

РАЗРАБОТКА ПРОГНОЗА ДИНАМИКИ КУРСА КРИПТОВАЛЮТЫ НА ОСНОВЕ ТЕОРИИ МАШИННОГО ОБУЧЕНИЯ*

Леонид Алексеевич ЕЛЬШИН^а, Айзат Минеханович ГИЛЬМАНОВ^б,
Виктор Викторович БАНДЕРОВ^с

^а доктор экономических наук, заведующий отделом макроисследований и экономики роста,
Центр перспективных экономических исследований АН Республики Татарстан, Казань, Российская Федерация
Leonid.Elshin@tatar.ru
<https://orcid.org/0000-0002-0763-6453>
SPIN-код: 1059-7059

^б магистр Института вычислительной математики и информационных технологий,
Казань, Российская Федерация
ai.9595@mail.ru
ORCID: отсутствует
SPIN-код: отсутствует

^с кандидат физико-математических наук, доцент кафедры анализа данных и исследования операций,
Казанский (Приволжский) федеральный университет (КФУ), Казань, Российская Федерация
Victor.Banderov@kpfu.ru
ORCID: отсутствует
SPIN-код: 7516-0379

* Ответственный автор

История статьи:

Рег. № 452/2019
Получена 26.06.2019
Получена в доработанном виде 14.07.2019
Одобрена 02.08.2019
Доступна онлайн
28.02.2020

УДК 332.055

JEL: F47, F63, G17

Ключевые слова: рынок криптовалюты, временной ряд, прогнозирование, машинное обучение, искусственные нейронные сети, LSTM, искусственный интеллект

Аннотация

Предмет. Методические подходы к прогнозированию динамики развития рынка криптовалюты (на примере биткойна).

Цели. Поиск и научное обоснование инструментов и механизмов разработки прогностических оценок развития рынка криптовалюты на краткосрочный период времени с использованием методов моделирования временных рядов на основе использования методов машинного обучения, в которых применяются искусственные нейронные сети LSTM.

Методология. На основе использования методов программирования в среде Python построена и обоснована модель нейронной сети для анализируемого ряда, характеризующего динамику биржевого курса биткойна.

Результаты. На основе реализации подбора функции потерь, оптимизатора и параметров построения нейронной сети, предсказывающей курс валютной пары BTC/USD на один день вперед доказана ее высокая пригодность, что подтверждается минимальным уровнем ошибок на тренировочной и валидационной выборке.

Область применения. Разработанный подход целесообразно использовать при проведении анализа и оценки текущих и перспективных параметров развития рынка криптовалюты. Инструментарий может представлять практический интерес для инвесторов, осуществляющих свою деятельность на новых рынках цифровых денег.

Выводы. Полученные результаты во многом свидетельствуют о перспективности выбранного инструментария прогнозирования рынка криптовалюты, основанного на использовании алгоритмов построения LSTM-сетей.

© Издательский дом ФИНАНСЫ и КРЕДИТ, 2019

Для цитирования: Ельшин Л.А., Гильманов А.М., Бандеров В.В. Разработка прогноза динамики курса криптовалюты на основе теории машинного обучения // *Финансовая аналитика: проблемы и решения*. – 2020. – Т. 13, № 1. – С. 97 – 113.
<https://doi.org/10.24891/fa.13.1.97>

Введение

Стремительно набирающие обороты процессы глобализации и цифровизации в экономике неизбежно запускают механизмы трансформации традиционных механизмов регулирования рынка денег и финансов. Новые инструменты обмена, накопления, распределения активов, развитие инновационных технологий в сфере транзакций влекут за собой значительные изменения привычных нам финансовых институтов. Одним из ярчайших примеров данных трансформационных процессов является рынок криптовалюты и связанные с ним технологии распределенного хранения данных (блокчейн-технологии), последовательно и уверенно захватывающие финансовый сектор национальных экономических систем, формируя новую парадигму развития государств в рамках концепции FinTech.

Несмотря на то, что на сегодняшний день рынок криптовалюты не получил однозначной юрисдикции в некоторых странах (*табл. 1, рис. 1*), а также несмотря на имеющие место скептические взгляды на рынок криптовалюты, спрос на финансовые инструменты, основанные на криптотранзакциях, не ослабевает, а только лишь стремительно набирает обороты в русле циклических закономерностей развития. В связи с этим внимание к данному инструменту со стороны мирового сообщества, государственных регуляторов с каждым днем возрастает, о чем свидетельствует динамика легализации данного рынка в мире¹ [1].

Вместе с тем, несмотря на в целом весьма высокий, восстанавливающийся после кризиса

2017 г. уровень активности на рынке цифровых денег (*рис. 2*), к настоящему моменту времени в научном и экспертном сообществе существуют определенные пробелы в части его изучения, особенно с позиции прогностических оценок и разработки соответствующего модельного аппарата.

Большинство стран не запрещают криптовалютные транзакции, однако единого определения цифровых денег, а также их правового статуса у них нет, следовательно, нормы регулирования, если таковые имеются, тоже различаются.

На сегодняшний день существует множество цифровых валют (свыше 2 200 ед.). Однако чтобы лучше продемонстрировать уровень их активности, в настоящем исследовании сконцентрировано внимание на самой известной цифровой валюте – биткойне, занимающим порядка 85% от общего мирового рынка криптовалюты.

Биткойны используются в ежедневных транзакциях значительное количество раз. Подтвержденное количество транзакций биткойнов на 1 июня 2019 г. составило 332 092 ед. (*рис. 3*). При этом следует, конечно же, упомянуть, что на рубеже 2017–2018 гг. интенсивность криптотранзакций значительным образом скорректировалась. В первую очередь это было связано с падением курса основных валют на исследуемом рынке. Вместе с тем к концу 2018 г. сформировавшийся негативный тренд преломился, и можно было наблюдать вновь рост совершаемых операций на мировых криптобиржах, что положительным образом сказалось на общей динамике развития рынка биткойна (*рис. 3*).

Учитывая наблюдаемую динамику циклического роста рынка криптовалюты с возрастающим трендом (предполагающую различные фазы своего развития во времени), крайне актуальным вопросом является выработка прогностического аппарата, позволяющего предсказывать весьма волатильные тренды его развития.

^{*} Статья подготовлена в рамках поддержанного РФФИ научного проекта № 18-010-00536.

Выражаем благодарность сотрудникам Казанского (Приволжского) федерального университета – участникам научного проекта № 19-18-00202 Российского научного фонда за помощь в подготовке публикации.

¹ The number of daily confirmed Bitcoin transactions. Source: blockchain.com. Confirmed Transactions Per Day. URL: <https://blockchain.info/charts/n-transactions>; The total USD value of bitcoin supply in circulation, as calculated by the daily average market price across major exchanges. URL: <https://blockchain.info/charts/market-cap>

Необходимо отметить, что решение данного рода вопросов частично и весьма в ограниченном формате находит свое отражение в пространстве научно-исследовательских российских и зарубежных работ. Вместе с тем следует констатировать, что в подавляющем большинстве случаев из числа ограниченного спектра работ, посвященных этой теме, исследования опираются либо на инструменты технического анализа² [2, 3], либо фундаментального [4–6]. Однако ни один из них нельзя отнести к категории эффективных применительно к рынку криптовалюты.

Аналогичной позиции придерживаются и авторы работы [7]. В соответствии с позицией исследователей, *«использование фундаментального анализа для прогнозирования волатильности биржевых котировок является неэффективным, так как курс криптовалюты не зависит от экономики определенной страны; использование технического анализа также неэффективно, так как невозможно определить состояние рынка в силу формирования спроса и предложения за счет лиц, готовых купить, либо продать определенные товары или услуги по всему миру»*.

Решение поставленного вопроса с использованием методов экономико-математического моделирования уже частично было предложено нами в научных трудах [1, 8–10]. В них с использованием методов эконометрического анализа было установлено и обосновано, что использование класса моделей *ARIMA*, *ARMA* в процессе моделирования параметров развития глобального рынка криптовалюты позволяет с высоким уровнем точности предсказывать не только текущие, но и будущие корректировки курса цифровых валют.

Вместе с тем, несомненно, останавливаться на достигнутом результате было бы неверным.

² *Badev A., Chen M.* Bitcoin: Technical Background and Data Analysis. Finance and Economics Discussion Series Divisions of Research & Statistics and Monetary Affairs Federal Reserve Board. Washington, D.C., 2014.
URL: <https://federalreserve.gov/econresdata/feds/2014/files/2014104pap.pdf>

Любой прогноз считается более реалистичным и точным, если он построен на основе использования различных методов, что впоследствии позволяет перейти к построению так называемых консенсус-прогнозов. В связи с этим целью настоящей работы является разработка дополнительных методических подходов, обеспечивающих процесс разработки прогностических оценок рынка криптовалюты. За основу был выбран метод нейронных сетей LSTM. При этом в качестве объекта исследования, также как и в наших предыдущих научных трудах, выбрана криптовалюта биткойн (*bitcoin*). Данный выбор обусловлен весьма широким набором аргументов, главные из которых выражаются в доминировании данной криптовалюты на рынке цифровых денег (около 50%), а также в ее популярности в системе реализации криптовалютных транзакций.

Процесс построения нейронных сетей применительно к статистическим временным рядам, отражающих динамику курса криптовалюты биткойн, представлен далее – с подробным описанием целесообразности и необходимости использования рекуррентного LSTM-слоя в рамках реализации задачи применения методов и инструментов моделей глубокого изучения анализируемых процессов.

Глубокое обучение (ГО) – это подмножество методов машинного обучения, в которых применяются искусственные нейронные сети (ИНС), построенные на базе аналогии со структурой нейронов человеческого мозга. Данные методы с огромным успехом применяются в самых разных областях (обработка изображений, текста, видео, речи и т.д.), что позволило добиться значительного прогресса по сравнению с результатами, достигнутыми за предшествующие годы. Своими успехами ГО обязано наличию больших объемов обучающих данных и графических процессоров (*GPU*), позволяющих построить очень эффективную процедуру вычислений. В компаниях Google, Microsoft, Amazon, Apple, Facebook и многих других методы глубокого обучения постоянно используются для анализа больших массивов данных.

Сети долгосрочной кратковременной памяти, или сокращенно LSTM, могут применяться для прогнозирования временных рядов. Существует множество типов моделей LSTM, которые можно использовать для каждой конкретной задачи прогнозирования.

В данной статье разрабатывалась модель LSTM для прогнозирования временных рядов, характеризующих динамику курса биткойна (BTC/USD).

Методы исследования

Перцептрон – это простой алгоритм, который получает входной вектор x , содержащий n значений (x_1, x_2, \dots, x_n) , которые часто называются входными признаками, и на выходе выдается два значения: 1 (да) или 0 (нет). Формально говоря, определяется функция:

$$f(x) = \begin{cases} 1, & \text{если } wx + b > 0 \\ 0, & \text{если } wx + b \leq 0 \end{cases},$$

где w – вектор весов; wx – скалярное произведение; b – смещение.

Многослойный перцептрон (МСП) – это модель с несколькими линейными слоями. На *рис. 4* показана нейронная сеть с одним входным, одним промежуточными и одним выходным слоем.

Рекуррентные нейронные сети – это класс нейронных сетей, в которых используется последовательная природа входных данных. Обычные нейронные сети – описанные ранее многослойные перцептроны – имеют фиксированное число входов и воспринимают каждый из них как независимый. В рекуррентных же сетях связи между нейронами могут идти не только от нижнего слоя к верхнему, но и от нейрона к самому себе, точнее, к предыдущему значению самого этого нейрона или других нейронов того же слоя. Именно это позволяет отразить зависимость переменной от своих значений в разные моменты времени: нейрон обучается использовать не только текущий вход и то, что с ним сделали нейроны предыдущих уровней,

но и то, что происходило с ним самим и, возможно, другими нейронами на предыдущих входах [11].

Входными данными может быть текст, речь, временные ряды и, вообще, любой объект, в котором появление элемента либо последовательности зависит от предшествующих элементов.

Для временных рядов, например, котировки валют характерна зависимость от прошлых данных, это явление называется долговременным трендом.

В ячейках рекуррентных нейронных сетей данная зависимость представляется с помощью скрытого состояния, или памяти, в которой хранится сводка прошлой информации. Значение скрытого состояния в любой момент времени – функция его значения на предыдущем шаге и значения данных на текущем шаге:

$$h_t = \phi(h_{t-1}, x_t),$$

где h_t и h_{t-1} – значения скрытого состояния на шаге t и $t - 1$ соответственно, и x_t – входное значение в момент t . Отметим, что данное уравнение рекуррентное, то есть h_{t-1} можно выразить через h_{t-2} и x_{t-1} и т.д., пока не дойдем до начала последовательности. Таким образом, в рекуррентных нейронных сетях кодируется и запоминается информация о сколь угодно длинной последовательности.

Обучение рекуррентной нейронной сети включает обратное распределение [11–14]. В процессе обратного распределения на каждом временном шаге вычисляются градиенты функции потерь по параметрам U , V и W , и сумма градиентов применяется для обновления параметров.

В обычных рекуррентных нейронных сетях возникает проблема исчезающего и взрывного градиента [15]. Из-за этого эффекта получается, что градиенты на отдельных шагах не дают никакого вклада в процесс обучения, так что обычная рекуррентная

нейронная сеть не может учесть долговременные зависимости.

Взрывные градиенты обнаруживаются проще, поскольку, когда градиент становится слишком большим и превращается в не число (*NaN*), процесс обучения аварийно завершается. Рост градиентов можно контролировать, обрезая их при достижении заданного порога³.

Существует несколько подходов к смягчению проблемы исчезающих градиентов, в частности, хорошая инициализация W , но наиболее популярна архитектура LSTM. Она специально проектирована для борьбы с исчезающим градиентом и более эффективно обучается долговременным зависимостям.

LSTM – это вариант рекуррентной нейронной сети, способный обучаться долгосрочным зависимостям [16]. LSTM-сети хорошо работают для широкого круга задач и являются самым популярным типом рекуррентной нейронной сети. В LSTM для реализации рекуррентности используется комбинация скрытого состояния на предыдущем шаге и текущих входных данных в слое с функцией активации. На *рис. 5* показаны преобразования, применяемые к скрытому состоянию на временной шкале t .

На горизонтальной линии сверху показано состояние ячейки, оно представляет внутреннюю память блока. На линии снизу показано скрытое состояние, а вентили f , i , c , o – это механизмы, благодаря которым LSTM-сеть обходит проблему исчезающего градиента. В процессе обучения LSTM находит параметры этих вентиляей:

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f);$$

$$i_t = \sigma_g(W_o x_o + U_i h_{t-1} + b_i);$$

$$o_t = \sigma_g(W_f x_t + U_o h_{t-1} + b_o);$$

$$c_t = f_t c_{t-1} + i_t \sigma_c(W_c x_c + U_c h_{t-1} + b_c);$$

³ *Pascanu R., Mikolov T., Bengio Y.* On the Difficulty of Training Recurrent Neural Networks, 2013. URL: <http://proceedings.mlr.press/v28/pascanu13.pdf>

$$h_t = o_t \sigma_g(c_t),$$

где x_t – входной вектор; y_t – выходной вектор;

c_t – вектор состояния; f_t – вектор вентиля забывания, вес запоминания старой информации; i_t – вектор входного вентиля, вес получения новой информации; o_t – вентиль выходного вектора; σ_g – функция активации на основе сигноиды; σ_c – функция активации на основе гиперболического тангенса.

Результаты и их обсуждение

Для построения нейронной сети, предсказывающей курс валютной пары BTC/USD на один день вперед, были взяты данные с портала *Criptocompare*⁴. Пример входных данных представлен в *табл. 2*.

Входные данные:

Low – самая низкая цена в период времени t ;

High – самая высокая цена в период времени t ;

Open – цена открытия в период времени t ;

Close – цена закрытия в период времени t ;

Volumefrom – объем торгов в биткойнах в период времени t ;

Volumeto – объем торгов в долларах в период времени t .

Выходные данные:

Low – самая низкая цена в период времени $t + 1$;

High – самая высокая цена в период времени $t + 1$;

Close – цена закрытия в период времени $t + 1$.

Для улучшения работы нейронных сетей мы использовали нормализацию данных в пределах $[0 \div 1]$ ⁵. Результат представлен в

⁴ *Criptocompare*. URL: <https://cryptocompare.com/>

⁵ *Голенков В.В., Гергет О.М.* Анализ методов нормировки разнотипных данных для анализа в экспертных системах медицинской диагностики. Томск: Изд-во Томского политех. ун-та, 2013. URL: <https://docplayer.ru/55311465-Analiz>

табл. 3. Структура построенной модели выглядит следующим образом:

- 1) входной слой;
- 2) скрытый LSTM-слой;
- 3) выходной слой.

Также для трех моделей, показавших лучшие результаты (с наименьшей среднеквадратичной ошибкой *rmse*), были построены графики обучения нейронной сети, графики сравнения прогнозируемых данных и исторических данных.

Для построения сети было использовано программное обеспечение Python и библиотеки *keras*, *pandas*, *numpy*, *sklearn*, *matplotlib*.

Для поддержки вычислений на GPU данные преобразованы к типу *float32*.

Полученные данные были разделены на обучающую и тестовую (1 600 обучающих и 401 тестовая) составляющие. Обучающий набор используется для поиска взаимосвязи между входными и выходными переменными, в то время как тестовые данные оценивает производительность модели. Назначение данных для обучения и для тестов выполняется с использованием случайной выборки.

Важной задачей при построении нейронной сети является правильный подбор функции потерь, оптимизатора и параметров.

Для подбора параметров использовался метод случайного поиска⁶ [17]. Для оценки надежности построенной модели была вычислена среднеквадратическая ошибка (*RMSE*).

Для подбора параметров методом случайного поиска использовали следующие параметры:

- 1) функцию потерь: *Logcosh*, *MAE*, *MSE*, *MSLE*;
- 2) оптимизатор: *SGD*, *Adam*, *Adagrad*, *AdaDelta*, *RMSprop*, *Adamax*, *Nadam*;
- 3) функцию активации: *ELU*, *SELU*, *Softplus*, *Softsign*, *ReLU*, *Tanh*, *Sigmoid*, *Hard sigmoid*, *Linear*.
- 4) количество нейронов в скрытом слое – от 1 до 30;
- 5) количество эпох – от 100 до 500;
- 6) количество данных в одном пакете – от 50 до 300;
- 7) дропаут – от 0 до 20.

Всего было проведено более 200 экспериментов. Результаты 15 лучших проведенных экспериментов представлены в табл. 4.

На рис. 6 приведены графики ошибки вычислений для тестовой и обучающей выборки. В качестве функции приближения выбиралась функция логарифма гиперболического косинуса, количество нейронов равно 16, оптимизатор *Nadam*. Видно, что с ростом количества итераций, погрешность ошибки падает (ошибка для тренировочных и тестовых данных равна $5,652479786606858 \cdot 10^{-5}$ и $7,527783456680481 \cdot 10^{-5}$ соответственно).

На рис. 7 приведены графики самой низкой цены в период времени с 11 февраля 2018 г. по 17 марта 2019 г. и прогнозного значения обученной модели. В качестве целевой функции выбиралась функция логарифма гиперболического косинуса, количество нейронов в скрытом LSTM-слое равно 16, оптимизатор – *Nadam*. Данный график показывает высокую корреляцию между реальными и предсказанными значениями.

Аналогичные результаты характерны и для других входных данных, которые подверглись тестированию в рамках построенных алгоритмов моделирования динамики

metodov-normirovki-raznotipnyh-dannyh-dlya-analiza-v-ekspertnyh-sistemah-medicinskoj-diagnostiki.html

⁶ Кушербаева В.Т., Сушков Ю.А. Статистическое исследование алгоритма случайного поиска. СПб: Изд-во Санкт-Петербургского гос. ун-та, 2007.
URL: https://math.spbu.ru/user/gran/sb3/sushkov_kusher.pdf

развития рынка криптовалюты (на примере биткойна). В частности, тестировались временные статистические ряды, построенные на базе таких биржевых параметров, как:

- самая высокая цена биткойна в анализируемый отрезок времени;
- цена закрытия.

Выводы

Из проведенных экспериментов можно сделать следующие выводы.

Построенная рекуррентная нейронная сеть хорошо подходит для прогнозирования цены валютной пары BTC/USD (это следует из столбца *rmse табл. 4* и приведенных графиков спрогнозированной и действительной стоимости валютной пары BTC/USD).

Уровни ошибки на тренировочной и валидационной выборке показывают, что модель хорошо прогнозирует реальные данные.

Визуально данные выводы хорошо верифицируются на примере графиков, представленных на *рис. 7*. Предсказанные значения с высокой степенью точности демонстрируют сходимость с фактическими значениями анализируемого ряда. При этом следует отметить, что между построенными рядами наблюдаются и некоторые расхождения, однако степень несоответствия укладывается в пределы статистической погрешности. Кроме того, важным является и то, что, как это было заявлено в начале настоящей работы, наблюдаемое несоответствие в системе абсолютных значений фактического и предсказанного

рядов может быть нивелировано на основе построения консенсус-прогнозов, с опорой на иные прогностические подходы и модели. К ним, к примеру, следует отнести модели *ARMA* и *ARIMA*, также продемонстрировавшие по результатам тестирования весьма высокий прогностический потенциал в сфере предвидения биржевых котировок на криптобиржах.

Заключение

В целом полученные результаты во многом свидетельствуют о перспективности выбранного инструментария прогнозирования, основанного на использовании алгоритмов построения LSTM-сети. Однако необходимо отметить, что построенная модель требует своего дальнейшего совершенствования и уточнения, чему и будут посвящены наши дальнейшие направления исследований.

Как показывают результаты тестирования построенных алгоритмов, с высокой долей уверенности можно утверждать, что разработанный на данном этапе исследований инструментарий может представлять практический интерес для инвесторов, осуществляющих свою деятельность на новых рынках цифровых денег. Предлагаемые методические подходы, основанные на использовании методов машинного обучения, в которых применяются искусственные нейронные сети, формирует платформу для реализации прогностических оценок корректировки курса криптовалюты на краткосрочную перспективу. Учитывая высокий уровень волатильности анализируемого рынка, его применение существенным образом может нивелировать риски финансовых потерь инвесторов.

Таблица 1**Распределение стран по уровню легализации рынка криптовалюты****Table 1****Countries broken down by level of the cryptocurrency market**

Уровень легализации рынка криптовалюты	Страна
Разработка нормативно-правовой базы	Япония, Австралия, Нидерланды, Франция, Германия, Италия, Норвегия, Сингапур, Словения, Южная Корея, Испания, Швейцария, Соединенные Штаты Америки, Индия
Отсутствие запрета на операции с криптовалютой	Великобритания, Гонконг, страны Европейского союза, Канада, Китай, Украина, Россия
Криптовалюта считается нелегальной	Бангладеш, Боливия, Эквадор, Исландия, Киргизия

Источник: авторская разработка*Source:* Authoring**Таблица 2****Пример входных данных, раскрывающих информацию о текущем курсе криптовалюты биткойн, BTC/USD****Table 2****The case of input data revealing the current bitcoin exchange rate, BTC/USD**

<i>datetime</i>	<i>low</i>	<i>high</i>	<i>open</i>	<i>close</i>	<i>volumefrom</i>	<i>volumeto</i>
2013-09-24	132,5	136,59	133,4	134,78	8 575,98	11 48 734,45
2013-09-25	134,7	138	134,78	135	9 517,07	1 293 657,92
...
2019-03-16	3 924,98	4 069,11	3 927,08	4 027,01	41 319,81	166 216 280,52
2019-03-17	3 970,97	4 030,38	4 027,01	3 994,18	8 442,71	33 698 596,43

Источник: авторская разработка*Source:* Authoring**Таблица 3****Нормированные данные, раскрывающие информацию о текущем курсе криптовалюты биткойн, BTC/USD****Table 3****The normalized data about the current bitcoin exchange rate, BTC/USD**

<i>datetime</i>	<i>low</i>	<i>high</i>	<i>open</i>	<i>close</i>	<i>volumefrom</i>	<i>volumeto</i>
2013-09-24	0,00218873	0,000232539	0,00113543	0,00120724	0,0157957	0,000150287
2013-09-25	0,00230663	0,000303973	0,00120717	0,00121868	0,0176149	0,000173492
...
2019-03-16	0,205438	0,199462	0,198363	0,20357	0,0790897	0,02658
2019-03-17	0,207903	0,1975	0,203558	0,201863	0,0155381	0,005362

Источник: авторская разработка*Source:* Authoring

Таблица 4
Результаты 15 лучших проведенных экспериментов

Table 4
The outcome of 15 best experiments

<i>loss</i>	<i>activation</i>	<i>optimizer</i>	<i>neurons</i>	<i>epochs</i>	<i>batch_size</i>	<i>dropout</i>	<i>rmse</i>
<i>logcosh</i>	<i>relu</i>	<i>Nadam</i>	16	488	216	17	139,35
<i>logcosh</i>	<i>linear</i>	<i>Nadam</i>	26	310	100	19	139,87
<i>mse</i>	<i>linear</i>	<i>Nadam</i>	6	381	80	3	141,21
<i>mse</i>	<i>linear</i>	<i>Nadam</i>	14	373	80	8	141,34
<i>mae</i>	<i>tanh</i>	<i>AdaDelta</i>	5	494	110	11	141,71
<i>logcosh</i>	<i>tanh</i>	<i>Nadam</i>	30	382	144	0	142,44
<i>mae</i>	<i>linear</i>	<i>Nadam</i>	12	455	123	4	142,48
<i>mse</i>	<i>selu</i>	<i>Nadam</i>	21	231	116	1	142,95
<i>logcosh</i>	<i>selu</i>	<i>Nadam</i>	8	486	115	2	143,25
<i>mse</i>	<i>elu</i>	<i>Nadam</i>	22	449	144	15	143,39
<i>logcosh</i>	<i>elu</i>	<i>RMSprop</i>	10	429	137	17	143,57
<i>msle</i>	<i>linear</i>	<i>Nadam</i>	26	461	116	17	143,67
<i>mse</i>	<i>tanh</i>	<i>RMSprop</i>	17	480	106	9	143,92
<i>msle</i>	<i>tanh</i>	<i>RMSprop</i>	24	460	71	14	143,97
<i>mae</i>	<i>relu</i>	<i>Nadam</i>	16	369	192	16	144,2

Источник: авторская разработка

Source: Authoring

Рисунок 1
Правовое регулирование криптовалют в разных странах

Figure 1
The legal framework for cryptocurrencies across countries



1 - Криптовалютные операции разрешены
 2 - Настороженное отношение


3 - Криптовалютные операции запрещены
 4 - Нет данных

Источник: авторская разработка

Source: Authoring

Рисунок 2
Динамика рынка криптовалюты (на примере биткойна)

Figure 2
Cryptocurrency market trends: The case of bitcoin




Источник: Криптовалютная биржа. URL: <https://blockchain.com/ru>

Source: Cryptocurrency exchange. URL: <https://blockchain.com/ru> (In Russ.)

Рисунок 3
Число транзакций на криптобиржах в день

Figure 3
The number of transactions on cryptocurrency exchanges per day




Источник: Криптовалютная биржа. URL: <https://blockchain.com/ru>

Source: Cryptocurrency exchange. URL: <https://blockchain.com/ru> (In Russ.)

Рисунок 4
Схема многослойного перцептрона

Figure 4
The multilayered perceptron chart

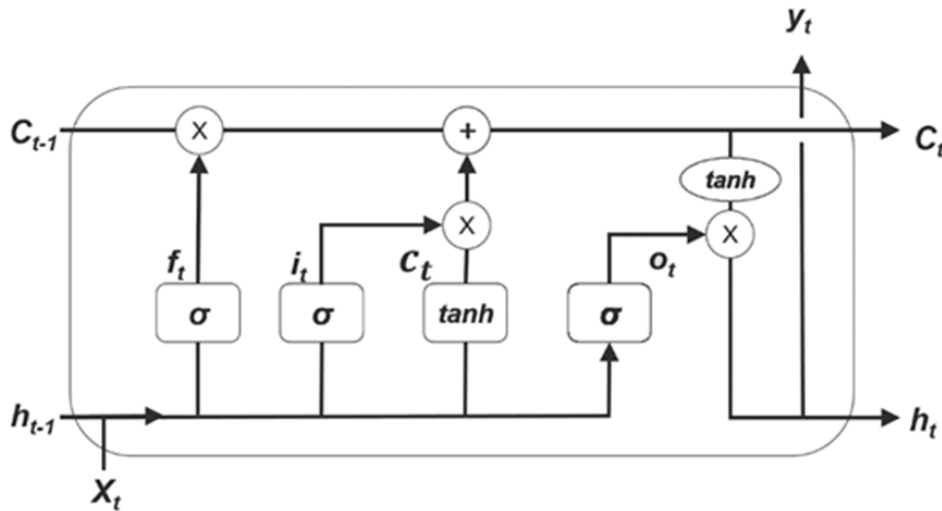


Источник: [15]

Source: [15]

Рисунок 5
Архитектура LSTM-сети

Figure 5
LSTM Network architecture




Источник: Кушербаева В.Т., Сушков Ю.А. Статистическое исследование алгоритма случайного поиска. СПб: Изд-во Санкт-Петербургского гос. ун-та, 2007. URL: https://math.spbu.ru/user/gran/sb3/sushkov_kusher.pdf

Source: Kuserbaeva V.T., Sushkov Yu.A. *Statisticheskoe issledovanie algoritma sluchainogo poiska* [Statistical study of the random search algorithm]. St. Petersburg, SPSU Publ., 2007.

URL: https://math.spbu.ru/user/gran/sb3/sushkov_kusher.pdf (In Russ.)

Рисунок 6
Графики ошибки вычислений для тестовой и обучающей выборки
Figure 6
Charts of computation errors in the case of a test set and training set

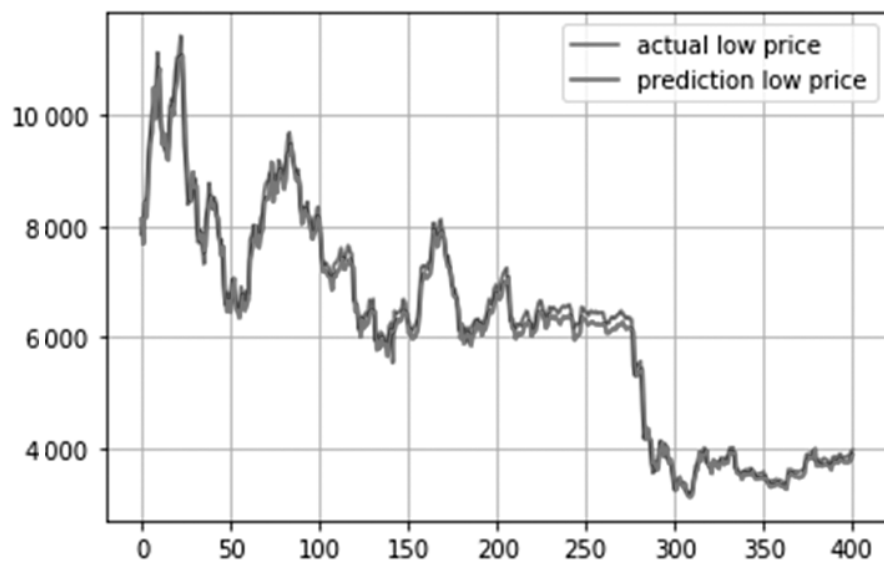


Источник: авторская разработка

Source: Authoring

Рисунок 7
Графики самой низкой действительной и спрогнозированной стоимости биткойна по отношению к доллару в период с 11.02.2018 по 17.03.2019

Figure 7
Charts of the lowest factual and predicted value of bitcoin against USD, February 11, 2018 and March 17, 2019



Источник: авторская разработка

Source: Authoring

Список литературы

1. Сафиуллин М.Р., Ельшин Л.А., Абдукаева А.А. Разработка стохастической модели среднесрочного прогнозирования курса криптовалют (на примере биткоина) // *Финансы и кредит*. 2018. Т. 24. Вып. 5. С. 1046–1060. URL: <https://doi.org/10.24891/fc.24.5.1046>
2. Luther W. Cryptocurrencies, Network Effects, and Switching Costs. *Contemporary Economic Policy*, 2016, vol. 34, iss. 3, pp. 553–571. URL: <https://doi.org/10.1111/coep.12151>
3. Vranken H. Sustainability of Bitcoin and Blockchains. *Current Opinion in Environmental Sustainability*, 2017, vol. 28, pp. 1–9. URL: <https://doi.org/10.1016/j.cosust.2017.04.011>
4. White L.H. The Market for Cryptocurrencies. *Cato Journal*, 2015, vol. 35, no. 2, pp. 383–402. URL: <https://www.cato.org/sites/cato.org/files/serials/files/cato-journal/2015/5/cj-v35n2-13.pdf>
5. Perron P. Further Evidence on Breaking Trend Functions in Macroeconomic Variables. *Journal of Econometrics*, 1997, vol. 80, iss. 2, pp. 355–385. URL: [https://doi.org/10.1016/S0304-4076\(97\)00049-3](https://doi.org/10.1016/S0304-4076(97)00049-3)
6. Wilson M., Yelowitz A. Characteristics of Bitcoin Users: An Analysis of Google Search Data. *Applied Economics Letters*, 2015, vol. 22, iss. 13, pp. 1030–1036. URL: <https://doi.org/10.1080/13504851.2014.995359>
7. Райкова Н.А., Янкина И.А. Перспективы использования в России криптовалюты как платежного инструмента // *Экономика и предпринимательство*. 2016. № 10-1. С. 890–894.
8. Safiullin M.R., El'shin L.A., Abdukaeva A.A. Setting the Stochastic Model for Mid-Term Prediction of Cryptocurrency Exchange Rate: The Bitcoin Case // *Дайджест-финансы*. 2018. Т. 23. Вып. 3. С. 261–273. URL: <https://doi.org/10.24891/df.23.3.261>
9. Сафиуллин М.Р., Абдукаева А.А., Ельшин Л.А. Разработка прогностической модели динамики курса криптовалют с применением инструментов стохастического анализа // *Вестник Института экономики Российской академии наук*. 2018. № 5. С. 161–173. URL: <https://cyberleninka.ru/article/n/razrabotka-prognosticheskoy-modeli-dinamiki-kursa-kriptovalyut-s-primeneniem-instrumentov-stohasticheskogo-analiza/viewer>
10. Сафиуллин М.Р., Ельшин Л.А., Абдукаева А.А. Разработка многофакторной прогностической модели развития глобального рынка криптовалюты // *Теоретическая и прикладная экономика*. 2018. № 3. С. 151–161. URL: <https://doi.org/10.25136/2409-8647.2018.3.27075>
11. Кадури А.А., Николенко С.И., Архангельская Е.В. Глубокое обучение. Погружение в мир нейронных сетей. СПб: Питер, 2018. 480 с.
12. Стрижов В.В. Функция ошибки в задачах восстановления регрессии // *Заводская лаборатория*. 2013. Т. 79. № 5. С. 65–73.
13. Rumelhart D.E., Hinton G.E., Williams R.J. Learning Representations by Back-Propagating Errors. *Nature*, 1986, vol. 323, pp. 533–536. URL: <https://doi.org/10.1038/323533a0>
14. Тормозов В.С. Исследование нейронных сетей памяти // *Ученые заметки ТОГУ*. 2016. Т. 7. № 1. URL: http://pnu.edu.ru/media/ejournal/articles-2016/TGU_7_31.pdf
15. Elman J.L. *Finding Structure in Time*. San Diego, University of California, 1990.

16. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*, 1997, vol. 9, no. 8, pp. 1735–1780. URL: <https://bioinf.jku.at/publications/older/2604.pdf>

17. Bergstra J., Bengio Y. Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*, 2012, vol. 13, pp. 281–305.

URL: <http://jmlr.org/papers/volume13/bergstra12a/bergstra12a.pdf>

Информация о конфликте интересов

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

FORECASTING TRENDS IN THE CRYPTOCURRENCY EXCHANGE RATE THROUGH THE MACHINE LEARNING THEORY

Leonid A. EL'SHIN ^{a,*}, Aizat M. GIL'MANOV ^b, Viktor V. BANDEROV ^c

^a Center for Advanced Economic Research of Academy of Sciences of Republic of Tatarstan, Kazan, Republic of Tatarstan, Russian Federation
Leonid.Elshin@tatar.ru
<https://orcid.org/0000-0002-0763-6453>

^b Institute of Computational Mathematics and Information Technologies, Kazan, Republic of Tatarstan, Russian Federation
ai.9595@mail.ru
ORCID: not available

^c Kazan (Volga) Federal University (KFU), Kazan, Republic of Tatarstan, Russian Federation
Victor.Banderov@kpfu.ru
ORCID: not available

* Corresponding author

Article history:

Article No. 452/2019
Received 26 June 2019
Received in revised form
14 July 2019
Accepted 2 August 2019
Available online
28 February 2020

JEL classification: F47, F63, G17

Keywords: cryptocurrency market, time series, forecasting, machine learning, artificial neural networks, LSTM, Artificial Intelligence

Abstract

Subject The study discusses methodological approaches to forecasting trends in the development of the cryptocurrency market (bitcoin).

Objectives The study aims to discover and explain tools and mechanisms for predicting how the cyptocurrency market may evolve in a short run through time series modeling methods and machine learning methods, which are based on artificial neural networks LSTM.

Methods Using Python-based programming methods, we constructed and substantiated a neural network model for the analyzable series describing how the stock exchange rate of bitcoin develops.

Results Matching loss functions, optimizer and parameters for constructing a neural network that predicts the BTC/USD exchange rate for a coming day, we proved its applicability and feasibility, which is confirmed with the lowest number of errors in the test and validation set.

Conclusions and Relevance The findings mainly prove that the above mechanism is feasible for predicting the cryptocurrency market. The mechanism is based on algorithms for constructing LSTM networks. The approach should be used to analyze and evaluate the current and future parameters of the cryptocurrency market development. The tools can be of interest for investors which operate in new markets of e-money.

© Publishing house FINANCE and CREDIT, 2019

Please cite this article as: El'shin L.A., Gil'manov A.M., Banderov V.V. Forecasting Trends in the Cryptocurrency Exchange Rate Through the Machine Learning Theory. *Financial Analytics: Science and Experience*, 2020, vol. 13, iss. 1, pp. 97–113.
<https://doi.org/10.24891/fa.13.1.97>

Acknowledgments

The article was prepared as part of scientific project № 18-010-00536 supported by the Russian Foundation for Basic Research (RFBR).

We are thankful to researchers of the Kazan (Volga) Federal University who participate in scientific project № 19-18-00202 of the Russian Science Foundation for their assistance in the preparation of this publication.

References

1. Safiullin M.R., El'shin L.A., Abdukaeva A.A. [Developing a stochastic model for medium-term forecasting of cryptocurrency exchange rate: The bitcoin case]. *Finansy i kredit = Finance and Credit*, 2018, vol. 24, iss. 5, pp. 1046–1060. (In Russ.)
URL: <https://doi.org/10.24891/fc.24.5.1046>
2. Luther W. Cryptocurrencies, Network Effects, and Switching Costs. *Contemporary Economic Policy*, 2016, vol. 34, iss. 3, pp. 553–571. URL: <https://doi.org/10.1111/coep.12151>
3. Vranken H. Sustainability of Bitcoin and Blockchains. *Current Opinion in Environmental Sustainability*, 2017, vol. 28, pp. 1–9. URL: <https://doi.org/10.1016/j.cosust.2017.04.011>
4. White L.H. The Market for Cryptocurrencies. *Cato Journal*, 2015, vol. 35, no. 2, pp. 383–402. URL: <https://cato.org/sites/cato.org/files/serials/files/cato-journal/2015/5/cj-v35n2-13.pdf>
5. Perron P. Further Evidence on Breaking Trend Functions in Macroeconomic Variables. *Journal of Econometrics*, 1997, vol. 80, iss. 2, pp. 355–385. URL: [https://doi.org/10.1016/S0304-4076\(97\)00049-3](https://doi.org/10.1016/S0304-4076(97)00049-3)
6. Wilson M., Yelowitz A. Characteristics of Bitcoin Users: An Analysis of Google Search Data. *Applied Economics Letters*, 2015, vol. 22, iss. 13, pp. 1030–1036. URL: <https://doi.org/10.1080/13504851.2014.995359>
7. Raikova N.A., Yankina I.A. [Perspective use cryptocurrency as a payment instrument in Russia]. *Ekonomika i predprinimatel'stvo = Journal of Economy and Entrepreneurship*, 2016, no. 10-1, pp. 890–894. (In Russ.)
8. Safiullin M.R., El'shin L.A., Abdukaeva A.A. Setting the Stochastic Model for Mid-Term Prediction of Cryptocurrency Exchange Rate: The Bitcoin Case. *Daidzhest-Finansy = Digest-Finance*, 2018, vol. 23, iss. 3, pp. 261–273. URL: <https://doi.org/10.24891/df.23.3.261>
9. Safiullin M.R., Abdukaeva A.A., El'shin L.A. [Development of a predictive model for the dynamics of the exchange rates of the cryptocurrencies using stochastic analysis tools]. *Vestnik Instituta ekonomiki Rossiiskoi akademii nauk = Bulletin of Institute of Economics of Russian Academy of Sciences*, 2018, no. 5, pp. 161–173. URL: <https://cyberleninka.ru/article/n/razrabotka-prognosticheskoy-modeli-dinamiki-kursa-kriptovalyut-s-primeneniem-instrumentov-stohasticheskogo-analiza/viewer> (In Russ.)
10. Safiullin M.R., El'shin L.A., Abdukaeva A.A. [Development of a multi-factor predictive model for the development of a global cryptocurrency market]. *Teoreticheskaya i prikladnaya ekonomika = Theoretical and Applied Economics*, 2018, no. 3, pp. 151–161. (In Russ.)
URL: <https://doi.org/10.25136/2409-8647.2018.3.27075>
11. Kadurin A.A., Nikolenko S.I., Arkhangel'skaya E.V. *Glubokoe obuchenie. Pogruzhenie v mir neironnykh setei* [Deep learning. Immersion in the world of neural networks]. Saint Petersburg, Piter Publ., 2018, 480 p.
12. Strizhov V.V. [The error function in the regression recovery problems]. *Zavodskaya laboratoriya = Industrial Laboratory. Diagnostics of Materials*, 2013, vol. 79, no. 5, pp. 65–73. (In Russ.)
13. Rumelhart D.E., Hinton G.E., Williams R.J. Learning Representations by Back-Propagating Errors. *Nature*, 1986, vol. 323, pp. 533–536. URL: <https://doi.org/10.1038/323533a0>
14. Tormozov V.S. [Neural memory network research]. *Uchenye zametki TOGU*, 2016, vol. 7, no. 1. (In Russ.) URL: http://pnu.edu.ru/media/ejournal/articles-2016/TGU_7_31.pdf

15. Elman J.L. *Finding Structure in Time*. San Diego, University of California, 1990.
16. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*, 1997, vol. 9, no. 8, pp. 1735–1780. URL: <https://bioinf.jku.at/publications/older/2604.pdf>
17. Bergstra J., Bengio Y. Random Search for Hyper-Parameter Optimization. *Journal of Machine Learning Research*, 2012, vol. 13, pp. 281–305.
URL: <http://jmlr.org/papers/volume13/bergstra12a/bergstra12a.pdf>

Conflict-of-interest notification

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