

УДК 004.8

DOI 10.34822/1999-7604-2021-3-30-40

## **СРАВНИТЕЛЬНЫЙ АНАЛИЗ РАЗЛИЧНЫХ МЕТОДОВ ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ ПРОИЗВОДСТВЕННЫХ ПОКАЗАТЕЛЕЙ ПРЕДПРИЯТИЯ НА ПРИМЕРЕ ЗАДАЧИ ВЫДАЧИ ДЕНЕЖНЫХ СРЕДСТВ В БАНКОМАТЕ КРЕДИТНОЙ ОРГАНИЗАЦИИ**

**К. Ш. Багаутдинов**

*Российский государственный университет нефти и газа  
(национальный исследовательский университет) им. И. М. Губкина, Москва, Россия  
E-mail: bagautdinov@asugubkin.ru*

Рассмотрена актуальная проблема обслуживания автоматизированных депозитных машин и банкоматов кредитных организаций. Решение задачи прогнозирования поможет автоматизировать процесс управления инкассацией и организовать оптимальную плановую загрузку устройств самообслуживания с целью минимизации времени их недоступности. Для решения задачи прогнозирования проведен сравнительный анализ математических методов прогнозирования временных рядов: модели экспоненциального сглаживания, сезонной интегрированной модели авторегрессии (скользящего среднего) и моделей, основанных на нейронных сетях (однослойная нейронная сеть и нейро-нечеткая сеть). Анализ проведен на базе данных о количестве снятых денежных средств из банкомата на закрытой территории бизнес-центра. В результате выявлен наилучший метод прогнозирования (нейро-нечеткая сеть) и получен прогноз выдачи наличных денежных средств для устройства самообслуживания. Управление плановой загрузкой банкоматов, основанное на полученном прогнозе, минимизирует время технического простоя устройства при избытке или недостатке наличных денежных средств, а также позволяет оптимизировать работу инкассаторов.

*Ключевые слова:* анализ временных рядов, ETS, SARIMA, ANFIS, нечеткие нейронные сети, банкоматы.

## **THE COMPARATIVE ANALYSIS OF VARIOUS METHODS FOR TIME SERIES FORECASTING OF PRODUCTION INDICATORS OF AN ENTERPRISE ON THE EXAMPLE OF THE PROBLEM OF CASH ASSETS WITHDRAWAL AT AN AUTOMATED TELLER MACHINE OF A CREDIT INSTITUTION**

**K. Sh. Bagautdinov**

*National University of Oil and Gas "Gubkin University", Moscow, Russia  
E-mail: bagautdinov@asugubkin.ru*

The article analyzes a current problem of maintaining a service of automated deposit machines and ATMs of credit institutions. Solution of the forecasting problem will help in automating the process of cash collection management and organizing an efficient planned load of a self-service machine in order to minimize time when the machine is unavailable for service. To solve the forecasting problem, the comparative analysis of existing mathematical methods of time series forecasting (such as exponential smoothing models, seasonal autoregressive integrated models (moving average) and models based on the neural networks (single-layer neural network and neural-fuzzy network)) is obtained. The analysis is carried out based on the data of the amount of cash withdrawn from the ATM in a closed area of the business center. As a result, the most efficient forecasting method (neural-fuzzy network) is determined and the forecast of cash withdrawal for the self-service machine is obtained. Management of a planned load of ATMs based on the obtained fore-

cast minimizes time of technical delay of the machine in case of cash assets excess or shortage as well as allows optimizing the collector's work.

**Keywords:** time series analysis, ETS, SARIMA, ANFIS, neural-fuzzy networks, ATMs.

### **Введение**

В настоящее время существует общемировая тенденция перехода к безналичному обращению денежных средств; созданы выгодные условия для клиентов, пользующихся кредитными и дебетовыми картами; банками выпущены электронные кошельки и их аналоги – виртуальные карты. Однако, несмотря на это, по данным Центрального Банка РФ, в обращении растет объем бумажных денег (на 1 января 2021 г. он составил 13,4 трлн рублей, что на 2,8 трлн рублей больше показателя 2019 г.) [1], поэтому вопросы размещения и обслуживания автоматизированных депозитных машин и банкоматов кредитных организаций остаются актуальными.

Перед банками стоит задача прогнозирования показателей загрузки автоматизированных устройств, которые напрямую зависят от остатка купюр в них. Поэтому существует потребность исследования имеющихся данных для оценки результатов в перспективе. Данные представляют собой различную информацию в виде набора чисел, образующих временные ряды, по внесению денег в автоматизированные устройства и их снятию. В большинстве случаев обслуживание автоматизированных устройств происходит без прогнозных расчетов, уже по факту необходимости и решению ответственного сотрудника. Для определения наилучшей модели автоматического прогноза выдачи денежных средств из банкоматов проведено исследование существующих методов прогнозирования в программном модуле.

### **Анализ временных рядов**

Временной ряд является набором данных, основанных на наблюдениях и полученных путем регулярного измерения одного показателя в течение некоторого периода времени. Эта последовательность может состоять из случайных величин, которые могут быть как-то связаны друг с другом. Данные временных рядов обусловлены естественным порядком времени, следовательно, значения из выбранного периода будут строго зависеть от значений из прошлого (не наоборот).

Анализ временных рядов основан на методах обработки данных с извлечением их значимых характеристик и применяется для определения изменений и закономерностей данных, используемых для прогнозирования. Прогнозирование временных рядов – это использование модели для предсказания будущих значений на основе ранее наблюдаемых значений [2].

### **Постановка задачи**

Проблема прогнозирования объема наличного оборота денег в банкоматах является актуальной не только для финансовых служб банков, но и для клиентов. Необходимо следить за количеством доступных купюр в устройствах самообслуживания, чтобы предотвратить ситуации нехватки купюр или переполнения ими банкоматов.

Реализация подсистемы прогнозирования выдачи наличных денежных средств из автоматизированных устройств позволит улучшить качество обслуживания, оптимизировать работу инкассаторов и, соответственно, повысить доходность кредитной организации.

Целью исследования является проведение сравнительного анализа имеющихся математических методов прогнозирования временных рядов, а именно:

- моделей экспоненциального сглаживания (ETS);
- сезонной интегрированной модели авторегрессии – скользящего среднего (SARIMA);
- моделей, основанных на нейронных сетях (однослойная нейронная сеть и нейронечеткая сеть).

### **Модели экспоненциального сглаживания**

Основой моделей ETS является экспоненциальное сглаживание – метод прогнозирования, при котором значения переменной за все предыдущие периоды входят в прогноз,

экспоненциально теряя свой вес со временем [3]. Поэтому модели способны своевременно реагировать на изменения, происходящие в наборе данных, с учетом информации об историческом поведении временного ряда.

Простое экспоненциальное сглаживание выглядит так:

$$\hat{y}_{T+1|T} = \alpha \sum_{i=0}^{\infty} (1 - \alpha)^i y_{t-i},$$

где  $y_t$  – значение переменной  $y$  в момент  $t$ ;

$\hat{y}_{T+1|T}$  – прогноз на период  $T + 1$  по значениям  $y$  до  $t$ ;

$\alpha$  – калибруемый параметр.

Модели ETS часто применяют для прогнозирования рядов с выраженным трендом и сезонностью. В этом случае экспоненциальное сглаживание используется для оценки вклада последних двух факторов.

У модели есть три компонента: ошибки (error), тренд (trend) и сезонность (seasonality). Каждый компонент можно описать отдельно:

- ошибки могут быть аддитивными (A) и мультипликативными (M);
- тренд может отсутствовать (N), быть постоянным (A) или со временем изменяться (Ad);
- сезонность может отсутствовать (N), быть аддитивной (A) или мультипликативной (M).

В итоге формируется модель, которая обозначается тремя буквами, например ETS(A, A, A). Выбор параметров модели происходит с помощью минимизации целевой функции (например, при помощи функции максимального правдоподобия).

### Сезонная интегрированная модель авторегрессии – скользящего среднего

Модели экспоненциального сглаживания (ETS) и модель Autoregressive Integrated Moving Average (ARIMA) – это два наиболее широко используемых подхода к прогнозированию временных рядов, которые обеспечивают дополнительные возможности решения задачи прогнозирования. Модели экспоненциального сглаживания основаны на описании сезонности данных и трендов, в то время как модель ARIMA стремится описать автокорреляции в рядах.

Модель ARIMA основана на идее объединения авторегрессионной модели с моделью скользящего среднего (в этом контексте Integrated (интеграция) – это противоположность разности), т. е. в модели ARIMA можно выделить две части.

Используя линейные комбинации значений переменной из прошлого, можно спрогнозировать ее будущие значения. Таким образом, авторегрессионная модель порядка **AR(p)** записывается так:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t,$$

где  $\varepsilon_t$  – белый шум [4].

Вместо того чтобы использовать прошлые значения прогнозируемой переменной в регрессии, модель скользящего среднего использует прошлые ошибки прогноза в регрессионной модели.

Таким образом, модель скользящего среднего порядка **MA(q)** записывается так:

$$y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q},$$

где  $\varepsilon_t$  – белый шум [4].

Исходя из этого, модель ARIMA можно записать как:

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t,$$

где  $y'_t$  – разница рядов.

Модель ARIMA также может моделировать широкий диапазон сезонных данных, в таком случае модель ARIMA становится моделью SARIMA путем включения дополнительных сезонных компонент. В общем виде модель выглядит так:

$$ARIMA(p, d, q)(P, D, Q)_s,$$

где  $s$  – размер сезонности.

Сезонная часть модели состоит из членов, которые аналогичны несезонным компонентам модели, но включают сдвиги назад сезонного периода.

Сезонная часть модели AR или MA будет видна в сезонных лагах коррелограмм PACF и ACF.

### Нейронные сети

Нейронная сеть представляет собой математический инструмент, позволяющий моделировать разного рода зависимости, примерами которых могут быть линейные модели, обобщенно линейные модели и нелинейные модели [5].

Искусственные нейронные сети состоят из искусственных нейронов, основная задача которых – преобразование полученной информации с применением алгоритма. Иными словами, искусственный нейрон – это некая нелинейная функция, которая получает входные значения с определенным весом  $w_i$ . Затем суммируются произведения весов со своими входными значениями. В результате получается взвешенная сумма ( $net = \sum_{i=1}^n x_i w_i$ ), смысл которой заключается в описании сигнала, поступающего на вход. Результатом работы нейронной сети является преобразование входного массива данных в выходной вектор, для формирования которого используется функция активации.

### Нечеткие нейронные сети

Нейронные сети и нечеткая логика способны аппроксимировать сложные функциональные зависимости в большинстве интеллектуальных задач, особенно в задачах прогнозирования. Объединение нейросетей и нечеткой логики дает возможность получить сеть, которая будет обладать человеческими свойствами (использование знаний об объекте на естественном языке и обучаемость в реальном времени).

Нейронные сети преимущественно применяются в задачах без смысловой информации исследуемой функциональной зависимости и ее структуры, поскольку в обучении используется выборка векторов входных и выходных данных. На базе нечеткой системы вывода Такаги – Сугено была разработана адаптивная сеть на основе системы нечеткого вывода – ANFIS (Adaptive Neuro Fuzzy Inference System). На рис. 1 изображен простой контроллер Такаги – Сугено с двумя входами и двумя правилами:

$$\begin{aligned} \text{ЕСЛИ } P11(x_1) \text{ И } P12(x_2) \text{ ТО } f1(x_1, x_2), \\ \text{ЕСЛИ } P21(x_1) \text{ И } P22(x_2) \text{ ТО } f2(x_1, x_2). \end{aligned}$$

Вывод такой системы соответствует набору нечетких правил («если – то»), которые имеют способность к обучению аппроксимации нелинейных функций. При этом функции принадлежности синтезированных систем обучены так, чтобы минимизировать отклонения между результатами нечеткого моделирования и экспериментальными данными [6].




Рис. 1. ANFIS, который реализует простой контроллер Такаги – Сугено с двумя входами и двумя правилами [7]

### Прогнозирование

Для анализа используется выгрузка данных о количестве снятых денежных средств из банкомата на закрытой территории бизнес-центра с 01.01.2016 по 30.12.2020. Было установлено, что в дни начисления зарплаты в банкомате стабильно возникает нехватка денежных купюр.

На рис. 2 изображен используемый временной ряд. Данные были разбиты на обучающую и тестовую выборки. Для контроля выбраны данные за два месяца (60 дней).




Рис. 2. Количество снятых наличных денежных средств из банкомата

Примечание: составлено автором.

При помощи языка программирования Python и библиотеки Sktime построен наивный прогноз для оценки других методов прогнозирования. В качестве базового решения использован наивный прогноз в виде последнего сезонного значения с сезонностью 30 дней (рис. 3).




Рис. 3. Наивный прогноз

Примечание: составлено автором.

Для оценки метода прогнозирования используется средняя абсолютная ошибка (MAPE – Mean absolute percentage error), которая является мерой точности предсказания. Обычно точность выражается в виде отношения, определяемого формулой:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right|,$$

где  $A_t$  – фактическое значение,  $F_t$  – прогноз.

Функция вычисления MAPE была реализована на Python для дальнейшего использования в работе.

Для сезонного наивного прогноза выдачи наличных денежных средств **MAPE = 6.00752795952783**. Исходя из полученного значения MAPE, можно сделать вывод, что последнее сезонное значение оказывается достаточно неплохим предсказанием. В принципе, это ожидаемый вывод, поскольку в работе банкомата на закрытой территории не стоит ожидать каких-то значимых различий между поведением пользователей в разные месяцы.

### Модель ETS

Для текущей сезонной выборки лучше всего использовать модель ETS(AAA).

Прогноз экспоненциальным сглаживанием (рис. 4) был произведен на языке программирования Python при помощи библиотеки Sktime.




Рис. 4. ETS(AAA) прогноз

Примечание: составлено автором.

**MAPE = 2.7871390781473817.** Средняя абсолютная ошибка показывает, что модель ETS(AAA) справилась лучше, чем наивный прогноз.

### SARIMA

Прежде чем приступить к построению модели SARIMA, необходимо произвести предварительный анализ ряда. Поскольку график исходного временного ряда не имеет ярких выбросов и ярко выраженного тренда, можно предположить, что при исключении сезонности ряд будет стационарным.

Для оценки изменчивости ряда был вычислен коэффициент вариации  $V = \frac{\sigma}{\bar{x}}$ , где  $\sigma$  – среднееквадратическое отклонение, а  $\bar{x}$  – среднее арифметическое выборки.

Коэффициент вариации  $V = 0,062227$  показывает **вариативность**, которую можно заметить из характеристик и гистограммы (рис. 5).




Рис. 5. Гистограмма и характеристики ряда


Примечание: составлено автором.

Ряд получился вполне однородным и имеет относительно небольшой разброс.

Модель SARIMA основана на утверждениях о стационарности ряда, поэтому необходимо провести проверку на стационарность ряда и применить обобщенный тест Дикки –

Фуллера, который покажет наличие единичных корней [8]. Реализацию будем осуществлять при помощи языка программирования Python и библиотеки Statsmodels. Однако вначале необходимо избавиться от сезонности, которую явно видно на графике. Поскольку картина для каждого месяца очень схожа, можно произвести сезонную корректировку путем вычитания данных предыдущего месяца.

На рис. 6 представлен график после сезонной корректировки.



**Рис. 6. Сезонная корректировка**

*Примечание:* составлено автором.

Для полученного ряда был проведен обобщенный тест Дикки – Фуллера:

adf: -15.710040394401553

Critical values: {'1%': -3.4339520666978056, '5%': -2.8631311116872475, '10%': -2.567617054512932}

Так как  $adf > 5\%$  Critical values, значит, единичных корней нет – ряд стационарен.

Получившийся **ряд стационарен и без сезонности.**

После предварительного анализа строится модель SARIMA, ее общий вид:  $ARIMA(p, d, q)(P, D, Q)_s$ .

Описание параметров:

**p** и **P** – порядок модели AR(p) и сезонной составляющей SAR(P);

**d** и **D** – порядок интегрирования исходных данных и сезонной составляющей;

**q** и **Q** – порядок модели MA(q) сезонной составляющей SMA(Q);

**s** – сезонный размер (например, год, месяц, неделя, 24-часовой день и т. д.).

Полученный ряд изначально не имел тренда, поэтому не приходилось вычислять разности исходного ряда, а это значит, что порядок интегрирования исходных данных и сезонной составляющей **d** = 0 и **D** = 0.

Для получения порядков моделей AR, MA, SAR и SMA необходимо изучить автокорреляционную (ACF) и частично автокорреляционную (PACF) функции для сезонно скорректированного стационарного ряда (рис. 7).

По графикам ACF и PACF видно, что все лаги не отличаются значительно от 0, кроме 30-го и 31-го. Это значит, что на 30-м лаге (30-й день) получается некоторое существенное поведение на коррелограммах, поэтому можно полагать, что у ряда есть сезонные составляющие SAR и SMA с задержкой в один месяц. Исходя из этой информации, можно утверждать, что **P** = 1 и **Q** = 1, а порядки модели AR и MA **p** = 0 и **q** = 0.




Рис. 7. Коррелограммы ACF и PACF

Примечание: составлено автором.

После определения всех параметров можно сформировать модель  $SARIMA(0,0,0)(1,0,1)_{30}$  при помощи языка программирования Python и библиотеки Statsmodels (рис. 8).




Рис. 8. SARIMA

Примечание: составлено автором.

**MAPE = 1.598627387603949.** Средняя абсолютная ошибка показывает, что модель SARIMA справилась лучше, чем наивный прогноз и ETS(AAA), и позволяет оценить полученную модель SARIMA (табл. 1).

Таблица 1

## Изложение модели SARIMA (данные получены в ходе построения модели)

| SARIMAX Results |                                               |         |       |
|-----------------|-----------------------------------------------|---------|-------|
| Модель:         | SARIMAX(1, 0, [1], 30)                        |         |       |
| Данные:         | 01.01.2016-30.12.2020                         |         |       |
| Ковариация:     | OPG (оценка внешнего произведения градиентов) |         |       |
|                 | coef                                          | std err | P> z  |
| ar.S.L30        | 0.9996                                        | 0.001   | 0.000 |
| ma.S.L30        | -0.2517                                       | 0.018   | 0.000 |

Примечание: составлено автором в ходе построения модели и получения ее краткого изложения.

В кратком изложении модели видно, что сезонные части  $ar.S.L30$  и  $ma.S.L30$  с запаздыванием на 30 дней отображают взаимосвязь внутри ряда (coef 0.99 означает сильную взаимосвязь, а -0.25 – отрицательную взаимосвязь), а также что Р-значения для обоих параметров очень низкие (0). Это говорит об их значимости и нужности в данной модели.

### Однослойная нейронная сеть

При помощи языка программирования Python была реализована однослойная нейронная сеть.

В качестве **функции потерь** используется средняя квадратичная ошибка (MSE). MSE – усредненный по всему набору данных квадрат разницы между предсказанными и истинными значениями, определяемый как

$$MSE = \frac{1}{m} \sum_{i=1}^m \|\hat{y}_i - y_i\|^2,$$

где  $y_i$  – фактический ожидаемый результат, а  $\hat{y}_i$  – прогноз модели.

В качестве оптимизатора используется Adam Optimization Algorithm, который означает адаптивную оценку момента и является способом вычисления текущих градиентов с помощью предыдущих. Кроме того, Adam использует концепцию импульса, которая добавляет доли предыдущих градиентов к текущему.

Начальный **шаг обучения** был подобран как 0,05; после 1 000-й эпохи шаг уменьшается до 0,007.

Было выбрано 15 000 эпох для обучения. Для контроля переобучения или недообучения модели каждую тысячу эпох проверяли значения функции потерь на обучающей и тестовой выборках.

После обучения модели были получены предсказания для тестовой выборки (рис. 9).




Рис. 9. Однослойная нейронная сеть

Примечание: составлено автором.

**MAPE = 2.435729.** Средняя абсолютная ошибка показывает, что однослойная нейронная сеть справилась лучше, чем наивный прогноз и ETS(AAA), но немного хуже модели SARIMA.

### Нейро-нечеткая сеть

При помощи математического пакета MatLab и метода ANFIS была реализована адаптивная нейронная сеть на основе системы нечеткого вывода.

Для обучения модели использовалась та же самая выборка. Сумма выдачи наличных средств за предыдущие 4 года была принята как аргумент целевой функции и подавалась как входной сигнал нейронной сети, поэтому обучение происходило на данных, полученных с января по октябрь, а данные за ноябрь и декабрь использовались как контрольные.

Были заданы параметры генерирования нейронной сети:

- количество термов для каждой входной переменной (3 3 3 3);

- метод обучения – гибридный (hybrid);
- требуемая ошибка – 0,005;
- количество циклов обучения (эпохи) – 200;
- тип функций принадлежности для входных (trimf – треугольная функция принадлежности) и выходных переменных (constant).

Результаты обучения нейронной сети: ошибка установлена на уровне 2985,1936 (рис. 10).




Рис. 10. Результат обучения нейро-нечеткой сети

Примечание: составлено автором.

На рис. 11 представлен график предсказания для тестовой выборки.




Рис. 11. Результат работы нейро-нечеткой сети

Примечание: составлено автором.

**MAPE = 0.7219134480576133.** Средняя абсолютная ошибка показывает, что нейро-нечеткая сеть справилась лучше, чем наивный прогноз, экспоненциальное сглаживание в зависимости от сезона и тренда ETS(AAA), однослойная нейронная сеть и даже лучше, чем модель SARIMA.

### Заключение

В табл. 2 представлено сравнение MAPE для каждого метода. Оценивая среднюю абсолютную ошибку, можно сделать вывод, что лучше всего себя показала нечеткая нейронная сеть за счет объединения нейросетей и нечеткой логики, которое дает возможность получить модель с человеческими свойствами.

Таблица 2

## Значение MAPE для каждого метода

| Модель                     | MAPE |
|----------------------------|------|
| Наивный прогноз            | 6    |
| ETS                        | 2,78 |
| SARIMA                     | 1,6  |
| Однослойная нейронная сеть | 2,44 |
| Нейро-нечеткая сеть        | 0,72 |

*Примечание:* составлено автором на основании полученных в ходе исследований данных.

Однослойная нейронная сеть показала себя немного хуже, чем модель SARIMA, поскольку, по сути, это и есть линейная регрессия со своеобразными модификациями.

В результате исследования получена модель, в основе которой лежит нейро-нечеткая сеть, прогнозирующая остаток снятых денежных средств со средней абсолютной ошибкой 0,72 % и позволяющая инкассационной службе заблаговременно определить дату и сумму как загрузки, так и изъятия купюр банкомата, что способствует оптимизации обслуживания устройств самообслуживания и хранения наличных в банкомате с учетом обеспечения беспроблемной выдачи наличных. Полученный этим методом результат более близок к реальному значению.

В рамках данного исследования рассмотрены еще три модели прогнозирования временных рядов (экспоненциальное сглаживание, SARIMA, однослойная нейронная сеть) и установлено, что для данной задачи они работают хуже, чем нечеткая нейронная сеть. Стоит отметить, что указанные модели показывают хорошие результаты только для краткосрочных прогнозов.

## Литература

1. ЦБ оценил вероятность сохранения повышенного спроса на наличные в 2021 году. URL: <https://www.vedomosti.ru/finance/news/2021/03/23/> (дата обращения: 03.09.2021).
2. Садовникова Н. А., Шмойлова Р. А. Анализ временных рядов и прогнозирование. М. : Синергия, 2016. 152 с.
3. Hyndman R. J., Athanasopoulos G. Forecasting: Principles and Practice. 2nd edition. Melbourne, Australia : OTexts, 2018. 382 p.
4. Box G. E., Jenkins G. M., Reinsel G. C. Time Series Analysis: Forecasting and Control. Hoboken : John Wiley & Sons Inc., 2015. 712 p.
5. Боровиков В. П. Нейронные сети. М. : Горячая линия –Телеком, 2008. 392 с.
6. Новикова С. В., Тунакова Ю. А., Кремлева Э. III. Использование различных алгоритмов нейро-нечеткого управления экологическим риском в зоне действия полимерных производств // Вестн. Казан. технолог. ун-та. 2013. № 17. URL: <https://cyberleninka.ru/article/n/ispolzovanie-razlichnyh-algoritmov-neyro-nechetkogo-upravleniya-ekologicheskim-riskom-v-zone-deystviya-polimernyh-proizvodstv> (дата обращения: 03.09.2021).
7. Jang J. S. R., Sun C. T., Mizutani E. Neuro-Fuzzy and Soft Computing – A Computational Approach to Learning and Machine Intelligence. IEEE, 1997. 640 p.
8. Brownlee J. Introduction to Time Series Forecasting With Python: How to Prepare Data and Develop Models to Predict the Future. Machine Learning Mastery, 2017. 367 p.