эффективности и результативности производства, итог деятельности субъекта хозяйствования или целого сектора, индикаторы прибыльности, платежеспособности, операционной гибкости и потенциала роста. Оценка и прогнозирование финансовых показателей может осуществляться как отдельными лицами, так и организациями с использованием научных методов и специальных приемов [3]. Составление финансового прогноза является одним из важнейших элементов принятия решений в современном мире, как в государственном, так и в частном секторе. Оценивая и делая предположения о результатах деятельности, представляется возможным выявить проблемы в процессе производства и эксплуатации, проанализировать их причины, улучшить работу и управление в будущем.

За последние несколько десятилетий составление финансовых прогнозов на основе эконо-

метрических моделей стало очень популярным приемом, однако, необходимо отметить, что это никогда не было легкой задачей из-за чувствительности финансовых детерминант и их динамики к политическим, экономическим и социальным факторам. Анализ финансовых результатов по своей сути сложен, и данные демонстрируют нелинейные закономерности и зависимости [8]. Упрощенный подход, например, полагающийся исключительно на субъективную классификацию или использование отдельных методов изолированно, может оказаться неэффективным для отражения тонкостей лежащих в основе финансовых данных.

Прогнозированию финансовых показателей посвящено множество исследований, в ходе которых были предложены различные методы, начиная от классических статистических или традиционных моделей, таких как модель авторегрессионного интегрированного скользящего среднего (ARIMA) и ее варианты, авторегрессионная




Рис. 1. Архитектура глубокой нейронной сети убеждений (DBN).




Рис. 2. Процесс обучения DBN с использованием нескольких ограниченных машин Больцмана (RBM).

условная гетероскедастичность (ARCH) и обобщенная авторегрессионная условная гетероскедастичность (GARCH), экспоненциальное сглаживание и его адаптации, до более сложных моделей, таких как процесс анализа иерархий (АНР), метод предпочтения порядка по сходству с идеальным решением (TOPSIS), нечеткая комплексная оценка (FCE), анализ оболочки данных (DEA), анализ главных компонент (DEA) [1; 10].

Однако, на сегодняшний день особую популярность приобрели нейронные сети, которые стали широко используемым инструментом принятия финансовых решений. Их распространенность объясняется тем, что они подходят для работы с зашумленными, нестационарными и большими данными. В тоже время, результаты исследований, посвященных способности нейронных сетей прогнозировать финансовые показатели, неоднозначны [4]. Объясняется это разнообразием дизайна исследований, широким спектром используемых критериев, поэтому сравнивать

итоги и выводы различных экспериментов достаточно проблематично. В связи с этим, вопросы перспектив и возможностей использования нейронных сетей для составления финансовых прогнозов остаются открытыми и требуют проведения дальнейших исследований, что и предопределило выбор темы данной статьи.

Систематический обзор исследований глубокого обучения и приложений для прогнозирования финансовых показателей работы предприятий представлен в трудах Пынько Л. Е., Толкачевой Е. В., Галаниной О. В., Золотаревой Ю. П., Changjin Xu, Wei Zhang, Chaouki Aouiti, Zixin Liu, Maoxin Liao, Peiluan Li.

Сравнению различных методов и алгоритмов, используемых для составления прогноза динамики экономических рядов, посвятили свои публикации Абдуллаев Н. В. О., Баранова М. А., Матюшин Д. В., Кох Л. В., Блохин Н. В., Макрушин С. В., Ajay Singh, Vaibhav Jindal, Rajinder Sandhu, Victor Chang.

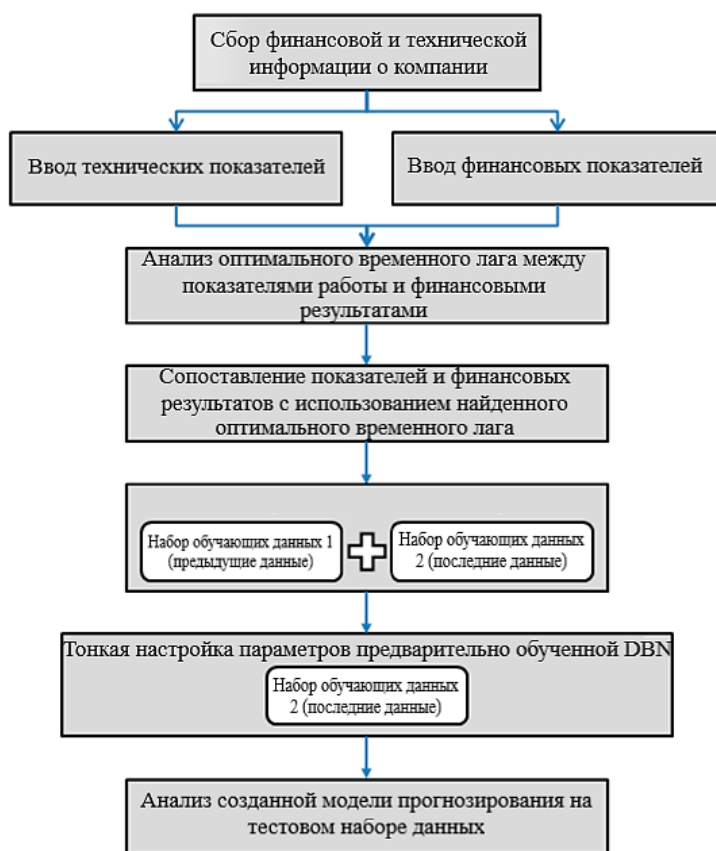


Рис. 3. Краткое описание предложенной модели прогнозирования.

Особенности применения нейронных сетей в качестве инструмента нелинейного прогнозирования для предсказания международных премий за риск на фондовых рынках описываются Мусацковым В. Ю., Афанасьевой Г. А., Шаталовой А. Ю., Зинёвым В. А., Anna Almosova, Niek Andresen, Soniya, Lotika Singh, Sandeep Paul.

В тоже время, несмотря на пристальный интерес ученых к рассматриваемой проблематике, большое количество параметров, которые необходимо выбрать для разработки модели прогнозирования нейронной сети, означает, что процесс проектирования по-прежнему включает в себя множество проб и ошибок. Отдельного внимания заслуживает вопрос выбора функций нейронной сети, которые лучше всего подходят для прогнозирования финансовых показателей.

Таким образом, цель статьи заключается в рассмотрении особенностей прогнозирования финансовых показателей с помощью нейронных

сетей.

Нейронные сети – это тип алгоритмов машинного обучения, которые становятся все более популярными в финансовой сфере благодаря своей способности изучать сложные взаимосвязи между входными и выходными данными. Они состоят из взаимосвязанных искусственных нейронов, которые обрабатывают информацию и изучают закономерности в данных в процессе обучения [9]. Нейронные сети способны анализировать большие объемы данных и улавливать нелинейные зависимости между переменными, что делает их весьма адаптируемыми для широкого спектра финансовых приложений. Тем не менее, такие проблемы, как чрезмерная подгонка и интерпретируемость, должны быть тщательно проработаны. Несмотря на эти сложные моменты, нейронные сети продемонстрировали значительные перспективы в области финансов и, вероятно, будут играть все большую роль в финансовом прогнозировании и принятии ре-

шений.

Использование нейронных сетей в финансовой сфере требует тщательной подготовки данных и разработки признаков. Основные этапы подготовки данных включают сбор подходящих индикаторов, выбор наиболее релевантных признаков, предварительную обработку данных и создание новых признаков с помощью инженерии признаков [5]. Данные должны быть разделены на обучающие и тестовые, а нейронная сеть должна быть проверена и ее гиперпараметры настроены для оптимизации работы. Следуя этим шагам, можно адаптировать нейронную сеть для финансового прогнозирования и принятия решений.

Идея прогнозирования финансовых показателей с использованием нейронных сетей состоит в том, чтобы построить функцию принятия решения $h(x)$ для аппроксимации результата или метки y (которая является бинарной, либо ноль, либо единица) [7]. Решение можно интерпретировать как простую взвешенную функцию, линейную комбинацию, например, двух признаков x_1 и x_2 :

$$h(x; \theta, b) = \theta_1 x_1 + \theta_2 x_2 + b,$$

что также можно записать в виде:

$$y = h(x; \theta, b) = \theta^T x + b.$$

Основная задача - найти вектор весов и параметр b (смещение), которые можно использовать для описания и предсказания результата y . Нейронный процесс – это биологический процесс, который описывает, как нейронная клетка обучается. Нейронная клетка обрабатывает информацию, полученную от стимулов, а затем использует ряд синапсов для передачи новой информации, которая уже обработана. Нейронная сеть пытается воспроизвести тот же процесс, используя входные узлы для получения информации, один скрытый слой для обработки информации с помощью функции активации, а затем выходные узлы, на которые поступает обработанная информация [6]. Получив выходное

значение y , необходимо обучить. В результате в конце будут получены веса, которые можно использовать для прогнозирования.

Процесс обучения нейронной сети зависит от функции активации, а также от метода рекурсивного поиска соответствующих весов. Обычно обучение нейронной сети начинается со случайных входных значений, а затем применяются веса к каждой точке данных, которые будут передавать информацию на скрытый слой, где она будет обрабатываться функцией активации. Веса θ^T пересчитываются итеративно до тех пор, пока не будет достигнута сходимость [2]. Желательно, чтобы значения, которые получаются от функции принятия решения $h(x; \theta, b)$, находились в небольшом диапазоне, например, между 0 и 1. Один из способов добиться этого - преобразовать функцию принятия решения $h(x; \theta, b)$ в новую функцию, которая будет давать на выходе значения между 0 и 1:

$$h(x; \theta, b) = g(\theta^T x + b).$$

Чтобы представить g как новую функцию $z(x) = \theta^T x + b$, можно использовать сигмоидальную функцию (хотя есть и другие типы функций, которые могут быть полезны для представления g):

$$g(z) = \frac{1}{1 + e^{-z}}.$$

Рассмотрим более детально как прогнозирование реализуется на практике.

Итак, необходимо решить задачу составления прогноза корпоративной эффективности. В качестве предикторов используется 11 финансовых показателей, их описательная статистика представлена в таблице 1.

Для решения этой задачи используем ограниченную машину Больцмана (RBM) в качестве основного компонента глубокой нейронной сети убеждений (DBN). После предварительного обучения с использованием RBM предложенная

Таблица 1. Описательная статистика финансовых показателей корпорации.

Финансовый показатель	Минимум	Максимум	Среднее	Стандартное отклонение
Выручка (млн, руб.)	0,2	74331	18027,55	18132,86
Рост выручки (млн, руб.)	-19160	40360	1498,12	4679,32
Операционная прибыль (млн, руб.)	-3016	22193	4226,28	4676,32
Рост операционной прибыли (млн, руб.)	-11314	13986	365,74	2354,49
Чистая прибыль (млн, руб.)	-4886	22003	3407,01	4016,59
Рост чистой прибыли (млн, руб.)	-12867	12773	341,74	2601,51
Валовая прибыль (млн, руб.)	-49,16	52340	13044,44	13327,01
Операционные расходы (млн, руб.)	9,51	53833	13772,44	14054,36
Акционерный капитал (млн, руб.)	-72,13	90450	17401,59	21827,93
Совокупные активы (млн, руб.)	8,73	212950	36185,63	42421,32
Коэффициент достаточности капитала (%)	-1,54	0,88	0,48	0,21

модель настраивается с помощью алгоритма обратного распространения. DBN – это генеративная модель с большим количеством слоев. Процесс обучения DBN можно разделить на две фазы. Первая фаза – это этап предварительного обучения, использующий ненаблюдаемое обучение и RBM. На втором этапе происходит тонкая настройка предварительно обученной нейронной сети для прогнозирования на наборе обучающих данных. На рисунке 1 показана DBN с тремя скрытыми слоями.

Как показано на рисунке 1, связь между слоями h^3 и h^2 является ненаправленной, а связи между нижними слоями направлены вниз. Два верхних слоя DBN состоят из RBM, действующей как

ассоциативная память для признаков верхнего уровня в DBN. Нижние слои состоят из сигмоидальной сети убеждений (SBN).

Например, два верхних слоя DBN с N скрытыми слоями содержат RBM, состоящую из h^N, h^{N-1}, W_N . Распределение вероятностей h^{N-1} выражается следующим образом:

$$p(h^{N-1}|W_N) = P_{RBM}(v = h^{N-1}|W_N).$$

Распределение вероятностей h^{N-2} , расположенное в следующем слое, соответствует распределению вероятностей SBN, которое описывается такой формулой:

$$\begin{aligned} p(h^{N-2}|W_{N-1}, W_N) &= \sum_{h^{N-1}} p(h^{N-2}, h^{N-1}|W_{N-1}, W_N) = \\ &= \sum_{h^{N-1}} P_{Sig}(v = h^{N-2}|h^{N-1}W_{N-1}) P_{RBM}(v = h^{N-1}|W_N). \end{aligned}$$

Распределение вероятностей i -го скрытого слоя h^i имеет следующий вид:

$$\begin{aligned} p(h^i|W_{i+1}, \dots, W_{N-1}, W_N) &= \sum_{h^{i+1}} p(h^i, h^{i+1}|W_{i+1}, \dots, W_{N-1}, W_N) = \\ &= \sum_{h^{i+1}} P_{Sig}(v = h^i|h^{i+1}, W_{i+1}) p(h^{i+1}|W_{i+3}, \dots, W_{N-1}, W_N). \end{aligned}$$

Наконец, распределение вероятностей видимого слоя v в нижней части сети описывается так:

$$p(v|W_1, \dots, W_{N-1}, W_N) = \sum_{h^1} P_{\text{Sig}}(v|h^1, W_1)p(h^1|W_2, \dots, W_{N-1}, W_N)$$

Процесс обучения DBN осуществляется путем изменения ее параметров таким образом, чтобы связь между «данными» и «признаком» была хорошо выражена. Для DBN с N скрытыми слоями параметры W_1, W_2, \dots, W_N обучаются путем

поиска W_1, W_2, \dots, W_N , которые содержат максимальное логарифмическое правдоподобие обучающих данных v для W_1, W_2, \dots, W_N . Лог-правдоподобие v для параметров DBN выражается следующим образом:

$$\ln p(v|W_1, \dots, W_{N-1}, W_N) = \ln \sum_{h^1} P_{\text{Sig}}(v|h^1, W_1)p(h^1|W_2, \dots, W_{N-1}, W_N).$$

Как и в случае с SBN, достаточно проблематично получить значения логарифмического правдоподобия напрямую, если скрытые узлы одного слоя связаны со скрытыми узлами другого слоя. Поэтому DBN обучается путем определения параметра, который максимизирует нижнюю границу (L_p) логарифмического правдоподобия. Когда верхние параметры W_2, \dots, W_{N-1}, W_N и нижний параметр W_1 ограничены, процессы максимизации нижней границы логарифмического правдоподобия и обучения RBM с использованием W_1 в качестве параметра одинаковы. Предложенный процесс обучения показан на рисунке 2.

Как показано на рисунке 2, W_1 обучается с помощью RBM с заданными обучающими данными v . Затем обученный W_1 фиксируется и выбирает $h^{1(k)}$ по $P_{\text{RBM}}(h^1|v, W_1)$. Для обучения второго слоя W_2 обучается с помощью RBM с выборкой $h^{1(k)}$. Затем $h^{2(k)}$ для $h^{1(k)}$ дискредитируется по $P_{\text{RBM}}(h^2|h^1, W_2)$.

Итак, с учетом вышеизложенного в статье предлагается модель прогнозирования корпоративной эффективности на основе глубокой нейронной сети, обученной с помощью RBM. В целом, влияние каждого предиктора корпоративной эффективности меняется в зависимости от рынка и условий ведения бизнеса. Поэтому при прогнозировании корпоративной эффективности приоритет должен отдаваться более свежим тенденциям. На рисунке 3 представлена предлагаемая модель.

Для того чтобы проверить эффективность прогнозирования предложенной модели на эмпирическом уровне, был составлен прогноз показателей деятельности корпорации (выручка, операционная прибыль) на 2022–2023 гг. с помощью обученной модели и тестового набора данных. Среднеквадратичная ошибка (RMSE) между фактической и прогнозируемой выручкой за 2022–2013 годы составляет 3146,44 млн. руб. Предложенная модель точно прогнозирует выручку компании. Значение RMSE между фактической и прогнозируемой операционной прибылью за 2022–2023 годы составляет 2876,36 млн. руб. Предложенная модель относительно точно прогнозирует операционную прибыль по сравнению с другими моделями, основанными на алгоритмах машинного обучения. Однако, поскольку операционная прибыль в целом более волатильна, чем выручка, прогнозы модели не столь точны.

Таким образом, в настоящее время одним из самых перспективных методов финансового прогнозирования является использование искусственных нейронных сетей, которые имеют ряд преимуществ перед другими методами, среди которых главной является возможность исследования зависимости прогнозируемой величины от независимых переменных.

В статье представлена модель прогнозирования эффективности работы корпорации с использованием глубокой нейронной сети убеждений. Формализована структура нейронной

сети и процесс ее обучения. Также проведена эмпирическая проверка эффективности модели. Результаты показали, что предложенная модель демонстрирует хорошие прогнозные характеристики.

Библиографический список

1. Абдуллаев Н. В. О., Баранова М. А. Применение искусственных нейронных сетей в экономике // Наука Красноярья. – 2023. – Т. 12, № 1/2. – С. 22–28.
2. Виноградова Е. Б., Мальтин О. В. Автоматизация принятия управленческих решений в организации с использованием нейронных сетей // Бизнес и общество. – 2023. – 4 (40).
3. Клевцов Д. В. Перспективы использования нейронных сетей в современной экономике // Международный журнал прикладных наук и технологий Integral. – 2020. – № 1. – С. 4–10.
4. Савина С. В. Анализ использования нейронных сетей в цифровой экономике // Самоуправление. – 2023. – 5 (138). – С. 214–217.
5. Семенова Э. А., Цепкова С. М. Нейронные сети как финансовый инструмент // Информатика. Экономика. Управление. – 2022. – Т. 1, № 2. – С. 168–175.
6. Троценко К. Д. Применение нейросетей в прогнозировании экономических процессов // Обществознание и социальная психология. – 2023. – 9–3 (39). – С. 85–89.
7. Barthélémy S., Gautier V. Early warning system for currency crises using long short-term memory and gated recurrent unit neural networks // Journal of Forecasting. – 2023. – No. 45. – P. 12–19.
8. Singh L., Paul S. Hybrid evolutionary network architecture search (HyENAS) for convolution class of deep neural networks with applications // Expert Systems. – 2021. – Vol. 40, issue 4. – P. 87–93.
9. Wang Z., Zhang Y. Recurrent spiking neural network with dynamic presynaptic currents based on backpropagation // International Journal of Intelligent Systems. – 2021. – Vol. 37, issue 3. – P. 139–145.
10. Xu C., Zhang W. Further investigation on bifurcation and their control of fractional-order bidirectional associative memory neural networks involving four neurons and multiple delays // Mathematical Methods in the Applied Sciences. – 2021. – Vol. 46, issue 3. – P. 56–63.