

## АНАЛИЗ ПРОБЛЕМ ПРОГНОЗИРОВАНИЯ ФИНАНСОВЫХ ИНСТРУМЕНТОВ НА ФОНДОВЫХ РЫНКАХ

Круглов А. И., Пирог М. В.

### 1. Введение

Благодаря стремительному развитию информационных технологий появилась возможность за считанные секунды проводить анализ большого объёма информации, строить сложные математические модели, решать задачи многокритериальной оптимизации. Учёные, занимающиеся вопросами циклического развития экономики, стали разрабатывать теории, полагая, что отслеживание тенденций ряда экономических переменных позволит прояснить и предсказать периоды подъёма и спада. Одним из объектов для изучения был выбран фондовый рынок. Предпринимались многократные попытки построить такую математическую модель, которая успешно бы решала задачу прогнозирования цены финансовых инструментов [1]. В частности, широкое распространение получил «технический анализ». Актуальность данного исследования заключается в том, что на данный момент при темпах развития мировой экономики, фондовых и валютных рынков появилось много методов прогнозирования. В данной работе автор выявляет наиболее точные из них на основании ряда изученных работ и построенных аналитических моделей.

### 2. Объект исследования и его технологический аудит

*Объектом исследования являются процессы прогнозирования финансовых инструментов на фондовых рынках в условиях неопределенности. Высокая степень неопределенности на фондовых рынках значительно усложняет процесс прогнозирования динамики финансовых инструментов. Данная проблема имеет значение как для государств, так и для инвестиционных компаний, а также прочих участников рынка, которым необходимо принимать долгосрочные инвестиционные решения, основанные на превентивных мерах по снижению влияния рисков финансовых кризисов на их деятельность.*

Одним из наиболее проблемных мест в прогнозировании является слабая прогностическая способность моделей. Сезонность, трендовость и нестационарность процесса прогнозирования, что приводит к неверным результатам.

### 3. Цель и задачи исследования

*Цель исследования – выявить существующие проблемы прогнозирования финансовых инструментов на фондовых рынках.*

Для достижения поставленной цели необходимо выполнить такие задачи:

1. Провести анализ существующих методов прогнозирования и выявить, какие проблемы в них присутствуют.
2. Предложить решения этих проблем.

#### **4. Исследование существующих решений проблемы**

Разные авторы предлагают многочисленные, отличные друг от друга, модели по прогнозированию числовых рядов. Однако многие из предлагаемых инструментов непригодны для прогнозирования динамики финансовых инструментов по причине нестационарности данного процесса согласно тесту Дики-Фуллера. В этом ключе стоит выделить регрессионные модели прогнозирования [1], авторегрессионные и прочие производные от них [2]. Ключевая проблема данных методов заключается в следующем: упомянутые модели основаны на допущении, что элементы прогнозирования не коррелируют и нормально распределены. Если это допущение в действительности неверно, то значительно возрастает риск ошибочности прогноза.

Некоторые методы (модели на цепях Маркова [3] и модели экспоненциального сглаживания [1]) способны выдавать адекватный прогноз лишь на временных интервалах небольшого значения, что делает их малоэффективными в долгосрочном прогнозировании. Они также непригодны при прогнозировании на большие периоды времени, поскольку они не учитывают такие важные показатели, как тренды и сезонность.

Такой метод, как модель по выборке максимального подобия [3], а также некоторые другие, аналогичные ей, в принципе не подходят для прогнозирования финансовых инструментов.

Главная же проблема нейросетевого прогнозирования согласно работам [4, 5] такова, что предположения меняются очень быстро на протяжении малого временного отрезка, и это превращает потенциально хорошие прогностические модели в бесполезные. Основополагающие причины данного превращения: переобучаемость нейросетей, переменные показатели воздействия и, в особенности, игнорирование нейросетями нестационарных характеристик в данных по финансовому инструменту.

Для решения данной проблемы экономфизика предлагает использовать стохастическую атомарную [1] и квантовую [6] системы, которые способны прогнозировать совместное влияние индивидуальных участников торгов на ценообразование, рассматривая их в качестве частиц. Моделирование и прогнозирование поведения участников рынка как индивидуальных агентов позволяет минимизировать смещение оценок динамики финансового инструмента и улучшить существующие прогностические модели и методологии. Так, в исследовании [7] используются мультиагентные технологии для прогнозирования динамики цен акций. Однако, авторы этих исследований не применяют технологию нейросетей, поэтому повысить сложность торговых стратегий агентов представляется невозможным. Они, как и в работах [4, 8], используют данную технологию как сигнальную систему для помощи участникам фондовых рынков.

В работах [4, 5] используют генетические алгоритмы для формирования стратегий индивидуальных агентов. Однако их подход состоит преимущественно в отборе наиболее приспособленных индивидов, исходя из доходности стратегий, заменяя исходную популяцию на популяцию более

приспособленных агентов. Далее предполагаем необходимость моделирования также и убыточных стратегий, поскольку все участники торгов не могут одновременно зарабатывать и необходимо учитывать негативный отбор.

Разработки, на которые ссылаются авторы многих научных работ, либо не опубликованы, либо опубликованы без исходного кода, либо имеют существенные конструктивные ограничения, что не позволяет осуществлять их дальнейшее развитие [9, 10].

Таким образом, результаты литературного анализа позволяют сделать вывод о том, что данная проблема не является полностью изученной, и поэтому авторами работы решено более подробно изучить эту проблему, на основании уже существующих работ.

## 5. Методы исследований

При исследовании были использованы следующие научные методы:

- метод анализа при изучении ряда научных работ и статей по проблемам прогнозирования финансовых инструментов на фондовых рынках;
- метод классификации при изучении методов прогнозирования

## 6. Результаты исследования

Методы прогнозирования регрессионного типа требуются, чтобы исследовать корреляцию между более чем двумя переменными. Известными регрессивными моделями можно назвать следующие.

Простая линейная регрессия (*linear regression*). Основанием модели служит гипотеза о наличии некого дискретного внешнего фактора ( $t$ ), под доминирующим влиянием которого находится весь анализируемый процесс ( $t$ ), при линейном типе связи. Следующее уравнение описывает данную зависимость [10]:

$$Z(t) = \alpha_0 + \alpha_1 X(t) + \varepsilon t,$$

где  $\alpha_0$  и  $\alpha_1$  – коэффициенты регрессии;  $\varepsilon t$  – модельная ошибка.

Чтобы получить значения прогноза  $Z(t)$  на временной отрезок  $t$ , необходимо иметь значение  $X(t)$  на тот же временной отрезок  $t$ , но в реальности это встречается нечасто.

*Множественная регрессия (multiple regression).* В действительности же многочисленные дискретные внешние факторы  $X_1(t)$ , ...,  $X_s(t)$  оказывают значительно влияние на процесс  $Z(t)$ . Тогда уравнение модели будет таким:

$$Z(t) = \alpha_0 + \alpha_1 X_1(t) + \alpha_2 X_2(t) + \dots + \alpha_s X_s(t) + \varepsilon t.$$

Однако и этот метод имеет весомую слабую сторону. А именно, будущее значение процесса  $Z(t)$  можно будет вычислить лишь после определения будущих значений всех факторов  $X_1(t)$ , ...,  $X_s(t)$ , что крайне редко удается сделать в реальности.

*Нелинейная регрессия (nonlinear regression).* Фундаментом этой модели служит гипотеза о наличии функции, которая подтверждает наличие корреляции между исходным процессом  $Z(t)$  и неким внешним фактором  $X(t)$ . Функция такой модели имеет вид:

$$Z(t)=F(X(t), A).$$

Чтобы построить данный тип модели, прежде всего следует вычислить параметры функции  $A$ . Тогда сделаем предположение, согласно которому:

$$Z(t)=\alpha_1 \cos(X(t))+\alpha_0.$$

Исходя из этого, зададим параметры  $A=[\alpha_1, \alpha_0]$ . Большой редкостью можно назвать реальные процессы, согласно которым уже заблаговременно определен тип связи, объединяющей процесс  $Z(t)$  и внешний фактор  $X(t)$ . Именно из-за этого факта применение нелинейных регрессионных моделей крайне ограничено, и в практике деятельности на фондовом рынке такие методы используется сравнительно нечасто.

Наиболее широко применяемыми справедливо являются тесты Дики-Фуллера [1]. Метод оценки временного ряда на предмет интегрируемости представлен формулой:

$$Y_t=a_1 \cdot Y_{t-1}+\varepsilon_t.$$

Основная идея этого метода такова: следует проверить факт стационарности процесса, то есть подтвердить либо опровергнуть соответствующую гипотезу, и также поочередно проверить его разности порядка, с трендом на повышение.

Тесты типа DF-теста содержат в себе существенный недостаток, а именно: они не предусматривают вероятную остаточную автокорреляцию. Однако если в остатках все же прослеживается автокорреляция, итоги метода наименьших квадратов могут стать недостоверными [11]. В работе [12] видно, что правая половина уравнения снабжена новыми переменными, а именно, лаговыми значениями, перенеся их из левой половины. Тогда уравнение будет иметь вид:

$$\Delta Y_t=a_1 \cdot Y_{t-1}+\sum_{i=1}^k a_i+1 \cdot \Delta Y_{t-i}+\varepsilon_t.$$

Этот тест имеет название общий тест Дики-Фуллера (ADF-тест). Важно подчеркнуть, что это наиболее продуктивный и самый распространенный из простых тестов на интегрируемость [13].

*Авторегрессионные модели прогнозирования.* В работе [1] обосновано, что форма авторегрессии считается крайне полезной с целью определения существующих в реальности временных рядов. Модификация отводит

ключевую роль процесса конечной линейной совокупности предшествующих значений процесса и импульса, которая именуется «белым шумом». Уравнение такой функции представлено как:

$$Z(t) = C + \varphi_1 Z(t-1) + \varphi_2 Z(t-2) + \dots + \varphi_p Z(t-p) + \varepsilon_t,$$

где процесс авторегрессии порядка  $p$ , обозначаемый как  $AR(p)$ , при этом  $C$  – вещественная константа,  $\varphi_1, \dots, \varphi_p$  – коэффициенты,  $\varepsilon_t$  – модельная ошибка. Чтобы определить  $\varphi_i$  и  $C$ , целесообразно применить метод максимального правдоподобия или же стандартный метод наименьших квадратов. Общую же модель зачастую именуют как ARMA.

Модель  $ARIMA(p,d,q)$  имеет несколько модификаций, одна из которых  $ARIMAX(p,d,q)$ , уравнение которой представлено как [1]:

$$Z(t) = AR(p) + a_1 X_1(t) + \dots + a_s X_s(t),$$

где  $a_1, \dots, a_s$  – коэффициенты внешних факторов  $X_1(t), \dots, X_s(t)$ . Зачастую  $Z(t)$  определяется как итог расчета по модели  $MA(q)$ . После этого дальнейшее прогнозное значение  $Z(t)$  определяется моделью авторегрессии. Она содержит еще и регрессоры внешних факторов  $X_1(t), \dots, X_s(t)$ , как уточняющее дополнение.

Авторегрессионная модель с условной гетероскедастичностью Т. П. Борреслева в сущности является моделью остатков для метода  $AR(p)$  [12]. Сначала определяем модель  $AR(p)$  для необходимого ряда. Затем ссылаемся на допущение, что ошибка модели  $\varepsilon_t$  имеет составляющие:

$$\varepsilon_t = \sigma_t \cdot \vartheta_t,$$

где  $\sigma_t$  – стандартное отклонение, зависимое от показателя времени;  $\vartheta_t$  – случайная величина с нормальным распределением, среднее значение 0 (нуль), и стандартное отклонение 1 (единица).

Величину стандартного отклонения рассчитаем по формуле:

$$\sigma_t^2 = \beta_0 + \beta_1 \varepsilon_{t-1}^2 + \dots + \beta_q \varepsilon_{t-q}^2 + \gamma_1 \sigma_{t-1}^2 + \dots + \gamma_p \sigma_{t-p}^2,$$

где  $\beta_0, \dots, \beta_q$  и  $\gamma_0, \dots, \gamma_p$  являются коэффициентами. Модель  $GARCH(p,q)$  включает 2 показателя:  $p$  – порядок авторегрессии квадратов остатков;  $q$  – число предшествующих оценок остатков. Использование этого метода особенно распространено в сфере финансов, поскольку ее с успехом применяют в случае необходимости моделирования волатильности. Существует множество модификаций метода GARCH – это и модель NGARCH, и EGARCH, и пр. Все они включают допущение о некоррелированности нормальному распределению остатков. Если хотя бы одно из данных предположений неверно, тогда возникает риск, что интервалы прогноза будут ошибочными.

*Модели экспоненциального сглаживания (ES) Prajakta S.K.* Это в определенной степени модели фильтра, через который проходят члены исходного ряда, а в итоге получаются текущие значения экспоненциальной средней, что задается уравнением:

$$Z(t)=S(t)+\varepsilon t \quad S(t)=\alpha \cdot Z(t-1)+(1-\alpha) \cdot S(t-1),$$

где  $S(t)$  – значение экспоненциальной средней в момент  $t$ ;  $\varepsilon t$  – белый шум;  $\alpha$  – параметр сглаживания, в котором  $0 < \alpha < 1$ .

Модель показывает адекватные результаты на малом горизонте прогнозирования, поскольку упускает из вида тренд и изменения сезонного характера. С другой стороны, упомянутые факторы можно учесть, используя:

- модель Хольта, которая базируется на линейном тренде;
- модель Хольта-Уинтерса, которая учитывает и сезонность, и мультипликативный экспоненциальный тренд;
- модель Тейла-Вейджа, использующую данные аддитивные линейный тренд и сезонность.

Достоинства данных моделей состоят в относительной простоте проектирования и анализа, а также единобразии, позволяющем упорядочить процесс расчетов и проводить сравнения. Ключевым недостатком этого класса моделей следует назвать негибкость [14]. И все же, именно этот класс моделей прогнозирования получил наибольшее распространение в случае, когда возникает необходимость расчета на долгосрочный период [15].

*Модель по выборке максимального подобия (MMSP).* Данная модель действительно может быть эффективна, но только в ограниченном диапазоне применения. Важно пояснить, что к рядам бирж, в том числе FOREX, применять ее нецелесообразно, поскольку, в таком случае, согласно исследованиям, она работает малоэффективно [16].

*Модель на нейронных сетях (ANN)* подразумевает, что для описания модели нейрона необходимы 2 функции:

$$U(t)=\sum \omega_i \cdot Z(t-i)+b, \quad i=1,$$

$$Z(t)=\varphi(U(t)),$$

где  $\omega_1, \dots, \omega_m$  – синаптические веса нейрона;  $Z(t-i), \dots, Z(t-m)$  – входные сигналы;  $(U(t))$  – функция активации;  $b$  – порог.

Нейроны используют разные типы связей, поэтому в научной литературе принято различать три вида сети: рекуррентные сети, однослойные сети и многослойные сети [17].

Главное преимущество таких моделей – отсутствие линейности, так как они могут связывать текущие и будущие показатели нелинейной зависимостью. К достоинствам нейронных сетей традиционно относят высокие показатели адаптивности, масштабируемость (ведь структура ANN, построенная на принципе параллельности, позволяет ускорить проведение расчетов) и единобразие [18].

И все же, модели ANN преисполнены многочисленными слабостями: неоднозначность алгоритма выбора целесообразной архитектуры; непрозрачность процесса моделирования. Отдельно необходимо подчеркнуть сложность удовлетворения требованиям обучающей выборки, которая подразумевает непротиворечивость, отсюда и затруднения при определении целесообразности использования того или иного алгоритма, а также дороговизна и ресурсоемкость обучаемого процесса [17].

*Модель на цепях Маркова* – эффективный способ прогнозирования стоимости акций, но для получения лучших результатов необходимо создать достаточно большие интервалы, небольшой период времени.

В сущности, теория Маркова представляется собой лишь упрощенную модель сложного процесса принятия решений. Структура цепи Маркова и вероятности перехода состояний являются основополагающими факторами при определении типа взаимосвязи между текущим и будущим значениями анализируемого процесса.

Сильная сторона этих моделей состоит в относительной простоте анализа и моделирования. Слабая же сторона модели на цепях Маркова состоит в том, что их невозможно использовать при моделировании процессов с характеристиками длинной памяти [17].

*Модель классификационно-регрессионного дерева (CART)*. Такой метод разрабатывает модель процессов, находящихся под влиянием непрерывных внешних и категориальных факторов. При условии непрерывности внешних факторов целесообразно использовать регрессионные деревья. И наоборот, для категориальных факторов лучше применять классификационный тип ветвления. Существуют также и смешанные модели CART, при необходимости позволяющие учитывать все упомянутые факторы.

Очевидными сильными сторонами данных моделей являются:

- высокая скорость и прозрачность процесса обучения дерева, что, например, выгодно отличает их от моделей ANN [18];
- масштабируемость, благодаря которой происходит быстрая обработка крупных массивов данных и открывается возможность использовать категориальные внешние факторы.

Слабые стороны моделей CART:

- непрозрачность процесса формирования структуры дерева;
- отсутствие единообразия;
- невозможность однозначности выбора времени и этапа прекращения дальнейшего ветвления (разрастания) дерева [18].

*Метод опорных векторов (SVM)* активно применяется в сфере электроэнергетики для моделирования будущей динамики стоимости электричества [19]. Модель базируется на классификации таким способом, что в пространство высокой размерности переходят исходные временные ряды. Как итог, на фазе обучения становится возможным однозначно определить внешние факторы, на будущие значения которых необходимо будет ссылаться при распределении прогнозов  $Z(t)$  по подклассам.

*Модель на основе передаточных функций (TF)* используется при прогнозировании процесса  $Z(t)$ , учитывая внешний фактор  $X(t)$  [19]. Зависимость будущего значения определяется как:

$$Z(t)=v(B)X(t)+\eta(t),$$

где  $B$  – оператор сдвига  $BZ(t)=Z(t-1), \dots, BkZ(t)=(t-k)$ .

Отрезок времени  $\eta(t)$  характеризует возмущение извне. Тогда функция  $v(B)$  имеет вид:

$$Z(t)=\alpha_0+\alpha_1X(t)+\varepsilon t.$$

Коэффициенты функции  $vi$  определяют отношения между процессами  $Z(t)$  и  $X(t)$  как динамические.

Всевозможные сочетания (нечеткая логика + ANN, SARIMA + ANN, регрессия + ANN и т. д.) также анализируются в обзоре методов по прогнозу объема энергопотребления [20].

ANN-модели при различных комбинациях эффективно используются в целях кластеризации. В научном труде [20] автор упоминает, что комбинированные модели целесообразно считать в наибольшей степени перспективными. Модели способны выполнять первичную кластеризацию и дальнейшее прогнозирование в контексте конкретного кластера.

Авторы работы [21] подчеркивают: кластеризацию, как метод, необходимо использовать, чтобы увеличить прогностическую точность и уменьшить вероятность ошибки. Кластеризация осуществляется по методам  $K$ -средних и нечетких  $C$ -средних. Целью обоих методов является увеличение точности прогноза, чего удается добиться благодаря извлечению необходимой информации из временного ряда.

*Модели на основе мультиагентных систем.* Агентный подход применим при необходимости анализа многокомпонентных самоорганизующихся процессов, которые характерны для целого ряда прикладных областей и характеризуются как сложные. Однако процесс разработки подобной системы представляется нетривиальным и даже затруднительным, поскольку агент имеет свойства независимости и автономности от общей системы. Агент склонен совершать целенаправленные действия, контактировать с другими агентами, принимать решения, адаптировать к среде, совершать перемещения и т. п.

*Модели на основе экономфизики.* Эконофизические модели и их подходы отличаются от традиционных эконометрических методов обширным применением графических рисунков. Но на практике оказывается, что в некоторых ситуациях это может привести к ошибкам, так как такой подход не дает возможности обнаружить особенности исследуемых данных.

По некоторым причинам ряд ученых отмечают модель Лакса-Марчези как наиболее эффективную [21].

В ней представлены три категории участников фондового рынка:

- представители фундаментального анализа, которые приобретают акции при снижении их цены ниже того уровня, который определяет долгосрочные факторы;
- представители технического анализа (или «пессимисты»), которые продают акции при увеличении котировок для фиксации дохода;
- представители технического анализа (или «оптимисты»), которые покупают акции исключительно при их подъеме.

Данная модель основана на понятии статистической физики о взаимодействии элементов под воздействием внутренних условий системы.

Модель составляет вероятности перемещения представителей одной категории участников рынка в прочие группы, при этом доход от реализации стратегий формирует функции переходов. Динамика котировок зависит от соотношений спроса всех трех категорий участников рынка. Данная модель подразумевает, что прочное положение рынка может наступить уже после значимых колебаний, когда уменьшается число последователей технического анализа и, в свою очередь, пополняются ряды сторонников фундаментального анализа. При этом модель Лакса-Марчези исходит из стабильности числа акций, доступных на рынке.

С конца 1980-ых гг., многие ученые стремились найти решение проблемы прогнозирования динамики финансовых инструментов на фондовых рынках [16]. Вопреки этому и несмотря на большое число работ по данной тематике, обнаруживается крайне незначительное число реальных проектов, при моделировании рынка применяющих мультиагентный подход.

В действительности, наличие единственно четко установленного подхода не наблюдается ни в одном из типов анализируемых моделей и методов. Но и разрабатывать и создавать мультиагентные модели под каждую определенную задачу – неэффективно. Причина этого состоит в том, что представляемая модель может управляться некоторым количеством эвристик, которые нельзя ни формально обосновать, ни допустить до стадии имитационного прогона. По ходу процесса моделирования, методы вывода, действия и система взаимного обмена информацией между агентами могут уточняться на регулярной основе.

Решением данной проблемы может стать развитие имитационного моделирования. Однако данная цель небезосновательно считается еще более сложной и затратной, в частности, в рамках агентного моделирования.

По словам некоторых авторов, все же достаточно эффективными можно считать оптимизационные методы, теорию графов и системы на основе нейронных сетей. Но тот же нейросетевой аспект нельзя считать в полной мере оптимальным и учитывающим все необходимые факторы [22].

В итоге, существующие решения указывают на то, что данная проблема является либо частично решенной, либо отсутствует практическая реализация. Очевидна необходимость использования технологий нейросетей для моделирования комплексных стратегий индивидуальных агентов, исключения псевдо-случайных, манипулятивных событий и как следствие – повышения прогностической способности.

На сегодняшний день, согласно исследованиям [23], основные сложности в прогнозировании числовых рядов представляют:

- отсутствие стационарности процесса;
- игнорирование тренда и сезонности;
- малый интервал прогнозирования;
- игнорирование стратегий отдельных участников рынка.

Был выполнен обзор наиболее практически используемых инструментов по прогнозированию финансовых инструментов. Рассмотрены сильные и слабые стороны каждой из рассматриваемых моделей. Отмечено, что на текущем этапе развития оценки динамики и прогнозирования фондовых инструментов наиболее широко используемыми методами являются нейросетевые модели (ANN), а также авторегрессионные модели (ARIMA).

## **7. SWOT-анализ результатов исследований**

*Strengths.* В ходе исследования выявлены решения проблем прогнозирования финансовых инструментов на фондовых рынках, которые позволяют повысить прогностическую способность существующих решений. А также предсказать финансовые кризисы и подготовить превентивные меры для их устранения либо смягчения.

*Weaknesses.* Выявленные в работе решения пока не имеют под собой практической почвы.

*Opportunities.* Прогнозирование может стать более точным ввиду того, что учитываются разнородные стратегии всех участников торгов. Это положительно скажется на экономическом развитии фондовых рынков.

*Threats.* Технологические методы могут давать сбой, который повлечёт за собой дальнейшие неправильные решения, также технологические методы могут быть подвергнуты внешним атакам.

## **8. Выводы**

1. Выявлены основные проблемы прогнозирования динамики финансовых инструментов, такие как: неточность моделирования и проблема нестационарности процесса. Показано, что дополнительную сложность прогнозирования на большие временные интервалы составляют трендовость и сезонность процесса.

2. Для повышения прогностической способности предлагается моделировать динамику финансовых инструментов при помощи мультиагентных систем. Это позволит учесть стратегии всех участников торгов в совокупности и тем самым повысить предсказательную способность.

## **Литература**

1. Астахова, Н. Н., Демидова, Л. А. (2015). Метод прогнозирования групп временных рядов с применением алгоритмов кластерного анализа. *Прикаспийский журнал: управление и высокие технологии*, 2, 59–79.
2. Keskin, M., Deviren, B., Kocakaplan, Y. (2011). Topology of the correlation networks among major currencies using hierarchical structure methods. *Physica A: Statistical Mechanics and Its Applications*, 390 (4), 719–730. doi: <https://doi.org/10.1016/j.physa.2010.10.041>

3. Nobi, A., Lee, S., Kim, D. H., Lee, J. W. (2014). Correlation and network topologies in global and local stock indices. *Physics Letters A*, 378 (34), 2482–2489. doi: <https://doi.org/10.1016/j.physleta.2014.07.009>
4. Roy, R. B., Sarkar, U. K. (2011). Identifying influential stock indices from global stock markets: A social network analysis approach. *Procedia Computer Science*, 5, 442–449. doi: <https://doi.org/10.1016/j.procs.2011.07.057>
5. Lü, L., Zhou, T. (2011). Link prediction in complex networks: A survey. *Physica A: Statistical Mechanics and Its Applications*, 390 (6), 1150–1170. doi: <https://doi.org/10.1016/j.physa.2010.11.027>
6. Armstrong, J. S., Brodie, R. J. (1999). Forecasting for Marketing. *Quantitative Methods in Marketing*, 92–120.
7. Andreas, J., Rohrbach, M., Darrell, T., Klein, D. (2016). Neural Module Networks. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. doi: <https://doi.org/10.1109/cvpr.2016.12>
8. Тихонов, Э. Е. (2006). *Методы прогнозирования в условиях рынка*. Невинномысск, 221.
9. Tumminello, M., Lillo, F., Mantegna, R. N. (2010). Correlation, hierarchies, and networks in financial markets. *Journal of Economic Behavior & Organization*, 75 (1), 40–58. doi: <https://doi.org/10.1016/j.jebo.2010.01.004>
10. Bessec, M., Fouquau, J., Meritet, S. (2015). Forecasting electricity spot prices using time-series models with a double temporal segmentation. *Applied Economics*, 48 (5), 361–378. doi: <https://doi.org/10.1080/00036846.2015.1080801>
11. Aue, A., Horváth, L., F. Pellatt, D. (2016). Functional Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Time Series Analysis*, 38 (1), 3–21. doi: <https://doi.org/10.1111/jtsa.12192>
12. Словарь современной экономической теории Макмиллана (2003). М.: Инфра-М, 21.
13. Ben Taieb, S., Huser, R., Hyndman, R. J., Genton, M. G. (2016). Forecasting Uncertainty in Electricity Smart Meter Data by Boosting Additive Quantile Regression. *IEEE Transactions on Smart Grid*, 7 (5), 2448–2455. doi: <https://doi.org/10.1109/tsg.2016.2527820>
14. Beran, J., Feng, Y., Ghosh, S., Kulik, R. (2013). *Long-Memory Processes*. Springer, 884. doi: <https://doi.org/10.1007/978-3-642-35512-7>
15. Nowotarski, J., Weron, R. (2014). Computing electricity spot price prediction intervals using quantile regression and forecast averaging. *Computational Statistics*, 30 (3), 791–803. doi: <https://doi.org/10.1007/s00180-014-0523-0>
16. Gontis, V., Havlin, S., Kononovicius, A., Podobnik, B., Stanley, H. E. (2016). Stochastic model of financial markets reproducing scaling and memory in volatility return intervals. *Physica A: Statistical Mechanics and Its Applications*, 462, 1091–1102. doi: <https://doi.org/10.1016/j.physa.2016.06.143>
17. Hu, R., Wen, S., Zeng, Z., Huang, T. (2017). A short-term power load forecasting model based on the generalized regression neural network with decreasing step fruit fly optimization algorithm. *Neurocomputing*, 221, 24–31. doi: <https://doi.org/10.1016/j.neucom.2016.09.027>

18. Vandewalle, N., Brisbois, F., Tordoir, X. (2018). Non-random topology of stock markets. *Quantitative finance*, 1, 372–374.
19. Mantegna, R. N. (1999). Hierarchical structure in financial markets. *The European Physical Journal B*, 11 (1), 193–197. doi: <https://doi.org/10.1007/s100510050929>
20. Rahman, M. H., Salma, U., Hossain, M. M., Khan, M. T. F. (2016). Revenue forecasting using holt–winters exponential smoothing. *Research & Reviews: Journal of Statistics*, 5, 19–25.
21. Levin, D., Peres, Y. (2017). Markov chains and mixing times. *American Mathematical Society*. doi: <https://doi.org/10.1090/mhk/107>
22. Wang, L., Zeng, Y., Chen, T. (2015). Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. *Expert Systems with Applications*, 42 (2), 855–863. doi: <https://doi.org/10.1016/j.eswa.2014.08.018>
23. Zhang, Z., Brand, M. (2017). Convergent block coordinate descent for training tikhonov regularized deep neural networks. *31st Conference on Neural Information Processing Systems (NIPS 2017)*. Available at: <https://papers.nips.cc/paper/6769-convergent-block-coordinate-descent-for-training-tikhonov-regularized-deep-neural-networks.pdf>