

УДК 330.43+ 336.67

UDC 330.43+ 336.67

5.2.2. Математические, статистические и инструментальные методы экономики (физико-математические науки, экономические науки)

5.2.2. Mathematical, statistical and instrumental methods of economics (physical and mathematical sciences, economic sciences)

**МЕТОДИКА ПОДГОТОВКИ ОБУЧАЮЩЕЙ ВЫБОРКИ ДЛЯ ПОВЫШЕНИЯ КАЧЕСТВА ПРОГНОЗОВ ЦЕН АКЦИЙ В ЗАДАЧАХ МАШИННОГО ОБУЧЕНИЯ**

**METHODOLOGY OF TRAINING SAMPLE PREPARATION FOR IMPROVING THE QUALITY OF STOCK PRICE FORECASTS IN MACHINE LEARNING TASKS**

Кесиян Грант Арутович  
доцент кафедры анализа данных и искусственного интеллекта  
SPIN (РИНЦ) 5411-3913 (773389)  
Researcher ID (Web of Science) - JZD-3924-2024  
ORCID: 0009-0001-1635-110X  
[grant.kesiyan@mail.ru](mailto:grant.kesiyan@mail.ru)  
ФГБОУ ВО «Кубанский Государственный Университет», Краснодар, Россия

Kesiyan Grant Arutovich  
Associate Professor of the Departments of Data Analysis and Artificial Intelligence  
SPIN (RSCI) 5411-3913 (773389)  
Researcher ID (Web of Science) - JZD-3924-2024  
ORCID: 0009-0001-1635-110X  
[grant.kesiyan@mail.ru](mailto:grant.kesiyan@mail.ru)  
Kuban State University, Krasnodar, Russia

Ласкин Михаил Борисович  
доктор экономических наук  
SPIN (РИНЦ): 3457-6998 (917848)  
Researcher ID (Web of Science) U-4427-2018  
Scopus ID: 57189848894  
ORCID: 0000-0002-0143-4164  
[laskin.m@iias.spb.su](mailto:laskin.m@iias.spb.su)  
Санкт-Петербургский ФИЦ РАН,  
ФГБОУ ВО «Санкт-Петербургский государственный университет», Санкт-Петербург, Россия

Laskin Mikhail Borisovich  
Dr.Sci.Econ.  
SPIN (RSCI): 3457-6998 (917848)  
Researcher ID (Web of Science) U-4427-2018  
Scopus ID: 57189848894  
ORCID: 0000-0002-0143-4164  
[laskin.m@iias.spb.su](mailto:laskin.m@iias.spb.su)  
St.Petersburg FRC RAS,  
St.Petersburg University,  
St.Petersburg, Russia

В статье предложена методика и модель построения прогноза движения цен на рынках ценных бумаг. Предложенная модель является алгоритмом машинного обучения, в частности, нейронной сетью с прямой связью и последовательным соединением (многослойный перцептрон). Новым является оптимизация гиперпараметров модели и анализ влияния резких возмущений на рынке на качество прогнозов. Модель и методика дают хорошие результаты прогнозирования в краткосрочном периоде. Модель хорошо справляется с изменениями на рынках, обусловленных быстро нарастающими внешними возмущениями. Модель также адекватно реагирует на мгновенные внешние возмущения и, хотя и теряет в точности, но правильно прогнозирует направления формирующихся трендов в начале их зарождения

The article proposes a methodology and model for constructing a forecast of price movements in securities markets. The proposed model is a machine learning algorithm, in particular, a neural network with a direct connection and a serial connection (multilayer perceptron). The optimisation of hyperparameters of the model and analysis of the influence of sharp perturbations in the market on the quality of forecasts, are new. The model and methodology provide good forecasting results in the short term. The model copes well with changes in the markets caused by rapidly growing external disturbances. The model also adequately responds to instantaneous external disturbances and, although it loses in accuracy, it correctly predicts the directions of emerging trends at the beginning of their emergence

Ключевые слова: МАШИННОЕ ОБУЧЕНИЕ, ФРАКТАЛЬНЫЙ АНАЛИЗ, ОБУЧАЮЩАЯ ВЫБОРКА, САМОПОДОБИЕ

Keywords: MACHINE LEARNING, FRACTAL ANALYSIS, TRAINING SAMPLE, SELF-SIMILARITY

<http://dx.doi.org/10.21515/1990-4665-204-062>

<http://ej.kubagro.ru/2024/10/pdf/62.pdf>

## **Введение**

Задачи прогнозирования временных изменений фондовых индексов, рыночной стоимости ценных бумаг (акций, облигаций и др.) по-прежнему привлекают внимание участников рынка, трейдеров и аналитиков. Несмотря на значительное количество опубликованных и применяемых прогнозных методик, продолжается активный поиск новых подходов и методов построения таких моделей, включая алгоритмы и методы машинного обучения. В настоящей статье развивается методика, описанная в [1, с. 68], которая позволяет строить прогнозы рыночной стоимости ценных бумаг, основанная на:

- фрактальном характере временных рядов рынка ценных бумаг и других финансовых инструментов;
- методах машинного обучения.

В качестве модели для машинного обучения выбрана простейшая модель нейронной сети – многослойный персептрон. Несмотря на появление новых моделей различных нейронных сетей, многослойный персептрон по-прежнему является популярным, часто применяется в задачах прогнозирования, в том числе в сочетании с другими моделями и подходами [2-7].

Мы рассматриваем динамику цен акций фондового рынка Российской Федерации как динамическую систему с фрактальными свойствами, что позволяет оценить некоторые характеристики временных рядов для получения обучающей выборки в нейросетевой модели с целью повышения качества прогнозов. Аналогичный подход, развивающий методы нейросетевого прогнозирования временных рядов с предварительной подготовкой данных, рассмотрен в работе [8].

### Формирование обучающей выборки

Пусть имеется одномерный временной ряд  $\{x(t)\}$ ,  $t \in [0, T]$  с дискретным временем. По теореме Ф. Такенса [9] любое гладкое отображение  $n$ -мерного пространства  $V_1$  в  $m$ -мерное пространство  $V_2$  будет задавать вложение компактного подмножества  $U \subseteq V_1$  в пространство  $V_2$  при условии, что  $m > 2 \cdot D_U + 1$ , где  $D_U$  – фрактальная размерность множества  $U$ .

Пусть временной ряд  $\{x(t)\}$ ,  $t \in [0, T]$  имеет параметр Харста  $H > 0,5$ . Такой ряд является персистентным, обладает самоподобием и автомодельностью (см. [10]).

Построим оценку  $\hat{m}$  размерности пространства вложения  $m$  и оценку  $\hat{\tau}$  временной задержки  $\tau$ , и получим набор точек из пространства  $R^{\hat{m}}$  траекторий системы по следующей формуле:

$$[x(t), x(t - \hat{\tau}), x(t - 2 \cdot \hat{\tau}), \dots, x(t - (\hat{m} - 1) \cdot \hat{\tau})], \quad \text{где } t \in [(\hat{m} - 1) \cdot \hat{\tau} + 1, T]$$

Оценки параметров  $\hat{\tau}$  и  $\hat{m}$  необходимы для выбора параметров модели.

Обучение модели производится с помощью метода скользящего окна. Для этого ищем модель  $f_k$ , для которой выполняется

$$x(t + k \cdot \hat{\tau}) \approx f_k(x(t + \hat{\tau}), x(t + 2 \cdot \hat{\tau}), \dots, x(t + (k - 1) \cdot \hat{\tau}), \hat{\tau})$$

где  $k$  – размер окна,  $t \in [1, T - k \cdot \hat{\tau}]$  и минимизирующую среднеквадратическое отклонение ошибки. Нижнюю границу параметра  $k$  выбираем в соответствии с неравенством  $k \geq \hat{m} - 1$  (см. [11, с. 63]).

В результате получаем многомерный временной ряд, из которого и состоит обучающая выборка, и, таким образом, в алгоритмах обучения будут учтены оценки характеристик динамической системы.

### Построение прогноза

Предположим, что модель  $f_k$  прошла этап обучения с помощью метода скользящего окна. Для построения прогноза рассматривается следующий алгоритм.

Для каждого значения из горизонта прогнозирования  $d \in \{1, \dots, D\}$ :

– формируем вектор по размеру окна  $k$  из предыдущих значений с задержкой  $\hat{t}$ :

$$[x(T + d - \hat{t}), x(T + d - 2 \cdot \hat{t}), \dots, x(T + d - k \cdot \hat{t})]$$

– получаем прогнозное значение по обученной модели  $f_k$ :

$$x(T + d) \approx f_k(x(T + d - \hat{t}), x(T + d - 2 \cdot \hat{t}), \dots, x(T + d - k \cdot \hat{t}), d).$$

– на каждой итерации прогнозное значение становится частью данных и используется как входное значение для последующих прогнозов.

### Условия проведения численных экспериментов

Обучающая выборка формируется из исходного ряда данных по принципу скользящего окна с параметрами  $k \geq \hat{m} + 1$  и  $\hat{t}$ .

Оценка  $\hat{m}$  рассчитывается по формуле  $\hat{m} = 2 \cdot [\hat{d}] + 1$ , где  $[\hat{d}]$  – оценка фрактальной размерности,  $[\cdot]$  – целая часть.

Оценка  $\hat{t}$  строится с помощью метода взаимной информации [9, стр. 49].

Для определения  $\hat{d}$  используем алгоритм Грассберга-Прокаччия, позволяющий вычислить корреляционную размерность [11, с. 52], как оценку фрактальной размерности.

Исходная выборка делится на обучающую (*train*) и тестовую (*test*). Тестовая выборка используется для проверки качества модели с метрикой среднеквадратичное отклонение.

В качестве семейства моделей использовалась нейронная сеть с прямой связью с последовательным соединением, или многослойный

персептрон (Multilayered Perceptron). Архитектура модели содержит четыре слоя:

- входной слой размерностью  $k$ ;
- первый скрытый слой;
- второй скрытый слой;
- выходной слой размерностью 1 и линейной функцией активации.

Для скрытых слоев количество нейронов и функции активации подбираются экспериментально и среди возможных моделей отбирается лучшая.

В качестве функции потерь (*loss function*) и метрики качества выбрана среднеквадратичная ошибка (*Mean Squared Error*).

В качестве метода обучения нашей модели выбран метод *Adam* (*adaptive moment estimation*), описанный в работе [12].

Настройки модели.

Параметр *batch\_size* равен 32 – это параметр, который определяет количество образцов для обновления градиента.

Максимальное значение *epochs* (количество итераций по всем данным в процессе обучения) равно 300. В процессе обучения алгоритм может остановиться раньше, если среднеквадратическая ошибка обучения перестанет уменьшаться.

Горизонт прогнозирования  $D$  выбирается в зависимости от целей эксперимента.

### **Численные эксперименты**

В качестве исходных данных выбран временной ряд: цена закрытия в рублях обычных акций Сбербанка России за период с 1 января 2015 г. по 3 октября 2024 г. с интервалом 1 день.

Оценки  $\hat{m}$  и  $\hat{t}$  получены с помощью программного продукта *Fractan 4.4*, разработанного в институте математических проблем биологии

(ИМПБ РАН). Получены следующие результаты:  $\hat{d} = 2,753$ ,  $\hat{\tau} = 18$ . Тогда  $\hat{m} = 2 \cdot \lceil 2,753 \rceil + 1 = 5$  и параметр скользящего окна  $k = \hat{m} + 1 = 6$ .

Таким образом, исходный одномерный ряд преобразуется в шестимерный с временной задержкой равной 18. Горизонт прогнозирования выбран  $D=100$  (дней).

Рассматривались модели с двумя скрытыми слоями, с количеством нейронов по 50,75,100,150 и тремя возможными функциями активации *silu*, *relu*, *sigmoid*. Общее количество рассмотренных моделей  $(4 \cdot 3)^2 = 144$ .

Здесь:

- $relu(x)=\max(0, x)$  – функция активации *ReLU* (*rectified linear unit*),
- $sigmoid(x)=1 / (1 + \exp(-x))$  – сигмоидальная функция,
- $silu(x)=swish(x) = x * sigmoid(x)$  – функция активации *Silu* (или *Swish*).

Для подбора лучшей комбинаций гиперпараметров скрытых слоев написан алгоритм, позволяющий выбрать модель с минимальным среднеквадратическим отклонением прогноза. Лучшей (с минимальной среднеквадратической ошибкой оказалась следующая модель:

- первый скрытый слой: количество нейронов 75, функция активации *relu*;
- второй скрытый слой: количество нейронов 150, функция активации *relu*.

Результат показан на рисунке 1.

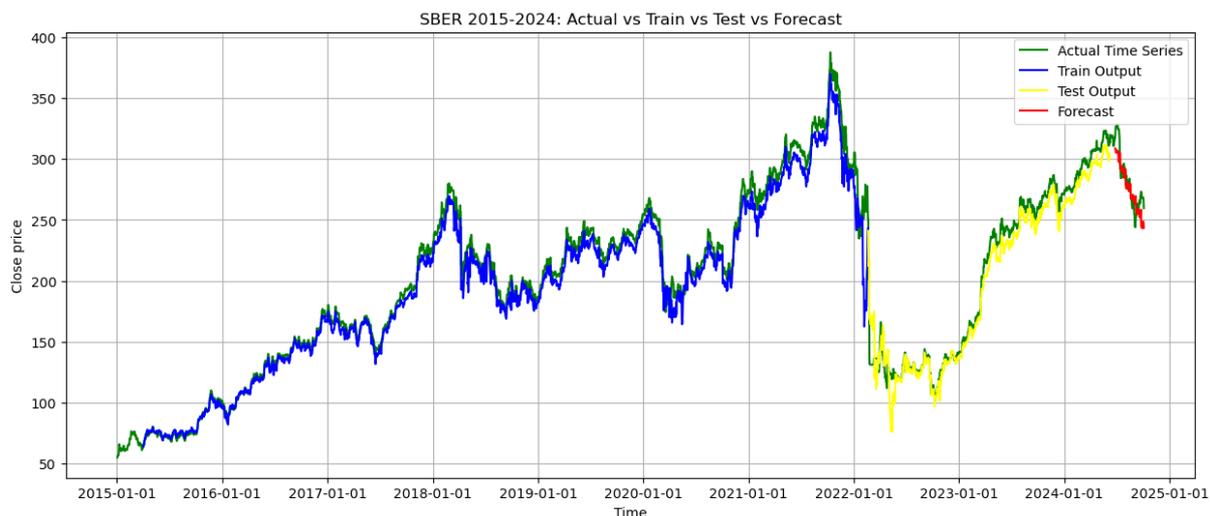


Рисунок 1. Прогноз цены закрытия обыкновенных акций Сбербанка на 100 дней. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели  $MSE=170.6$ , стандартное отклонение  $RSE=13.06$ . Полученный результат позволяет надеяться, что при прогнозировании исследуемого ряда на 100 дней вперед, по подобранной модели нейронной сети и соответствующей обучающей выборке, коридор 95%-ной надежности составляет +/- 8-10%.

### **Поведение модели при аномальных скачках временного ряда**

Текущая рыночная ситуация характеризуется высокими рисками внешних непрогнозируемых возмущений. Посмотрим, как построенная модель реагирует на резкие внешние возмущения, вызванные неожиданными макроэкономическими изменениями. В новейшем периоде таких возмущений, оказавших существенное влияние на финансовые и фондовые рынки было два: в начале 2020 года, и в начале 2022 года.

Модель остается прежней: первый скрытый слой – 75 нейронов, второй -150 нейронов, функции активации – *relu*.

Скачок, относящийся к началу 2020 года, сформировался под быстро нарастающим влиянием изменений в экономике, вызванных эпидемией Covid-19. Для оценки чувствительности к скачку в 2020 г. разделим выборку с 01.01.2015 по 01.06.2020 г. на 3 части:

- обучающая выборка – до 01.01.2019 г.
- тестовая выборка – до 01.0.2020 г.
- выборка для проверки прогноза – до 01.06.2020 г. (прогноз на

$D=153$  (дня) с 01.01.2020 г.). Результат показан на рисунке 2.



Рисунок 2. Прогноз цены закрытия обыкновенных акций Сбербанка на 153 дня в момент скачка в начале 2020 года. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели,  $MSE=450.3$ , стандартное отклонение  $RSE=21.2$ . Полученный результат позволяет надеяться, что при прогнозировании исследуемого ряда на 153 дня вперед, по подобранной модели нейронной сети и соответствующей обучающей выборке коридор 95%-ной надежности составляет +/- 17 - 21%. Риск увеличился, однако модель верно

предсказала направление изменившегося тренда и глубину снижения цен на период до 153 дней.

Сдвинем обучающую, тестовую выборки и период прогнозирования на 1 и 2 квартала вперед, так, чтобы обучающая выборка захватила начало восходящего тренда. Результаты показаны на рисунке 3 (сдвиг на 1 квартал) и на рисунке 4 (сдвиг на два квартала).



Рисунок 3. Прогноз цены закрытия обыкновенных акций Сбербанка на 153 дня в момент начала разворота тренда в первом квартале 2020 года. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели  $MSE=259,7$ , стандартное отклонение  $RSE=16.1$ . Полученный результат позволяет надеяться, что при прогнозировании исследуемого ряда на 153 дня вперед, по подобранной модели нейронной сети и соответствующей обучающей выборке коридор 95%-ной надежности составляет +/- 13 - 16%. Риск, по сравнению с предыдущим рисунком, снизился, модель уверенно прогнозирует восходящий тренд на период до 153 дней.



Рисунок 4. Прогноз цены закрытия обыкновенных акций Сбербанка на 153 дня в момент сформировавшегося восходящего тренда во втором квартале 2020 года. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели  $MSE=190.4$ , стандартное отклонение  $RSE=13.8$ . Полученный результат позволяет надеяться, что при прогнозировании исследуемого ряда на 153 дня вперед, по подобранной модели нейронной сети и соответствующей обучающей выборке коридор 95%-ной надежности составляет  $\pm 11 - 14\%$ . Риск еще снизился, модель уверенно прогнозирует восходящий тренд на период до 153 дней.

Негативные события 2020 года нарастали быстро, но не мгновенно. Модель хорошо справилась с таким возмущением и позволяла бы в таких случаях формировать торговые стратегии. Напротив, события 2022 года были не ожидаемыми и мгновенно спровоцировали резкий скачок вниз.

Для оценки чувствительности к скачку в 2022 г. разделим выборку на следующие 3 части:

- обучающая выборка – до 01.01.2021 г.

- тестовая выборка – до 01.0.2022 г.
- выборка для проверки прогноза – до 01.01.2023 г. (прогноз на  $D=366$  дней с 01.01.2022 г.).

Результат показан на рисунке 5.



Рисунок 5. Прогноз цены закрытия обыкновенных акций Сбербанка на 366 дней в момент формирующегося нисходящего тренда к началу 2022 года. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели  $MSE=10499.0$ , стандартное отклонение  $RSE=102.5$ . Риск высокий, сопоставимый с порядком цены. Нисходящий тренд уже формировался в конце 2021 года и только был усилен внешним возмущающим фактором. В этом случае модель верно указывает нисходящий прогнозный тренд, но не может дать адекватный прогноз по глубине и скорости его снижения.

Сдвинем обучающую, тестовую выборки и период прогнозирования на 1 и 2 квартала вперед, так, чтобы обучающая выборка захватила момент

наибольшего падения наблюдаемых значений. Результаты показаны на рисунке 6 (сдвиг на 1 квартал) и на рисунке 7 (сдвиг на два квартала).



Рисунок 6. Прогноз цены закрытия обыкновенных акций Сбербанка на 366 дней в момент наибольшего падения цены в 2022 году. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели  $MSE=1215.8$ , стандартное отклонение  $RSE=34.9$ . Риск остается высоким, но уже не кажется таким большим, как в предыдущем случае. Модель по-прежнему уверенно указывает на восходящий тренд, хорошо оценивает прирост, но не в состоянии прогнозировать период низких цен, предшествующий восходящему тренду, который продолжался весь 2022 год.



Рисунок 7. Прогноз цены закрытия обыкновенных акций Сбербанка на 366 дней в период наибольшего снижения цены в середине 2022 года. Зеленый цвет – наблюдаемые значения цены закрытия, голубой цвет – обучающая выборка, желтый цвет – тестовая выборка, красный цвет – прогноз.

Среднеквадратическое отклонение, полученное при прогнозе по лучшей модели  $MSE=775.8$ , стандартное отклонение  $RSE=27.9$ . Риск снизился. Модель уверенно указывает на восходящий тренд, хорошо оценивает прирост, еще не достаточно точна, но уже позволяет вырабатывать торговые стратегии.

## Выводы

Основной новизной предложенной методики и модели является подготовка обучающей выборки, которая учитывает фрактальный характер временного ряда и его динамические характеристики.

Разработанная модель и соответствующая программа позволили довольно точно прогнозировать движение цены выбранного актива и позволяет строить торговые стратегии в краткосрочном периоде. Проведенные численные эксперименты показали, что модель адекватно реагирует на быстро нарастающие тенденции рынка, обусловленные внешними возмущающими факторами. В случае неожиданных, резких

внешних возмущений модель сохраняет способность верно прогнозировать направление тренда, в том числе в точках разворота, но теряет в точности прогноза, в силу значительного увеличения риска.

### Литература

1. Кесиян, Г. А. Математические модели ценообразования на российском рынке ценных бумаг / Г. А. Кесиян, М. А. Х. Уртенев, А. В. Коваленко. – Красно-дар : Кубанский государственный университет, 2014. – 158 с. – ISBN 978-5-8209-1074-6. – EDN XRJNCM.
2. Dadabada, Pradeepkumar & Vadlamani, Ravi. (2020). Financial time series prediction: an approach using motif information and neural networks. *International Journal of Data Science*. 5. 79. 10.1504/IJDS.2020.10031614.
3. Meng, X. A hybrid model for assessing the price behavior of financial markets: a case study of the HSI. *J Ambient Intell Human Comput* (2024). <https://doi.org/10.1007/s12652-024-04894-9>
4. S. Gong, D. Zhang, S. Du, H. Jiu and T. Zhou, "An Empirical Analysis and Research on the Prediction of Stock Trends Based on the MLP Neural Network Model, 2021 International Conference on Artificial Intelligence and Blockchain Technology (AIBT), Beijing, China, 2021, pp. 28-33, doi: 10.1109/AIBT53261.2021.00012.
5. Емалетдинова, Л. Ю. Нейросетевое моделирование задачи прогнозирования значений временного ряда / Л. Ю. Емалетдинова, А. Н. Кабирова, Н. Р. Вильданов // Вестник Технологического университета. – 2022. – Т. 25, № 10. – С. 101-106. – DOI 10.55421/1998-7072\_2022\_25\_10\_101. – EDN DHBERH.
6. TSMixer: An All-MLP Architecture for Time Series Forecasting / Si-An Chen and Chun-Liang Li and Nate Yoder and Sercan O. Arik and Tomas Pfister. - 2023. - 24 p. - Available at: <https://arxiv.org/abs/2303.06053>.
7. Метод построения прогнозной нейросетевой модели временного ряда / Л. Ю. Емалетдинова, З. И. Мухаметзянов, Д. В. Катасева, А. Н. Кабирова // Компьютерные исследования и моделирование. – 2020. – Т. 12, № 4. – С. 737-756. – DOI 10.20537/2076-7633-2020-12-4-737-756. – EDN FFSHKX.
8. Шабунин, А. В. Нейронная сеть как предсказатель динамики дискретного отображения / А. В. Шабунин // Известия высших учебных заведений. Прикладная нелинейная динамика. – 2014. – Т. 22, № 5. – С. 58-72. – DOI 10.18500/0869-6632-2014-22-5-58-72. – EDN TNVRPJ.
9. Takens, F. Detecting Strange Attractors in Turbulence / F. Takens // *Dynamical Systems and Turbulence*. – Warwick, 1981. - Vol. 898. - p. 366-381.
10. Учайкин, В. В. Автомодельность как характеристическое свойство нелокальной аномальной диффузии / В. В. Учайкин // Вестник НовГУ. - 2021. - №2 (123). - URL: <https://cyberleninka.ru/article/n/avtomodelnost-kak-harakteristicheskoe-svoystvo-nelokalnoy-anomalnoy-diffuzii> (дата обращения: 29.09.2024).
11. Головкин, В. А. Нейросетевые методы обработки хаотических процессов / В. А. Головкин // Научная сессия МИФИ–2005. VII всероссийская научно-техническая конференция «Нейроинформатика–2005»: лекции по нейроинформатике, Москва, 26–28 января 2005 года. – Москва : Московский физико-технический институт (государственный университет), 2005. – 214 с.
12. Kingma, D. P. Adam: a method for stochastic optimization / D. P. Kingma, J. Ba // 3rd International Conference for Learning Representations. - 2014.

### References

1. Kesijan, G. A. Matematicheskie modeli cenoobrazovanija na rossijskom rynke cennyh bumag / G. A. Kesijan, M. A. H. Urtenov, A. V. Kovalenko. – Krasno-dar : Kubanskij gosudarstvennyj universitet, 2014. – 158 s. – ISBN 978-5-8209-1074-6. – EDN XRJNCM.
2. Dadabada, Pradeepkumar & Vadlamani, Ravi. (2020). Financial time series prediction: an approach using motif information and neural networks. *International Journal of Data Science*. 5. 79. 10.1504/IJDS.2020.10031614.
3. Meng, X. A hybrid model for assessing the price behavior of financial markets: a case study of the HSI. *J Ambient Intell Human Comput* (2024). <https://doi.org/10.1007/s12652-024-04894-9>
4. S. Gong, D. Zhang, S. Du, H. Jiu and T. Zhou, "An Empirical Analysis and Research on the Prediction of Stock Trends Based on the MLP Neural Network Model, 2021 International Conference on Artificial Intelligence and Blockchain Technology (AIBT), Beijing, China, 2021, pp. 28-33, doi: 10.1109/AIBT53261.2021.00012.
5. Emaletdinova, L. Ju. Nejrosetevoe modelirovanie zadachi prognozirovanija znachenij vremennogo rjada / L. Ju. Emaletdinova, A. N. Kabirova, N. R. Vil'danov // *Vestnik Tehnologicheskogo universiteta*. – 2022. – T. 25, № 10. – S. 101-106. – DOI 10.55421/1998-7072\_2022\_25\_10\_101. – EDN DHBHERH.
6. TSMixer: An All-MLP Architecture for Time Series Forecasting / Si-An Chen and Chun-Liang Li and Nate Yoder and Sercan O. Arik and Tomas Pfister. - 2023. - 24 p. - Available at: <https://arxiv.org/abs/2303.06053>.
7. Metod postroenija prognoznoj nejrosetevoj modeli vremennogo rjada / L. Ju. Emaletdinova, Z. I. Muhametdzjanov, D. V. Kataseva, A. N. Kabirova // *Komp'juternye issledovanija i modelirovanie*. – 2020. – T. 12, № 4. – S. 737-756. – DOI 10.20537/2076-7633-2020-12-4-737-756. – EDN FFSHKX.
8. Shabunin, A. V. Nejronnaja set' kak predskazatel' dinamiki diskretnogo otobrazhenija / A. V. Shabunin // *Izvestija vysshih uchebnyh zavedenij. Prikladnaja nelinejnaja dinamika*. – 2014. – T. 22, № 5. – S. 58-72. – DOI 10.18500/0869-6632-2014-22-5-58-72. – EDN TNVRPJ.
9. Takens, F. Detecting Strange Attractors in Turbulence / F. Takens // *Dynamical Systems and Turbulence*. – Warwick, 1981. - Vol. 898. - p. 366-381.
10. Uchajkin, V. V. Avtomodel'nost' kak harakteristicheskoe svojstvo nelokal'noj anomal'noj diffuzii / V. V. Uchajkin // *Vestnik NovGU*. - 2021. - №2 (123). - URL: <https://cyberleninka.ru/article/n/avtomodelnost-kak-harakteristicheskoe-svoystvo-nelokalnoy-anomalnoy-diffuzii> (data obrashhenija: 29.09.2024).
11. Golovko, V. A. Nejrosetevye metody obrabotki haoticheskikh processov / V. A. Golovko // *Nauchnaja sessija MIFI–2005. VII vsrossijskaja nauchno-tehnicheskaja konferencija «Nejroinformatika–2005»: lekcii po nejroinformatike*, Moskva, 26–28 janvarja 2005 goda. – Moskva : Moskovskij fiziko-tehnicheskij institut (gosudarstvennyj universitet), 2005. – 214 s.
12. Kingma, D. P. Adam: a method for stochastic optimization / D. P. Kingma, J. Ba // *3rd International Conference for Learning Representations*. - 2014.