

## ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ОЦЕНКИ ТРАЕКТОРИИ РАЗВИТИЯ ФИНАНСОВЫХ РЫНКОВ

**Савостьянов А. В., Гринева Н.В.**

*Финансовый университет при Правительстве Российской Федерации, Москва, Россия*  
s.aleks-02@mail.ru, ngrineva@fa.ru

**Строева Е.Н.**

*Московский государственный университет имени М.В. Ломоносова, Москва, Россия*  
katestroeva@gmail.com

*Аннотация. В работе исследуется возможность применения нескольких различных архитектур искусственных нейронных сетей для построения прогноза значений финансовых показателей для группы стран. Анализ проводился на основе данных, собранных из баз данных всемирного банка, индекса финансового развития и ООН.*

*Ключевые слова: финансовые рынки, финансовые показатели, прогнозирование, искусственные нейронные сети.*

### Введение

Финансовые рынки являются сложной системой, постоянно меняющейся во времени. Предсказание возможных изменений в будущем позволяет принимать верные решения инвесторам, трейдерам, банкирам и другим участникам рынка и уменьшить инвестиционные риски.

Финансовые рынки оказывают значительное влияние на экономический рост, занятость и благосостояние населения, поэтому оценка траектории их развития является важной задачей для экономики в целом.

В последнее время активными темпами развиваются искусственные нейронные сети, предоставляющие широкие возможности для обработки больших объемов данных и выявления скрытых закономерностей, которые могут быть полезны для прогнозирования траектории развития финансовых рынков.

### 1. Подходы к решению задачи прогнозирования поведения финансовых рынков

Задача оценки изменения и предсказания значений финансовых показателей в будущем является актуальной на протяжении последних десятилетий. В статье [1] 2015 года на основе регрессивного анализа исследуются взаимосвязи между прямыми иностранными инвестициями и развитием финансового рынка. В процессе исследования автор анализирует такие показатели как: отношение ПИИ (прямых иностранных инвестиций) к ВВП, отношение капитализации фондового рынка к ВВП, отношение оборота рынка акций к ВВП, отношения частного кредитования банками с денежными депозитами и другими финансовыми учреждениями к ВВП, отношение ликвидных обязательств финансовой системы к ВВП. В результате автор пришел к выводу, что указанные показатели в полной мере могут описывать степень развития финансовых рынков. Исследование этих показателей стало основой при решении поставленной задачи.

За последние десять лет развитие искусственных нейронных сетей получило широкое применение. Стал более интенсивным процесс построения различных архитектур, применения их к широкому кругу задач из всех жизненных сфер. Экономисты также начали применять новые технологии стали использоваться и для анализа финансовых показателей.

В 2021 году было проведено успешное исследование [2] по применению одного из типов рекуррентной искусственной нейронной сети — сети долгой краткосрочной памяти (Long short-term memory, далее LSTM) [3] к прогнозированию индекса Доу-Джонса. В 2022 году — построена нейронная сеть для опционов типа «пут» и «колл» [4].

В статье [5] для предсказаний развития финансовых рынков используют уже хорошо зарекомендовавшие себя методы машинного обучения, а именно — метод ближайшего соседа (Nearest-neighbour) [6], метод опорных векторов (Support Vector Machines, далее SVM) [7] и глубокие сети прямого распространения (Deep Feedforward Network): многослойный перцептрон (Multi layer Perceptron, MLP) [8] и сверточную искусственную нейронную сеть (Convolutional Neural Network, далее CNN) [9]. Авторы также делают вывод о возможности моделей машинного обучения извлекать более информативные признаки, чем традиционные показатели.

В работе [10] отмечается, что предсказанный при помощи искусственной нейронной сети типа LSTM тренд цен на акции почти полностью (с относительно небольшой погрешностью) соответствует реальному характеру поведения фондового рынка. Авторы также обращают внимание на проблему

широкого диапазона колебания реальных цен, но построенная искусственная нейронная сеть хорошо обрабатывает большие объемы информации и показывает свою надежность при прогнозировании цен на акции даже с учетом различных мутаций.

С учетом полученных результатов нами была выдвинута гипотеза о возможности предсказания значений финансовых показателей в будущем с использованием искусственных нейронных сетей. Для экспериментов нами были выбраны две архитектуры нейронных сетей — LSTM и 6-слойная сеть прямого распространения (Deep Neural Network, далее DNN).

## 2. Архитектура используемых искусственных нейронных сетей

### 2.1. Deep Neural Network

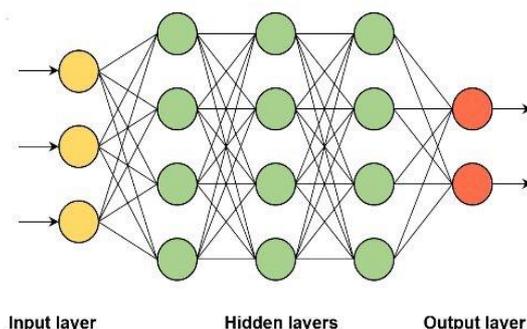


Рис. 1. Архитектура искусственной нейронной сети прямого распространения

Принцип работы сети DNN [8]:

- на вход поступают данные  $x_i$  в векторном виде (Input layer на рис.1 представлен желтым цветом);
- каждому ребру, соединяющему нейроны соседних слоев, присвоен свой вес  $W_i$ ;
- на вход скрытому слою (Hidden layers на рис.1 представлен зеленым цветом) поступает взвешенная сумма входных данных, перемноженных на веса,  $x_1W_1 + \dots + x_nW_n = \sum_i^n x_iW_i$ ;
- к полученной взвешенной сумме добавляется число  $b_i$ , которое позволяет сделать сдвиг (bias-вектор);
- выражение  $y = \sum_i^n x_iW_i + b_i$  подается на вход функции активации, которая принимает решение об «активации нейрона». Самой распространенной функцией активации (которую мы также используем в своём эксперименте) является  $ReLU(y) = \max(0, y)$  [11], передающая дальше все положительные значения полученной суммы;
- после проведения подобных вычислений на каждом нейроне сети получается выходное значение  $y_{output}$  (Output layer на рис.1 представлен красным цветом);
- строится функция потерь, показывающая отличие полученного значения  $y_{output}$  от заданного  $y_{data}$  в наборе данных;
- методом градиентного спуска в сочетании с алгоритмом обратного распространения ошибки подбираются оптимальные веса  $W_i$  и говорят, что «сеть обучилась».

Для решения задачи была выбрана архитектура искусственной нейронной сети, состоящая из входного слоя, 6 скрытых слоев и выходного слоя.

### 2.2. Long short-term memory neural network

Одним из типов рекуррентных искусственных нейронных сетей являются сети с долгой краткосрочной памятью (Long short-term memory, LSTM). Они сконструированы так, чтобы иметь способность «запоминать информацию» на довольно длительный период. Такие сети хорошо справляются с задачами распознавания речи, генерации текста, распознавания изображений и других задач, для решения которых необходимо пользоваться большим количеством данных, учитывая предыдущие состояния.

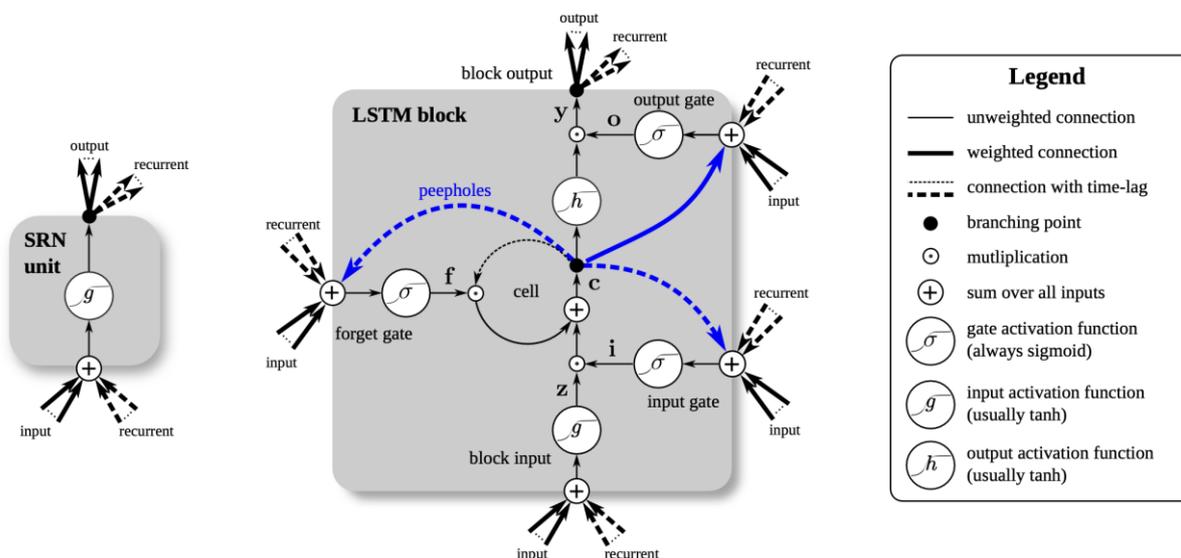


Рис. 2. Схема работы одной ячейки искусственной нейронной сети типа LSTM [3]

На рис. 2 представлено схематическое изображение одной ячейки памяти искусственной нейронной сети типа LSTM и показаны взаимосвязи между ее составляющими.

Ключевой идеей является построение одной ячейки памяти (рис. 2), в которой содержится несколько блоков, ответственных за:

- принятие решения о том, какую часть входных данных не стоит пропускать дальше (block gate на рис. 2);
- осознание того, какую информацию необходимо обновить (input gate на рис. 2);
- принятие решения о том, какую часть входных данных необходимо забыть на данном этапе (forget gate на рис. 2);
- состояние ячейки (cell на рис. 2) — принимает решение о том, какую часть информации следует пропустить дальше;
- принятие решения о том, какую информацию необходимо получить на выходе (output gate на рис. 2). Решение принимается по состоянию ячейки (cell) и применении некоторых фильтров.

### 3. Проверяемая гипотеза и методика исследования

Основной идеей, заложенной в настоящей статье, является проверка возможности применения моделей искусственных нейронных сетей для качественного прогнозирования данных.

В качестве объекта исследования рассматриваются финансовые показатели стран из Североатлантического альянса. Предметом исследования являются системный анализ, линейная регрессия и искусственные нейронные сети.

Целью работы является моделирование значений рассматриваемых показателей в будущем при помощи двух типов искусственных нейронных сетей.

Методика исследования заключается в проведении следующих этапов:

- анализ и подготовка данных:

- обзор источников для получения данных с учетом их глубины и возможности доступа;
- выявление списка экономических показателей для каждой страны;
- разбиение данных на тренировочную и тестовую часть с учетом хронологии событий;
- анализ моделей искусственных нейронных сетей:
- обзор библиотек для программирования на языке Python;
- разработка подходящих к задаче архитектур искусственных нейронных сетей;
- сравнение полученных результатов.

#### 4. Набор данных и его подготовка для подачи на вход искусственным нейронным сетям

Для составления набора данных были использованы четыре источника: база данных Всемирного банка «The World Development Indicators» (далее WDI) [12], база данных индексов финансового развития (Financial Development Index Database, далее FDID) [13], глобальная база данных по финансовому развитию (Global Financial Development Database, далее GFDD) [14], база данных ООН «Индекс Человеческого Развития» (Human Development Index, далее HDI) [15].

В качестве материала для анализа были взяты экономические показатели, для следующих стран: Австрия, Германия, Греция, Испания, США. Для указанных стран данные содержат наименьшее количество пропусков. Список показателей представлен в Таблице 1.

Таблица 1. Список экономических показателей для каждой страны

GFDD.DI.12	Отношение кредитов к ВВП
GFDD.DI.02	Отношение активов банков к ВВП
GFDD.DM.01	Отношение капитализации рынка акций к ВВП
GFDD.DM.02	Отношение оборота рынка акций к ВВП
GFDD.DM.13	Отношение оборота размещений корпоративных облигаций к ВВП
GFDD.EM.01	Отношение оборота рынка акций к капитализации рынка акций
NV.AGR.TOTL.ZS	Отношение добавленной стоимости в СХ секторе и в промышленности к ВВП
NV.SRV.TOTL.ZS	Отношение добавленной стоимости в секторе услуг к ВВП
IP.PAT.RESD	Количество патентных заявок
IP.JRN.ARTC.SC	Количество статей в научно-технических журналах
NY.GDP.PCAP.KD	ВВП на душу населения

В качестве временного промежутка были выбраны данные с 2001 года по 2020 год. Для построения модели были выбраны данные по 2018 год, а последующие использовались для верификации модельных данных с фактическими.

На рис. 3 представлены некоторые графики временных рядов по выбранным странам по таким показателям, как: ВВП на душу населения, отношение кредитов к ВВП, отношение оборота рынка акций к ВВП, отношение оборота рынка акций к капитализации рынка акций.

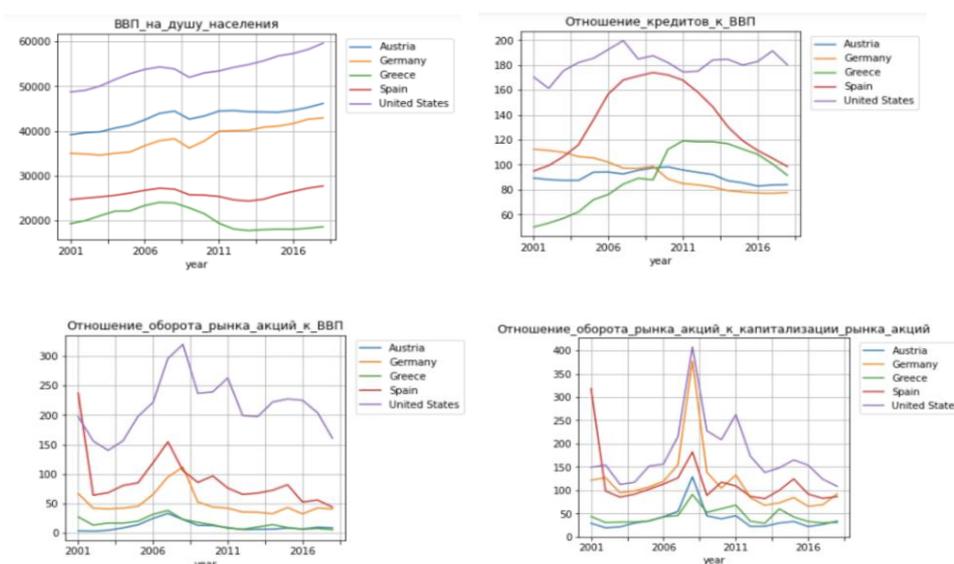


Рис. 3. Графическое представление значений выбранных показателей

Для обработки данных при помощи искусственных нейронных сетей необходимо удалить все пустые значения, иначе модель не сможет обучиться. Было установлено, что среди данных для выбранных показателей были пропуски в следующих столбцах: отношение оборота акций к ВВП, отношение оборота размещений корпоративных облигаций к ВВП, отношение оборота рынка акций к капитализации рынка акций и количество статей в научно-технических журналах.

Решение проблемы заполнения пропусков было осуществлено при помощи метода приближения линейной регрессии, которая была построена на основе данных, находящихся до пустого значения. Выбор был сделан в пользу линейной регрессии поскольку заполнение средним значением или модой может вызвать появление одинаковых показателей на протяжении нескольких лет, что маловероятно, учитывая большое количество кризисных ситуаций за последние годы.

Следующим вопросом в подготовке данных для эксперимента стала необходимость масштабирования данных. Для этого построены графики показателей, представленные на рис. 3, поскольку такой способ визуализации позволяет лучше понять тенденции.

Анализ представленных графиков позволяет сделать вывод, что кризис 2008 года был ключевым моментом за период с 2001 год по 2020 год. Он существенно повлиял на финансовые показатели стран, например, отношение капитализации рынка акций к ВВП у всех стран просело в 2 раза, и только у США в 2013 году получилось выйти на показатели до 2008 года, а также улучшить их. Только у Австрии и США отношение активов банков к ВВП осталось стабильным в то время, как в других странах мы видим отрицательную динамику после 2008 года. Больше всего кризис 2008 года сказался на экономике Греции, отношение добавленной стоимости в СХ секторе и промышленности к ВВП растет, однако и оно не восстановилось до своих предкризисных значений, а отношение добавленной стоимости в секторе услуг к ВВП упало незначительно. Это подтверждает тот факт, что Греция в основном является страной, которая живет за счет туризма и своей сельскохозяйственной промышленности.

Анализ показал, что в периоды кризисов показатели могут как расти, так и падать на 50% и более. И поэтому необходимо произвести масштабирование данных для избежания проблем при обучении моделей искусственных нейронных сетей. Был применен метод MinMaxScaler (-1, 1), где -1 соответствует минимальному значению, а 1 — максимальному значению. Указанный метод масштабирует данные с сохранением распределения, а также позволяет ускорить сходимость значений при использовании градиентного спуска в модели нейронной сети.

## 5. Построение моделей искусственных нейронных сетей

Для цели исследования выбраны два типа искусственных нейронных сетей: DNN и LSTM. Архитектура DNN — простая и широко используемая архитектура, которая может быть использована для прогнозирования финансовых показателей. LSTM — это архитектура, которая позволяет учитывать предыдущие значения временных рядов, что может быть особенно полезно при работе с финансовыми данными. Отдельно подчеркнем, что при выборе архитектуры искусственной нейронной сети всегда необходимо основываться на том, какого типа данные будут подаваться ей на вход. В этом случае работа была проведена с панельными данными, которые лучше всего обрабатывают рекуррентные нейронные сети.

Для оценки качества моделей использованы метрики:

- Mean Squared Error:  $MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$ ;
- Mean Average Error:  $MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$ ;
- Mean Absolute Percentage Error:  $MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{e_t}{\hat{y}_t} \right|$ ,

где  $e_t = y_t - \hat{y}_t$ ,  $y_t$  — заданное значение,  $\hat{y}_t$  — прогноз,  $n$  — количество наблюдений.

Указанные метрики выбраны на основании их линейного представления, которые наиболее просто и понятно интерпретируются. Это позволяет использовать их для сравнения результатов разных моделей и для оценки качества моделей искусственных нейронных сетей в различных сценариях. В частности, MSE применяется во время построения модели как метрика, которая вычисляет ошибку между реальными данными и предсказанными показателями для их дальнейшей корректировки на следующей итерации.

Искусственная нейронная сеть LSTM была представлена архитектурой: 6 слоёв LSTM, каждый из которых содержит 256 скрытых блоков. Кроме того, использовался линейный слой (fc), который принимает выходные данные из скрытого слоя и возвращает один выход. Модель обучалась на 300 эпохах с использованием оптимизатора Adam и функции потерь MSE.

На рис. 4 представлены графики реальных данных (синяя линия), обучающие данные (зеленая линия) и предсказания LSTM, основанные на тестовых данных (оранжевая линия) по следующим показателям: отношение капитализации рынка акций к ВВП, отношение кредитов к ВВП, отношение оборота размещений корпоративных облигаций к ВВП, отношение оборота рынка акций к ВВП.

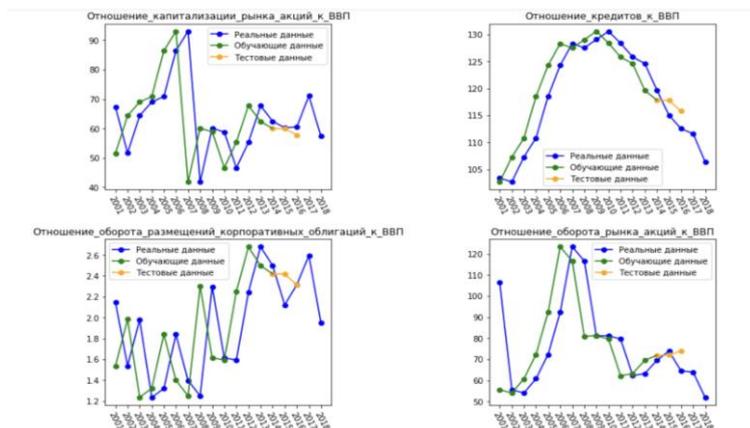


Рис. 4. Графическое представление сравнения предсказанных значений LSTM с реальными усредненными данными по всем странам для каждого показателя по каждому году

Анализ показывает, что модель LSTM рекуррентной искусственной нейронной сети успешно справилась с поставленной задачей, в большинстве случаев движения прогнозов, основанных на тестовых данных, совпадают с движением реальных данных. Кроме того, в результате обучения были получены значения MAPE = 0.6065 и MAE = 0.2275, которые свидетельствуют о том, что у модели средняя ошибка прогнозирования составляет 60.65% от фактического значения, а средняя абсолютная ошибка прогнозирования составляет 0.2275 единицы в измеряемых единицах, что является неплохим результатом с учетом количества обучающих данных.

DNN для эксперимента представлена 6 полносвязными слоями, включая один входной слой, четыре скрытых слоя и один выходной слой. Скрытые слои имеют размерности 128, 256, 512, 128 нейронов соответственно. Функция активации — ReLU.

На рис. 5 представлены графики тренировочных данных (синяя линия), обучающие тестовые данные (зеленая линия) и предсказания DNN, основанные на тестовых данных (оранжевая линия).

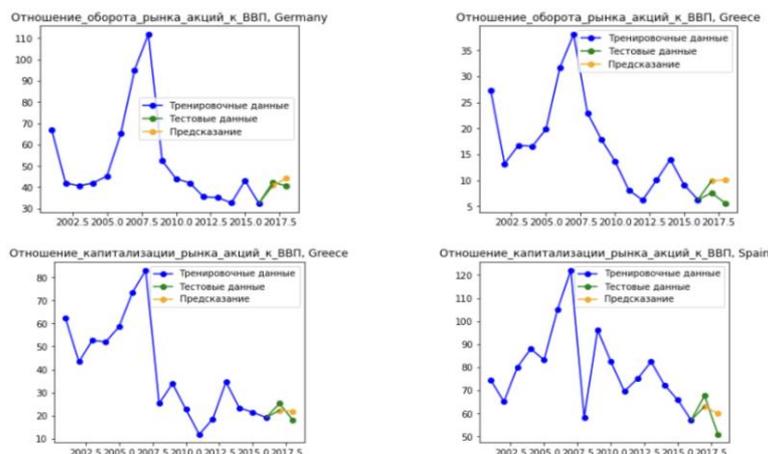


Рис. 5. Графическое представление сравнения предсказанных значений DNN с реальными усредненными данными по всем странам для каждого показателя по каждому году

Большинство полученных прогнозов имеют схожую динамику с реальными данными. В особенности важно подчеркнуть тот факт, что отношение кредитов к ВВП практически во всех странах растет. Нельзя сказать, что это хорошая динамика, поскольку в кризисные времена страны, у которых высокий показатель кредитов к ВВП, могут испытать еще большее давление вплоть до дефолта. Кроме того, во всех странах растет отношение активов банков к ВВП, а значит банки укрепляют свои позиции по отношению к финансовым рынкам, поскольку последние имеют большую волатильность в кризисные времена, и полагаться только на них опасно для экономики страны. Модель предсказывает падение капитализации рынка акций. Этот прогноз верен, поскольку в 2020 году рынок акций сильно просел на фоне пандемии Covid-19.

Таким образом, модель хорошо формирует прогнозы по многим показателям в указанном периоде, а также выявляет верные тренды для остальных показателей, учитывая события, которые начались в 2022 году и продолжаются в настоящее время.

## 5. Заключение

Применение моделей искусственных нейронных сетей типа LSTM и DNN позволяют получить адекватный прогноз, который во многом повторяет те же тенденции траектории развития финансовых показателей, как и реальные данные. Построенные архитектуры позволяют выявить правильные тенденции относительно будущих событий на мировых финансовых рынках. Было установлено, что далеко не все страны готовы к новым кризисам, как например кризис 2020 года.

Работа имеет практическую значимость и результаты ее могут стать основой для прогнозирования временных рядов финансовых показателей с использованием построенных архитектур искусственных нейронных сетей. Представленные модели также могут быть применены министерствами, ведомствами, банковскими структурами для минимизации рисков в экономике в случае возникновения возможных кризисных ситуаций.

## Литература

1. *Issouf Soumare, Fulbert Tchana Tchana* Causality between FDI and Financial Market Development: Evidence from Emerging Markets // *The World Bank Economic Review*. – 2015. – Vol. 29. – P. S205–S216.
2. *Qi Tang, Tongmei Fan, Ruchen Shi* Prediction of financial time series using LSTM and data denoising methods // *Arxiv*. – 2021.
3. *Klaus Greff, Rupesh K. Srivastava, Jan Koutnik, Bas R. Steunebrink, Jurgen Schmidhuber* LSTM: A Search Space Odyssey // *Institute of Electrical and Electronics Engineers (IEEE)*. – 2017. – Vol. 28. – N 10. – P. 2222-2232.
4. *Гринева Н.В.* Построение нейронной сети для прогнозирования цены опциона // *Проблемы экономики и юридической практики*. – 2022. – Vol. 18. – N 5. – P. 190-199.
5. *Jia Wang, Tong Sun, Benyuan Liu, Yu Cao, Degang Wang* Financial Markets Prediction with Deep Learning // *IEEE*. – 2021. – Vol. 12.
6. *Padraig Cunningham, Sarah Jane Delany* k-Nearest neighbour classifiers // *ACM Computing Surveys*. – 2007. – Vol. 54. – N 6.
7. *Theodoros Evgeniou, Massimiliano Pontil* Support Vector Machines: Theory and Applications // *Conference: Machine Learning and Its Applications, Advanced Lectures*. – 2001.
8. *Marius-Constantin Popescu, Valentina Emilia Balas, Liliana Perescu-Popescu, Nikos E Mastorakis* Multilayer perceptron and neural networks // *WSEAS Transactions on Circuits and Systems*. – 2009. – Vol. 8. – N 7.
9. *Keiron O'Shea and Ryan Nash* An Introduction to Convolutional Neural Networks // *Arxiv*. – 2015.
10. *Weidong Xu* Stock Price Prediction based on CNN-LSTM Model in the PyTorch Environment // *Proceedings of the 2022 2nd International Conference on Economic Development and Business Culture (ICEDBC 2022)*. – 2022. – P. 1272-1276.
11. *Xavier Glorot, Antoine Bordes, Yoshua Bengio* Deep Sparse Rectifier Neural Networks // *Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, PMLR*. – 2011. – Vol. 15. – P. 315-323.
12. The World Development Indicators [Электронный ресурс], URL: <https://datacatalog.worldbank.org/search/dataset/0037712/World-Development-Indicators>.
13. Financial Development Index Database [Электронный ресурс], URL: <https://data.imf.org/?sk=388dfa60-1d26-4ade-b505-a05a558d9a42>.
14. Global Financial Development Database [Электронный ресурс], URL: <https://www.worldbank.org/en/publication/gfdr/data/global-financial-development-database>.
15. Human Development Reports: [Электронный ресурс], URL: <https://hdr.undp.org/data-center/documentation-and-downloads>.