

REFERENCES

1. Nicolis, J. (1989). Dynamics of the hierarchical systems. Evolutional presentation. Moscow: Mir.
2. Olshansky, V. P. & Olshansky, S. V. (2014). Non-stationary vibrations of oscillator of variable mass taking into account a viscid friction. *Vibratsiyi v tekhnitsi i tekhnolohiyakh*, No. 3(75), pp. 18–27.
3. Bezglasnyi, S. P. & Kutyreva, N. I. (2013). Control of oscillations of a pendulum of variable length. *Izvestiia samarskogo nauchnogo tcentra Rossiiskoi akademii nauk*, Vol. 15, No. 6(3), pp. 589–593.
4. Bezglasnyi, S. P. & Kutyreva, N. I. (2014). Stabilization of nonstationary pendulum movements on a rotating base. *Izvestiia samarskogo nauchnogo tcentra Rossiiskoi akademii nauk*, Vol. 16, No. 4, pp. 77–82.
5. Krasilnikov, P. S. & Storozhkina, T. A. Study of resonant oscillations of a mathematical pendulum of variable length. *Elektronnyi zhurnal «Trudy MAI»*, Issue 46, pp. 1–11.
6. Mikishev, G. N. & Rabinovich, B. I. (1968). Dynamics of a solid body with cavities partially filled with liquid. Moscow: Mashinostroenie.
7. Narimanov, G. S., Dokuchaev, L. V. & Lukovskii, I. A. (1977). Nonlinear dynamics of an aircraft with a liquid. Moscow: Mashinostroenie.
8. Kubenko, V. D. & Koval'chuk, P. S. (2015). Modeling the Nonlinear Interaction of Standing and Traveling Bending Waves in Fluid-Filled Cylindrical Shells Subject to Internal Resonances. *International Applied Mechanics*, Vol. 50, No. 3, pp. 353–364.
9. Limarchenko, O. S. (2007). Peculiarities of application of perturbation techniques in problems of nonlinear oscillations of liquid with a free surface in cavities of non-cylindrical shape. *Ukrayins'kyi matematychnyy zhurnal*, Vol. 59, No. 1, pp. 44–70.
10. Azarskov, V. N., Grishchak, D. V. & Grishchak, D. D. (2013). An approximate analytical solution of the problem of the dynamics of a mathematical pendulum of variable mass and length. *Proceedings of the XI International Scientific and Technical Conference “AVIA-2013”*, (pp. 22.1–22.4), Kiev (NAU).
11. Grishchak, D. D. (2016). Control for forced vibrations of rotating mathematical pendulum with dependent from time length and mass. *Visnik Zaporiz'kogo nacional'nogo universitetu. Fiziko-matematični nauki*, No. 2, pp. 69–81.

УДК 0048:681.3

DOI: 10.26661/2413-6549-2018-2-03

**ОГЛЯД МЕТОДІВ МАШИННОГО НАВЧАННЯ В ЗАДАЧІ
ПРОГНОЗУВАННЯ ФІНАНСОВИХ ЧАСОВИХ РЯДІВ**

Гурєєва К. М., Кудін О. В., к. ф.-м. н., Лісняк А. О., к. ф.-м. н.

*Запорізький національний університет,
вул. Жуковського, 66, м. Запоріжжя, 69600, Україна*

avk256@gmail.com

Часові ряди, які відображають динаміку деякого процесу, є досить складними за своєю структурою та можуть включати тренд, сезонну складову, випадковий шум. Такі часові ряди містять характеристики, що описують зміни стану системи протягом її еволюції. Наприклад, фінансові часові ряди відображають поточний економічний стан, і тому перспективними є дослідження в цій сфері для моделювання подальшого розвитку економіки. У літературі запропоновано велику кількість різноманітних моделей для вирішення проблем прогнозування, це класичні методи математичної статистики, а також методи машинного навчання. Актуальною є задача аналізу сучасних методів і моделей прогнозування фінансових часових рядів та класифікації досить великого обсягу існуючих публікацій за певними ознаками. Метою даної

роботи є огляд останніх публікацій з прогнозування фінансових часових рядів, що використовують машинне навчання, статистичні підходи та гібридні моделі. На основі аналізу підходів, що використовуються в різних публікаціях, можна їх класифікувати за двома категоріями. До першої категорії належать роботи, у яких прогнозування здійснюється на основі попередніх значень часових рядів. У публікаціях цього класу використовуються класичні статистичні підходи, такі як ARIMA, GARCH та інші варіанти цих алгоритмів. Також застосовуються прогностичні моделі на основі методів машинного навчання: методу опорних векторів, k -найближчих сусідів, дерев рішень, нейронних мереж різних типів. У багатьох статтях для обробки даних використовуються перетворення Фур'є або вейвлет-перетворення. До другої категорії належать публікації, в яких автори намагаються об'єднати інформацію про конкретні події (фінансові або політичні новини, пошукові запити користувачів) та історію попередніх значень часових рядів. Такі моделі більш складні за рахунок великої кількості параметрів. На підставі аналізу публікацій та методів, що використовуються в них, можна зробити висновок, що найбільш перспективним напрямком дослідження є розробка гібридних систем, що поєднують прогнозування майбутніх значень часових рядів на основі історичних даних і використання додаткових даних з новин, статистики пошукових систем і т.д. Одним з методів розробки таких гібридних систем може бути метод побудови ансамблю різних моделей машинного навчання, які використовували б різні дані для навчання. Перевагою такого підходу є його адаптивність з точки зору використання обчислювальних ресурсів.

Ключові слова: фінансовий часовий ряд, машинне навчання, класифікація, прогнозування.

AN OVERVIEW OF MACHINE LEARNING METHODS FOR FINANCIAL TIME SERIES FORECASTING

Hurieieva K. M., Kudin O. V., Lisnyak A. O.

*Zaporizhzhya National University,
Zhykovsky str., 66, Zaporizhzhya, 69600, Ukraine*

avk256@gmail.com

Time series reflect the dynamic of natural or artificial process. Such time series contain parameters describing system's changes in different epochs of its evolution. For example, financial time series reflect current economic state and therefore researches in this sphere are demanded. A wide number of sophisticated models have been proposed in the literature to solve prediction problems, most popular are classic statistical methods and machine learning methods. Therefore, the necessity for overview modern methods and models for financial time series forecasting has arisen. The aim of our paper is to overview the recent publications which use machine learning, statistical approaches and hybrid models. There are two categories we determine from recent research papers survey. First category includes works in which the forecasting is performed on the basis of previous time series values. The methods used in these publications relate to classic statistical approaches, such as ARIMA, GARCH and other variants of these algorithms. Also, prognostic models are used based on methods of machine learning: the method reference vectors, k -nearest neighbors, decision trees, neural networks of different types. In many articles for data pre-processing Fourier transform or wavelet transform are used. The second category includes publications in which the authors try to combine the information about specific events (financial or political news, volume of user search queries) and the history of the previous values of the time series. Such models are more complex at the expense of a large number of parameters. Based on the analysis of publications and the methods used in them, we can conclude that the most promising direction of research is hybrid systems development that combine both the prediction of future values of the time series on the basis of historical data of a number of data, and the use of additional data from the news, search engine statistics, etc. One of the methods of developing such hybrid systems can be a method of constructing an ensemble of different models of machine learning, which would use different data for learning. The advantage of this approach is its adaptability in terms of demanding to computing resources.

Key words: financial time series, machine learning, classification, forecasting.

ВСТУП

Складні природні та технічні системи під час свого функціонування породжують часові ряди, які характеризують стан системи у певні проміжки часу. Можливість прогнозування таких часових рядів дозволяє дослідникам передбачати стан системи у майбутньому та застосовувати різні підходи для керування її станом. Згідно з деякими гіпотезами, зокрема гіпотезою ефективного ринку [1], стан ринку цінних паперів відображає не тільки актуальне положення економіки, але й політичні та соціальні події, які впливають на поведінку

учасників ринку. З іншої точки зору, сучасні ринки є адаптивними системами, які еволюціонують за певною внутрішньою логікою [2]. У будь-якому разі актуальною задачею є прогнозування фінансових часових рядів, які відображають зміну в часі макроекономічних показників, біржових індексів, вартості валютних пар тощо.

Метою даної роботи є огляд методів та моделей прогнозування фінансових часових рядів. Акцент робиться на роботах, які застосовують методи машинного навчання для дослідження впливу економічних, політичних новин на значення фінансових часових рядів, зокрема на курс криптовалют Bitcoin.

ОГЛЯД ПОПЕРЕДНІХ ПУБЛІКАЦІЙ

Стандартними задачами при аналізі часових рядів є прогнозування майбутніх значень ряду та класифікація рядів, наприклад для виявлення аномальних даних.

Прогнозуванню часових рядів присвячено досить багато публікацій, при цьому класичні підходи, які розглядаються в цих роботах, також застосовуються і в аналізі фінансових часових рядів. Такими підходами є сімейство методів на основі авторегресивної моделі (autoregressive moving-average model, ARMA) та авторегресивні умовно гетероскедастичні моделі (AutoRegressive Conditional Heteroscedasticity, ARCH), у яких моделюється залежність дисперсії від попередніх значень часового ряду. Основи цих методів викладено у монографіях, присвячених аналізу часових рядів [3, 4].

Застосування та розвинення класичних підходів у задачах прогнозування та аналізу фінансових часових рядів розглядається в роботах [5-9]. Статті [5, 8] присвячені особливостям використання сімейства методів ARCH. У [5] порівнюються 330 варіантів моделі ARCH для прогнозування значення коливань ціни (волатильності) фінансових часових рядів, зокрема в роботі [8] розглянуто модель порогової авторегресії (threshold autoregressive model). Автори на емпіричних прикладах демонструють високу ефективність моделі GARCH(1,1) порівняно з іншими варіантами.

При дослідженні часових рядів, як і в інших задачах, виникає потреба в попередній обробці даних з метою фільтрації або зміни способу представлення. Зазвичай у цих випадках використовуються варіанти перетворення Фур'є та, останніми роками, вейвлет перетворення.

У роботах [7, 9] розглядаються моделі фільтрації даних від шуму – випадкових значень часового ряду. Основна задача фільтрації даних у цьому випадку – відокремити детерміновані паттерни та цикли від випадкових значень ряду. Авторами використовуються декілька видів фільтрів – нелінійний прямий та зворотний фільтр (forward-backward filtering), фільтри на основі вейвлет та Фур'є перетворення. Для прогнозування значень часового ряду використовується модель авторегресії [7] та GARCH [9].

Одним з широко застосовуваних підходів є використання алгоритмів сімейства ARMA, ARCH у поєднанні з методами машинного навчання, які виконують функції налаштування параметрів класичних алгоритмів (наприклад, нейронні мережі, генетичні алгоритми тощо) [10-15]. Так, наприклад, у статтях [10-12] поєднується метод ARIMA з генетичним програмуванням [10], нейронними мережами [11, 12]. Прогнозування в таких випадках виконується в два етапи: спочатку моделюються лінійні залежності в даних за допомогою методу ARIMA, потім залишки прогнозуються за допомогою нелінійної моделі на базі одного з методів машинного навчання.

У роботі [13] перед застосуванням методу ARIMA виконується попереднє експоненційне згладжування даних. Пропонується метод декомпозиції часових рядів, який дозволяє виділити такі складові: тренд, сезонну компоненту, циклічну компоненту та випадковий шум.

Окрім нейронних мереж, широко застосовуються більш класичні детерміновані методи машинного навчання, наприклад, метод опорних векторів [14] або статистичне виведення за Бассом для оцінки параметрів методу GARCH в [15].

Останніми роками найбільша кількість публікацій присвячена саме використанню методів машинного навчання в задачах прогнозування часових рядів. Огляд статей з цього напрямку наведено в [16-19], а в [20-29] викладені деякі результати досліджень цього напрямку.

Одними з найбільш поширених інструментів прогнозування часових рядів серед методів машинного навчання є нейронні мережі, зокрема багатошаровий перцептрон. Так, у роботі [20] поєднуються багатошаровий перцептрон для прогнозування значень ряду та еволюційні алгоритми для параметризації нейронної мережі.

Також широко застосовуються різні варіанти рекурентних нейронних мереж (recurrent neural network, RNN). Особливість використання цієї архітектури полягає в тому, що результати обчислень рекурентних нейронів на попередніх ітераціях навчання впливають на всі наступні ітерації навчання, тобто у випадку з часовими рядами попередні значення ряду впливають на наступні, що і є природним. Наприклад, у роботі [22] для прогнозування часового ряду використовується варіант рекурентних нейронних мереж Елмана, який поєднує переваги використання багатошарового перцептрону та рекурентних нейронних мереж.

Порівняння ефективності нейронної мережі довгої короткочасної пам'яті (long short-term memory, LSTM), рекурентних нейронних мереж та згорткових нейронних мереж (convolutional neural network, CNN) для прогнозування фінансових часових рядів можна знайти в статті [23]. LSTM нейронні мережі також використовуються в роботах [25, 29].

У [26] будується гібридний підхід на основі обмеженої машини Больцмана та методу опорних векторів. Обмежена машина Больцмана використовується для зменшення розмірності вектора ознак часового ряду, а метод опорних векторів – для класифікації рядів на два класи: зростаючі та спадаючі часові ряди.

Не менш поширеними методами побудови регресійних моделей для прогнозування фінансових часових рядів є методи опорних векторів та k-найближчих сусідів [24, 27, 28].

З метою узагальнення результатів та отримання більш точної результуючої моделі в статтях [21, 25] розглядаються різні підходи до поєднання декількох моделей машинного навчання.

У задачах аналізу фінансових часових рядів є окремий напрям, який полягає у поєднанні класичних методів прогнозування та методів обробки додаткової, переважно текстової інформації [30-43]. Джерелами такої додаткової інформації зазвичай виступають поширені ресурси новин засобів масової інформації, блоги відомих фінансистів тощо. У статтях цього напрямку розв'язуються наступні основні задачі: вибір способу моделювання текстів, тобто перетворення тексту новин у деякий числовий вектор; визначення методу поєднання вектора характеристик новин та попередніх значень часового ряду; визначення проміжку часу між публікацією новин та потенційною реакцією ринку.

Серед основних методів моделювання текстів новин, які використовуються в останніх публікаціях, можна виділити наступні: статистика слів, які зустрічаються в документах (bag of words) [31, 37], статистика словосполучень (n-грами слів) [32, 37], статистика слів, що зустрічаються в документі стосовно статистики документів (term-frequency inverse-document-frequency) [30, 34, 37, 39]. Також у багатьох публікаціях використовуються бібліотеки Word2Vec, GloVe [43], OpenIE [40, 41], які є, фактично, стандартом у задачах обробки природної мови.

У деяких роботах [33, 42] аналізується не статистика певних слів або словосполучень у тексті, а емоційне забарвлення тексту в цілому з точки зору впливу на поведінку ринку. Зазвичай використовуються деякі заздалегідь натреновані словники та ресурси: Google-

Profile of Mood States, OpinionFinder [33], Loughran McDonald Master Dictionary [42]. Оскільки бібліотеки Word2Vec, GloVe, OpenIE описують семантичне представлення текстів, тобто відстань між векторами текстів зі схожим змістом буде незначна, вони також можуть використовуватись для визначення емоційного забарвлення текстів.

У роботі [35] аналізуються повідомлення у twitter-каналах, пов'язаних з певними фінансовими компаніями. Повідомлення у twitter моделюються за допомогою графу взаємодій, у якому вузлами є повідомлення, користувачі тощо, а ребрами – зв'язки. Після чого обчислюються характеристики графу, наприклад кількість пов'язаних компонентів. Показано високу кореляцію між зміною характеристик графу взаємодій та динамікою цін на ринку.

Інформація про статистику пошуків у Google, зокрема сервіс Google Trends та статистика переглядів Wikipedia, використовується в [38]. Показано кореляцію між підвищенням пошукових запитів, які стосуються певних валют та цінних паперів, та послідуочим падінням ринку.

У роботах [40, 41] розробляється метод структурного представлення новин засобами інструменту Open IE. Таке представлення дозволяє виділити об'єкт, дію, пов'язані об'єкти. Пропонується алгоритм на основі нейронних мереж представлення новин у вигляді $E = (O_1, P, O_2)$, де O_1, O_2 – об'єкти, які пов'язані дією P . Порівнюються два підходи до моделювання текстів – bag of words та структурне представлення [40]. Для класифікації новин використовуються метод опорних векторів, глибинна нейронна мережа прямого поширення [40] та згортокова нейронна мережа [41].

При моделюванні впливу фінансових новин на динаміку цін на ринку часто розв'язується задача класифікації з метою визначити, до якого наслідку призводить та чи інша новина: зменшення, збільшення ціни або нейтральний стан. Серед алгоритмів машинного навчання, які при цьому застосовуються як найбільш популярні, можна виділити наступні: метод опорних векторів [31, 32, 37, 39, 40], нейронні мережі прямого поширення сигналу [40, 42], самоорганізаційні карти Кохонена [30], метод навчання з множинними ядерними функціями (multi-kernel learning) [34], метод k-найближчих сусідів [39], згорткові нейронні мережі [41].

Останнім часом особливий інтерес представляє можливість прогнозування значень ціни криптовалют, наприклад Bitcoin, оскільки спосіб торгівлі, обсяг на ринку відрізняються від стандартних валют. Підходи до прогнозування значень ціни криптовалюти Bitcoin у доларах USD наведено в джерелах [44-51]. Можна зробити висновок, що основні підходи до прогнозування Bitcoin мало відрізняються від розглянутих вище. Так, у статтях [44, 45, 47, 48] для прогнозування значень часового ряду ціни Bitcoin використовуються наступні підходи: метод k-найближчих сусідів, метод опорних векторів [45], алгоритми ARIMA [47, 48] та GARCH [48], випадковий ліс [48], лінійна регресія [51], нейронні мережі [49-51].

Також у деяких роботах зустрічаються спроби аналізувати та прогнозувати вплив новин або активності у соціальних мережах на курс Bitcoin. Наприклад, у статті [46] для опису ступеня зацікавленості інвесторів у валюті використовується кількість повідомлень у Twitter. Для опису взаємної залежності двох часових рядів, відповідно, динаміки кількості нових у Twitter з ключовим словом «Bitcoin» та ціною валюти, використовується метод векторної авторегресії (vector autoregressive). Показано суттєвий вплив кількості повідомлень на волатильність валюти та на обсяг продаж.

У роботі [49] для прогнозування значень часового ряду використовується глибинна нейронна мережа прямого поширення сигналу з п'ятьма прихованими шарами, які містять по сто нейронів. Також використовуються рекурентні нейронні мережі. Для порівняння використовується чотири типи рекурентних нейронних мереж. Додатково аналізується інформація соціальних мереж, форумів, блогів фінансистів. Для обробки текстової

інформації використовується тематичне моделювання методом латентного аналізу Діріхле, яке застосовується для сентимент аналізу текстів.

Емоційне забарвлення тексту з точки зору фінансового впливу аналізується і в [51]. Для сентимент аналізу публікацій у Twitter застосовується алгоритм VADER [52]. Виконується порівняння декількох алгоритмів машинного навчання для прогнозування ціни Bitcoin, зокрема лінійна регресія, багатошаровий перцептрон та нейронна мережа типу LSTM.

ВИСНОВКИ

З аналізу літературних джерел можна зробити висновок, що задача прогнозування фінансових часових рядів, зокрема прогнозування цін криптовалют, є досить актуальною. Опубліковані на цей час наукові статті можна умовно розділити на дві великі категорії.

До першої відносять роботи, у яких виконується прогнозування на основі суто попередніх значень часового ряду. До методів, які застосовуються в цих публікаціях, відносяться класичні статистичні підходи, наприклад ARIMA, GARCH та інші варіанти цих алгоритмів. Також застосовуються прогностичні моделі на базі методів машинного навчання: методу опорних векторів, k-найближчих сусідів, дерев рішень, нейронних мереж різних типів. У багатьох статтях при попередній обробці даних використовується фільтрація за допомогою перетворення Фур'є або вейвлет-перетворення. Можливі також різні комбінації всіх згаданих підходів.

До другої категорії можна віднести публікації, у яких автори намагаються поєднати відомості про певні події (фінансові або політичні новини, кількість пошукових запитів користувачів) та історію попередніх значень часового ряду. Такі моделі є більш складними за рахунок великої кількості параметрів. Стандартними підходами тут є моделювання текстів за допомогою суто статистичних характеристик слів або застосування бібліотек, на кшталт Word2Vec та GloVe, які використовують заздалегідь навчені нейронні мережі для перетворення тексту в числовий вектор. Після цього числові вектори, що характеризують новини, поєднуються з історичними даними часових рядів цін валют або використовуються для навчання класифікатора, що визначає, як ціна впливає на курс.

На основі наведеного в роботі аналізу публікацій та методів, що в них застосовуються, можна зробити висновок, що найбільш перспективним напрямом досліджень є розробка гібридних систем, які поєднують у собі як прогнозування майбутніх значень часового ряду на основі історичних даних ряду даних, так і використання додаткових даних з новин, статистики пошукових запитів тощо. Одним з методів розробки таких гібридних систем може стати метод побудови ансамблю різних моделей машинного навчання, які б використовували для навчання різні дані.

Перевагою такого підходу може бути його адаптивність з точки зору вимогливості до обчислювальних ресурсів, оскільки, за необхідності, можна коректувати кількість класифікаторів, які беруть участь в аналізі.

ЛІТЕРАТУРА

1. Fama E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*. 1970. Vol. 25, N. 2. P. 383–417
2. Lo A. W. Adaptive Markets. Princeton University Press, 2017. 483 p.
3. Brockwell P. J., Davis R. A. Introduction to Time Series and Forecasting. New York: Springer, 2016. 425 p.
4. De Gooijer J. G. Elements of Nonlinear Time Series Analysis and Forecasting. New York: Springer, 2017. 622 p.
5. Hansen P. R., Lunde A. A Forecast Comparison of Volatility Models: Does Anything Beat a GARCH(1,1)? *Journal of Applied Econometrics*. 2005. Vol. 20. P. 873–879

6. Chakraborti A., Patriarca M., Santhanam M. S. Financial time-series analysis: A brief overview. 2007. URL: <https://arxiv.org/abs/0704.1738>.
7. Leng J. Modelling and Analysis on Noisy Financial Time Series. *Journal of Computer and Communications*. 2014. Vol. 2. P. 64–69.
8. Truong Buu-Chau, Chen Cathy W. S., So Mike K. P. Model selection of a switching mechanism for financial time series. *Applied Stochastic Models in Business and Industry*. 2016. P. 1-16.
9. Rostan P., Rostan A. The versatility of spectrum analysis for forecasting financial time series. *Journal of Forecasting*. 2017, Vol. 37. Issue 3. P. 327–339. DOI: <https://doi.org/10.1002/for.2504>.
10. Barbulescu A. Bautu E. A Hybrid Approach for Modeling Financial Time Series. *The International Arab Journal of Information Technology*. 2012, Vol. 9, N. 4, P. 327–335.
11. Kapila Tharanga Rathnayaka R. M., Seneiratna D. M. K. N, Arumawadu H. I. A New Financial Time Series Approach for Volatility Forecasting. *Symposium on Statistical & Computational Modelling with Applications*. 2016. P. 5–8.
12. Khashei M., Hajirahim Z. Performance evaluation of series and parallel strategies for financial time series forecasting. *Financial Innovation*. 2017. 3:24. DOI: <https://doi.org/10.1186/s40854-017-0074-9>.
13. Gautam A., Singh V. A Novel Approach for Decomposition of Financial Time Series. *Recent Innovations in Signal Processing and Embedded Systems (RISE-2017)*. 2017. DOI: 10.1109/RISE.2017.8378214.
14. Fabregues L., Arratia A., Belanche L.A. Forecasting Financial Time Series with Multiple Kernel Learning. *Advances in Computational Intelligence. IWANN 2017. Lecture Notes in Computer Science*. 2017. Vol 10306. P. 176-187. DOI: 10.1007/978-3-319-59147-6_16.
15. Zhu F., Quan W., Zheng Z., Wan S. A Bayesian Learning Method for Financial Time-Series Analysis. *IEEE Access*. 2018. Vol. 6. P. 38959–38966. DOI: 10.1109/ACCESS.2018.2853998.
16. Guilherme A. Barreto. Time Series Prediction with the Self-Organizing Map: Review. Perspectives of Neural-Symbolic Integration. *Studies in Computational Intelligence*. 2007. Vol 77. P. 135-158. DOI:https://doi.org/10.1007/978-3-540-73954-8_6.
17. Kavitha S., Raja Vadhana P., Nivi A. N. Big Data Analytics In Financial Market. *International Journal of Research in Engineering and Technology*. 2015. Vol. 04, Issue 02. P. 422-427.
18. Dingli A., Fournier K.S. Financial Time Series Forecasting – A Machine Learning Approach. *Machine Learning and Applications: An International Journal (MLAIJ)*. 2017. Vol. 4, No. 1/2/3.
19. Lorant Bodis. Financial Time Series Forecasting Using Artificial Neural Networks. Master Thesis. 2004.
20. Nayak S. C., Misra B. B., Behera H. S. Cooperative Optimization for Efficient Financial Time Series Forecasting. *2014 International Conference on Computing for Sustainable Global Development (INDIACom)*. 2014. P. 124-129.
21. Jin S., Su L., Ullah A. Robustify Financial Time Series Forecasting with Bagging. *Econometric Reviews*. 2014. Vol. 33(5–6). P. 575–605.
22. Wang J., Wang J., Fang W., Niu H. Financial Time Series Prediction Using Elman Recurrent Random Neural Networks. *Computational Intelligence and Neuroscience*. 2016. P. 1-14. DOI: <http://dx.doi.org/10.1155/2016/4742515>.
23. Sreelekshmy S., Vinayakumar R, Gopalakrishnan E.A, Vijay K.M., Soman K.P. Stock Price Prediction Using LSTM, RNN And CNN-Sliding Window Model. *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. 2017. P. 1643-1647. DOI: 10.1109/ICACCI.2017.8126078.
24. Chowdhury U. N., Chakravarty S. K., Hossain Md. T. Short-Term Financial Time Series Forecasting Integrating Principal Component Analysis and Independent Component Analysis with Support Vector Regression. *Journal of Computer and Communications*. 2018. Vol. 6. P. 51-67

25. Sun S., Wei Y., Wang S. AdaBoost-LSTM Ensemble Learning for Financial Time Series Forecasting. *ICCS 2018: Computational Science – ICCS 2018*. 2018. P. 590-597. DOI: 10.1007/978-3-319-93713-7_55.
26. Assis C. A. S., Machado E. J., Pereira A. C. M., Carrano E. G. Hybrid deep learning approach for financial time series classification. *Revista Brasileira de Computação Aplicada*. 2018, Vol. 10, N. 2, P. 54–63.
27. Pang S., Sarrafzadeh A., Inoue D. Referential kNN Regression for Financial Time Series Forecasting. *ICONIP 2013*. 2013. Part I. P. 601–608.
28. Yujun Y., Yimei Y., Jianping L. Research on financial time series forecasting based on SVM. *13th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP)*. 2016. P. 346–349. DOI: 10.1109/ICCWAMTIP.2016.8079870.
29. Yan H., Ouyang H. Financial Time Series Prediction Based on Deep Learning. *Wireless Pers Commun*. 2018. Vol. 102, Issue 2. P. 683–700. DOI: <https://doi.org/10.1007/s11277-017-5086-2>.
30. Stefano Di D., Pediroda V. A news-based financial time series discretization. *Proceedings of the 6th International Workshop on Self-Organizing Maps*. 2007. P. 1–8.
31. Schumaker R., Chen H. Textual Analysis of Stock Market Prediction Using Breaking Financial News: The AZFinText System. *ACM Transactions on Information Systems*. 2009. Vol. 27(2).
32. Kaya Yasef M. I., Karşligil M. E. Stock Price Prediction Using Financial News Articles. *2010 2nd IEEE International Conference on Information and Financial Engineering*. 2010. P. 478–482. DOI: 10.1109/ICIFE.2010.5609404.
33. Bollen J., Mao H., Zeng X.-J. Twitter mood predicts the stock market. 2010. Ref: <https://arxiv.org/pdf/1010.3003.pdf>.
34. Li X., Wang C., Dong J., Wang F., Deng X., Zhu S. Improving Stock Market Prediction by Integrating Both Market News and Stock Prices. *DEXA 2011, Part II, LNCS 6861*. 2011. P. 279–293.
35. Ruiz E. J., Hristidis V., Castillo C., Gionis A., Jaimes A. Correlating Financial Time Series with Micro-Blogging Activity. *WSDM '12 Proceedings of the fifth ACM international conference on Web search and data mining*. 2012. P. 513–522. DOI: 10.1145/2124295.2124358.
36. Abdullah S. S., Rahaman M. S., Rahman M. S. Analysis of Stock Market using Text Mining and Natural Language Processing. *International Conference on Informatics, Electronics and Vision (ICIEV)*. 2013. DOI: 10.1109/ICIEV.2013.6572673.
37. Hagenau M., Liebmann M., Neumann D. Automated news reading: Stock price prediction based on financial news using context-capturing features. *Decision Support Systems*. 2013. Vol. 55. P. 685–697.
38. Curme C., Preis T., Stanley H.E., Moat H.S. Quantifying the semantics of search behavior before stock market moves. *PNAS*. 2014. Vol. 111, N. 32. P. 11600–11605.
39. Seker S. E., Mert C., Al-Naami K., Ozalp N., Ayan U. Time Series Analysis On Stock Market For Text Mining Correlation Of Economy News. *International Journal Of Social Sciences And Humanity Studies*. 2014. Vol 6, No 1. ISSN: 1309-8063 (Online).
40. Ding X., Zhang Y., Liu T., Duan J. Using structured events to predict stock price movement: An empirical investigation. *Proceedings EMNLP*. 2014. P. 1415–1425.
41. Ding X., Zhang Y., Liu T., Duan J. Deep Learning for Event-Driven Stock Prediction. *Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015)*. 2015. P. 2327–2333.
42. Кононова К. Ю., Дек А. О. Прогнозування Фінансових Рядів: Семантичний Аналіз Економічних Новин. *Нейро-нечіткі технології моделювання в економіці*. 2016. № 5. С. 82–92.
43. Bruyn De M. From Word to Financial Time Series Embedding. 2018. Ref: <https://ssrn.com/abstract=3184513>.
44. Catania L., Grassi S. Modelling Crypto-Currencies Financial Time-Series. 2017. DOI: 10.2139/ssrn.3028486.

45. Raghava-Raju A. A Machine Learning Approach to Forecast Bitcoin Prices. *International Journal of Computer Applications* (0975 – 8887). 2018. Vol. 182, No. 24.
46. Shen D., Urquhart A., Wang P. Does twitter predict Bitcoin? *Economics Letters*. 2018. DOI: <https://doi.org/10.1016/j.econlet.2018.11.007>.
47. Yenidogan I., Cayir A., Kozan O., Dag T., Arslan C. Bitcoin Forecasting Using ARIMA and PROPHET. *3rd International Conference on Computer Science and Engineering UBMK'18*. 2018. DOI: 10.1109/UBMK.2018.8566476.
48. Guo T., Antulov-Fantulin N. An experimental study of Bitcoin fluctuation using machine learning methods. 2018. URL: <https://arxiv.org/abs/1802.04065>.
49. Seo Y., Hwang C. Predicting Bitcoin Market Trend with Deep Learning Models. *Quantitative Bio-Science*. 2018. Vol. 37, No. 1. P. 65-71
50. Nakano M., Takahashi A., Takahashi S. Bitcoin technical trading with artificial neural network. *Physica A*. 2018. № 510. P. 587–609
51. Matas Navickas, Ignas Bagdonas, Vu Ngoc Viet Nguyen. Predicting Bitcoin Price using Machine Learning. 2018. Report.
52. Hutto C. J., Gilbert E. VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text. *8th international AAAI conference on weblogs and social media (ICWSM)*. 2014.

REFERENCES

1. Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, Vol. 25, No. 2, pp. 383-417.
2. Lo, A. W. (2017). *Adaptive Markets*. Princeton University Press.
3. Brockwell, P. J. & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. New York: Springer.
4. De Gooijer, J. G. (2017). *Elements of Nonlinear Time Series Analysis and Forecasting*. New York: Springer.
5. Hansen, P. R., Lunde, A. (2005). A Forecast Comparison of Volatility Models: Does Anything Beat a GARCH(1,1)? *Journal of Applied Econometrics*, Vol. 20, pp. 873-879.
6. Chakraborti, A., Patriarca, M. & Santhanam, M. S. (2007). Financial time-series analysis: A brief overview. URL: <https://arxiv.org/abs/0704.1738>.
7. Leng, J. (2014). Modelling and Analysis on Noisy Financial Time Series. *Journal of Computer and Communications*, Vol. 2, pp. 64-69.
8. Truong, Buu-Chau, Chen Cathy, W. S. & So Mike, K. P. (2016). Model selection of a switching mechanism for financial time series. *Applied Stochastic Models in Business and Industry*, pp. 1-16.
9. Rostan, P. & Rostan, A. (2017). The versatility of spectrum analysis for forecasting financial time series. *Journal of Forecasting*, Vol. 37, Issue 3, pp. 327-339. DOI: <https://doi.org/10.1002/for.2504>.
10. Barbulescu, A. & Bautu, E. (2012). A Hybrid Approach for Modeling Financial Time Series. *The International Arab Journal of Information Technology*, Vol. 9, No. 4, pp. 327-335.
11. Kapila Tharanga Rathnayaka, R. M., Seneiratna, D. M. K. N. & Arumawadu, H. I. (2016). A New Financial Time Series Approach for Volatility Forecasting. *Symposium on Statistical & Computational Modelling with Applications*, pp. 5-8.
12. Khashei, M. & Hajirahim, Z. (2017). Performance evaluation of series and parallel strategies for financial time series forecasting. *Financial Innovation*, Vol. 3:24. DOI: <https://doi.org/10.1186/s40854-017-0074-9>.
13. Gautam, A. & Singh, V. (2017). A Novel Approach for Decomposition of Financial Time Series. *Recent Innovations in Signal Processing and Embedded Systems (RISE-2017)*. DOI: 10.1109/RISE.2017.8378214.

14. Fabregues, L., Arratia, A. & Belanche, L. A. (2017). Forecasting Financial Time Series with Multiple Kernel Learning. *Advances in Computational Intelligence. IWANN 2017. Lecture Notes in Computer Science*, Vol. 10306, pp. 176-187. DOI: 10.1007/978-3-319-59147-6_16.
15. Zhu, F., Quan, W., Zheng, Z. & Wan, S. (2018). A Bayesian Learning Method for Financial Time-Series Analysis. *IEEE Access*, Vol. 6, pp. 38959-38966. DOI: 10.1109/ACCESS.2018.2853998.
16. Guilherme, A. Barreto. (2007). Time Series Prediction with the Self-Organizing Map: Review. Perspectives of Neural-Symbolic Integration. *Studies in Computational Intelligence*, Vol. 77, pp. 135-158. DOI: https://doi.org/10.1007/978-3-540-73954-8_6.
17. Kavitha, S., Raja Vadhana, P. & Nivi, A. N. (2015). Big Data Analytics In Financial Market. *International Journal of Research in Engineering and Technology*, Vol. 04, Issue 02, pp. 422-427.
18. Dingli, A. & Fournier, K. S. (2017). Financial Time Series Forecasting – A Machine Learning Approach. *Machine Learning and Applications: An International Journal (MLAIJ)*, Vol. 4, No. 1/2/3.
19. Lorant, Bodis (2004). Financial Time Series Forecasting Using Artificial Neural Networks. Master Thesis.
20. Nayak, S. C., Misra, B. B. & Behera, H. S. (2014). Cooperative Optimization for Efficient Financial Time Series Forecasting. 2014 International Conference on Computing for Sustainable Global Development (INDIACom), pp. 124-129.
21. Jin, S., Su, L. & Ullah, A. (2014). Robustify Financial Time Series Forecasting with Bagging. *Econometric Reviews*, Vol. 33(5–6), pp. 575-605.
22. Wang J., Wang J., Fang W., Niu H. (2016). Financial Time Series Prediction Using Elman Recurrent Random Neural Networks. *Computational Intelligence and Neuroscience*, pp. 1-14. DOI: <http://dx.doi.org/10.1155/2016/4742515>.
23. Sreelekshmy, S., Vinayakumar, R., Gopalakrishnan, E. A., Vijay, K. M. & Soman, K. P. (2017). Stock Price Prediction Using LSTM, RNN And CNN-Sliding Window Model. 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI), pp. 1643-1647. DOI: 10.1109/ICACCI.2017.8126078.
24. Chowdhury, U. N., Chakravarty, S. K. & Hossain, Md. T. (2018). Short-Term Financial Time Series Forecasting Integrating Principal Component Analysis and Independent Component Analysis with Support Vector Regression. *Journal of Computer and Communications*, Vol. 6, pp. 51-67.
25. Sun, S., Wei, Y. & Wang, S. (2018). AdaBoost-LSTM Ensemble Learning for Financial Time Series Forecasting. *ICCS 2018: Computational Science – ICCS 2018*, pp. 590-597. DOI: 10.1007/978-3-319-93713-7_55.
26. Assis, C. A. S., Machado, E. J., Pereira, A. C. M. & Carrano, E. G. (2018). Hybrid deep learning approach for financial time series classification. *Revista Brasileira de Computação Aplicada*, Vol. 10, No. 2, pp. 54-63.
27. Pang, S., Sarrafzadeh, A. & Inoue, D. (2013). Referential kNN Regression for Financial Time Series Forecasting. *ICONIP 2013, Part I*, pp. 601-608.
28. Yujun, Y., Yimei, Y. & Jianping, L. (2016). Research on financial time series forecasting based on SVM. 13th International Computer Conference on Wavelet Active Media Technology and Information Processing (ICCWAMTIP), pp. 346-349. DOI: 10.1109/ICCWAMTIP.2016.8079870.
29. Yan, H. & Ouyang, H. (2018). Financial Time Series Prediction Based on Deep Learning. *Wireless Pers Commun*, Vol. 102, Issue 2, pp. 683-700. DOI: <https://doi.org/10.1007/s11277-017-5086-2>.
30. Stefano, Di D. & Pediroda, V. (2007). A news-based financial time series discretization. *Proceedings of the 6th International Workshop on Self-Organizing Maps*, pp. 1-8.
31. Schumaker, R. & Chen, H. (2009). Textual Analysis of Stock Market Prediction Using Breaking Financial News: The AZFinText System. *ACM Transactions on Information Systems*, Vol. 27(2).
32. Kaya Yasef, M. I. & Karsligil, M. E. (2010). Stock Price Prediction Using Financial News Articles. 2010 2nd IEEE International Conference on Information and Financial Engineering, pp. 478-482. DOI: 10.1109/ICIFE.2010.5609404.

33. Bollen, J., Mao, H. & Zeng, X.-J. (2010). Twitter mood predicts the stock market. Ref: <https://arxiv.org/pdf/1010.3003.pdf>.
34. Li, X., Wang, C., Dong, J., Wang, F., Deng, X. & Zhu, S. (2011). Improving Stock Market Prediction by Integrating Both Market News and Stock Prices. DEXA 2011, Part II, LNCS 6861, pp. 279-293.
35. Ruiz, E. J., Hristidis, V., Castillo, C., Gionis, A. & Jaimes, A. (2012). Correlating Financial Time Series with Micro-Blogging Activity. WSDM '12 Proceedings of the fifth ACM international conference on Web search and data mining, pp. 513-522. DOI: 10.1145/2124295.2124358.
36. Abdullah, S. S., Rahaman, M. S. & Rahman, M. S. (2013). Analysis of Stock Market using Text Mining and Natural Language Processing. International Conference on Informatics, Electronics and Vision (ICIEV). DOI: 10.1109/ICIEV.2013.6572673.
37. Hagenau, M., Liebmann, M. & Neumann, D. (2013). Automated news reading: Stock price prediction based on financial news using context-capturing features. Decision Support Systems, Vol. 55, pp. 685-697.
38. Curme, C., Preis, T., Stanley, H. E. & Moat, H. S. (2014). Quantifying the semantics of search behavior before stock market moves. PNAS, Vol. 111, No. 32, pp. 11600-11605.
39. Seker, S. E., Mert, C., Al-Naami, K., Ozalp, N. & Ayan, U. (2014) Time Series Analysis On Stock Market For Text Mining Correlation Of Economy News. International Journal Of Social Sciences And Humanity Studies, Vol 6, No. 1. ISSN: 1309-8063 (Online).
40. Ding, X., Zhang, Y., Liu, T. & Duan, J. (2014). Using structured events to predict stock price movement: An empirical investigation. Proceedings EMNLP, pp. 1415-1425.
41. Ding, X., Zhang, Y., Liu, T. & Duan, J. (2015). Deep Learning for Event-Driven Stock Prediction. Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015), pp. 2327-2333.
42. Kononova, K. & Dek, A. (2016). Financial Time Series Forecasting: Semantic Analysis of Economic News. Neuro-Fuzzy Modeling Techniques in Economics, No. 5, pp. 82-92.
43. Bruyn, De M. (2018). From Word to Financial Time Series Embedding. Ref: <https://ssrn.com/abstract=3184513>.
44. Catania, L. & Grassi, S. (2017). Modelling Crypto-Currencies Financial Time-Series. DOI: 10.2139/ssrn.3028486.
45. Raghava-Raju, A. (2018). A Machine Learning Approach to Forecast Bitcoin Prices. International Journal of Computer Applications, Vol. 182, No. 24.
46. Shen, D., Urquhart, A. & Wang P. (2018). Does twitter predict Bitcoin? Economics Letters. DOI: <https://doi.org/10.1016/j.econlet.2018.11.007>.
47. Yenidogan, I., Cayir, A., Kozan, O., Dag, T. & Arslan, C. (2018). Bitcoin Forecasting Using ARIMA and PROPHET. 3rd International Conference on Computer Science and Engineering UBMK'18. DOI: 10.1109/UBMK.2018.8566476.
48. Guo, T. & Antulov-Fantulin, N. (2018). An experimental study of Bitcoin fluctuation using machine learning methods. URL: <https://arxiv.org/abs/1802.04065>.
49. Seo, Y. & Hwang, C. (2018). Predicting Bitcoin Market Trend with Deep Learning Models. *Quantitative Bio-Science*, Vol. 37, No. 1, pp. 65-71.
50. Nakano, M., Takahashi, A. & Takahashi, S. (2018). Bitcoin technical trading with artificial neural network. *Physica A*, No. 510, pp. 587-609.
51. Matas Navickas, Ignas Bagdonas & Vu Ngoc Viet Nguyen. (2018). Predicting Bitcoin Price using Machine Learning. Report.
52. Hutto, C. J. & Gilbert, E. (2014). VADER: A Parsimonious Rule-based Model for Sentiment Analysis of Social Media Text. 8th international AAAI conference on weblogs and social media (ICWSM).