

16. Xue X. Phase transition for SIR model with random transition rates on complete graphs, *Frontiers of Mathematics in China*, 2018, A 13, pp. 667-690.
17. Bartoszek K., Bartoszek W., Krzemiński M. Simple SIR models with Markovian control, *Jpn J Stat Data Sci.*, 2021, A 4, pp. 731-762.
18. Yoon-Gu Hwang, Hee-Dae Kwon, Jeehyun Lee. Optimal Control Problem of an SIR Model with Random Inputs Based on a Generalized Polynomial Chaos Approach, *International Journal of Numerical Analysis and Modeling*, 2022, Vol. 19. Issue 2-3, pp. 255-274.
19. Dubko V.A. Pervyy integral sistemy stokhasticheskikh differentsial'nykh uravneniy [The first integral of the system of stochastic differential equations]. Kiev: Institut matematiki AN USSR, 1978, 21 p.
20. Gikhman I.I., Skorokhod A.V. Stokhasticheskie differentsial'nye uravneniya [Stochastic differential equations]. Kiev: Nauk. Dumka, 1968, 354 p.
21. Karachanska E.V. Integral'nye invarianty stokhasticheskikh sistem i programmnoe upravlenie s veroyatnost'yu 1 [Integral invariants of stochastic systems and program control with probability 1]. Khabarovsk: Izd-vo Tikhokean. gos. un-ta, 2015, 149 p.
22. Chalykh E.V. Postroenie mnozhestva programmnykh upravleniy s veroyatnost'yu 1 dlya odnogo klassa stokhasticheskikh sistem [Constructing the set of program controls with probability 1 for one class of stochastic systems], *Avtomatika i telemekhanika* [Automation and Remote Control], 2009, Vol. 70, No. 8, pp. 110-122.
23. Karachanskaya E.V. Modelirovanie sistem differentsial'nykh uravneniy s dinamicheskimi invariantami [Modeling of systems of differential equations with dynamic invariants], *Matematicheskoe modelirovanie i chislennye metody* [Mathematical modeling and numerical methods], 2019, No. 1, pp. 98-117.
24. Rybkina O.V. Postroenie determinirovannoy i stokhasticheskoy matematicheskikh modeley zashchity informatsionnoy sistemy [Construction of deterministic and stochastic mathematical models of information system protection], *Problemy informatsionnoy bezopasnosti. Komp'yuternye sistemy* [Problems of information security. Computer systems], 2024, No. 3, pp. 30-39.

Карачанская Елена Викторовна – Дальневосточный государственный университет путей сообщения; e-mail: elena_chal@mail.ru; г. Хабаровск, Россия; д.ф.-м.н., профессор кафедры «Информационные технологии и системы».

Рыбкина Олеся Викторовна – Дальневосточный государственный университет путей сообщения; e-mail: ribkina_ol@mail.ru; г. Хабаровск, Россия; старший преподаватель кафедры «Информационные технологии и системы».

Karachanskaya Elena Viktorovna – Far Eastern State Transport University; e-mail: elena_chal@mail.ru; Khabarovsk, Russia; dr. of phys.-math. sc.; professor of the Department «Information Technologies and Systems».

Rybkina Olesya Viktorovna – Far Eastern State Transport University; e-mail: ribkina_ol@mail.ru; Khabarovsk, Russia; senior lecturer of the Department of «Information Technologies and Systems».

УДК 303.732.4

DOI 10.18522/2311-3103-2025-6-157-178

А.И. Гусева, Р.М. Романов

МЕТОД ПРОГНОЗИРОВАНИЯ ВРЕМЕННЫХ РЯДОВ, ОСНОВАННЫЙ НА КОГНИТИВНОМ НЕЧЕТКОМ МОДЕЛИРОВАНИИ И РЕГРЕССИОННОМ АНАЛИЗЕ

Актуальность исследования определяется низкой эффективностью традиционных методов прогнозирования временных рядов в условиях высокой неопределённости и ограниченного объёма данных, характерных для слабо формализованных систем. Цель работы заключается в разработке и обосновании метода прогнозирования временных рядов на основе гибридного подхода, объединяющего когнитивное нечеткое моделирование, регрессионный анализ и метод аналитических сетей. В рамках исследования проведён системный обзор и сравнительный анализ существующих методов прогнозирования, включая подходы на основе нечеткой логики, нейросетевого и когнитивного моделирования, ансамблевых и гибридных методов, и выявлены их ограничения при работе с малыми выборками, нелинейными зависимостями и неопределённостью. Разработанный ме-

тод включает: построение нечетких когнитивных карт, дефаззификацию лингвистических оценок, кластеризацию факторов, применение метода аналитических сетей для определения приоритетов и формирование взвешенной регрессионной модели. Модель проходит статистическую валидацию по метрикам MAE, RMSE, MAPE и R^2 , а также проверку предпосылок регрессионного анализа, включая тесты на мультиколлинеарность и автокорреляцию. Применение метода обеспечило снижение RMSE с 0,38 до 0,22, MAE с 0,30 до 0,18 и MAPE с 11,65 % до 7,12 %, что подтверждает повышение точности и устойчивости прогнозов при ограниченном объеме данных по сравнению с классической многофакторной регрессией. Новизна разработанного метода заключается в интеграции когнитивного моделирования, регрессионного анализа и метода аналитических сетей, при которой преимущества каждого компонента компенсируют их индивидуальные ограничения, обеспечивая более точное и устойчивое прогнозирование в условиях неопределенности исследуемой системы. Практическая значимость работы состоит в возможности применения предложенного метода для поддержки принятия решений и повышения обоснованности прогнозов в различных предметных областях и ситуациях, где имеется ограниченный объем наблюдений, а существенную роль играют экспертные оценки, а также сложная структура причинно-следственных связей между показателями во времени.

Прогнозирование временных рядов; когнитивное моделирование; нечеткие когнитивные карты; регрессионный анализ; гибридный подход; экспертные оценки; аналитические сети; управление в условиях неопределенности; газовый бизнес.

A.I. Guseva, R.M. Romanov

A TIME SERIES FORECASTING METHOD BASED ON COGNITIVE FUZZY MODELING AND REGRESSION ANALYSIS

The relevance of the study stems from the low effectiveness of traditional time series forecasting methods under conditions of high uncertainty and limited data, which are typical of weakly formalized systems. The aim of the work is to develop and substantiate a time series forecasting method based on a hybrid approach that integrates cognitive fuzzy modelling, regression analysis, and the analytic network process. Within the study, a systematic review and comparative analysis of existing forecasting methods was carried out, including approaches based on fuzzy logic, neural network and cognitive modelling, as well as ensemble and hybrid methods, and their limitations were identified when dealing with small samples, nonlinear dependencies, and uncertainty. The proposed method includes: the construction of fuzzy cognitive maps, defuzzification of linguistic assessments, clustering of factors, application of the analytic network process to determine priorities, and the formation of a weighted regression model. The model undergoes statistical validation using the MAE, RMSE, MAPE, and R^2 metrics, as well as diagnostic checks of the assumptions underlying regression analysis, including tests for multicollinearity and autocorrelation. Application of the method reduced RMSE from 0.38 to 0.22, MAE from 0.30 to 0.18, and MAPE from 11.65 % to 7.12 %, thereby confirming an improvement in the accuracy and robustness of forecasts under limited data compared with classical multiple regression. The novelty of the proposed method lies in the integration of cognitive modelling, regression analysis, and the analytic network process, whereby the strengths of each component compensate for their individual limitations, providing more accurate and robust forecasting under the uncertainty inherent in the system under study. The practical significance of the work consists in the possibility of applying the proposed method to support decision-making and to enhance the validity of forecasts in various subject domains and situations characterized by a limited number of observations, a substantial role of expert judgments, and a complex structure of causal relationships between indicators over time.

Time series forecasting; cognitive modeling; fuzzy cognitive maps; regression analysis; hybrid approach; expert assessments; analytic network process; decision-making under uncertainty; gas industry.

Введение. Прогнозирование в различных областях осуществляется на протяжении десятилетий как в науке, так и в промышленности: при исследовании временных рядов, научно-технологического прогресса, социально-экономического состояния общества, в медицине и здравоохранении, сельском хозяйстве и логистике, управлении и маркетинге и т.д. Сама задача прогнозирования временных рядов является классической задачей машинного обучения и относится к типу «обучение с учителем» [1].

Накопление огромных объемов данных расширяет возможности моделей машинного обучения, однако степень нелинейности, зашумленности и неопределенности данных растёт, а кризисные явления и политико-экономическая нестабильность в мировом масштабе существенно затрудняют прогнозирование на основе только исторических вре-

менных рядов [2]. Важно отметить, что статистические и регрессионные модели могут некорректно определять значимость факторов, что приводит к существенным искажениям в прогнозах. Особенно ярко данная проблема проявляется при анализе малых выборок с резкими изменениями в данных, когда модель может ошибочно идентифицировать причинно-следственные связи. Это подтверждается исследованиями в области эконометрического моделирования, где показано, что в условиях нестабильности и резких изменений в данных классические регрессионные модели часто присваивают высокую значимость несущественным факторам, что ведёт к снижению точности прогнозов [3]. В таких ситуациях на первый план выходят методы, основанные на экспертных оценках, а также модели, способные эффективно работать на малых выборках. Более того, даже при наличии достаточного объема данных, учет экспертного мнения остается критически важным для корректной интерпретации результатов и валидации прогнозных моделей в сложных и нестабильных системах. Одним из перспективных инструментов являются нечеткие когнитивные карты (НКК): они описывают проблемную область в виде сети факторов со связями «причина–следствие» и позволяют на основе экспертных высказываний (например, «усиление фактора А сильно увеличивает В») моделировать развитие ситуации и прогнозировать изменение системы по выбранным входным воздействиям [4]. Преимущество НКК состоит в возможности включения новых факторов, по которым отсутствует достаточный объём наблюдений, но которые оказывают косвенное или прямое воздействие на уже существующие элементы модели. Такое причинно-следственное влияние способно не только скорректировать, но и существенно трансформировать существующие прогнозные модели, изменяя структуру их взаимосвязей и результаты расчётов. В финансово-экономическом контексте это способствует более полному учёту последствий валютных колебаний и рыночной турбулентности, повышая уровень системности организации и качество оценок возможных состояний.

Учитывая вышеизложенные сложности прогнозирования, особую актуальность приобретает разработка комбинированных подходов к прогнозированию финансово-экономических показателей.

В качестве практической области применения комбинированных подходов в данной статье рассматривается топливно-энергетический комплекс РФ (ТЭК). Топливо-энергетический комплекс, как объект исследования и управления, представляет собой сложную систему, характеризующуюся высокой динамичностью и многоаспектностью протекающих в ней процессов. Его состояние определяется не только экономическими, но и геополитическими, технологическими и социальными факторами. Именно специфика ТЭК, характеризующаяся высокой степенью неопределённости и многофакторности, делает особенно актуальным разработку методов прогнозирования. Многие элементы и взаимосвязи данной системы, особенно в контексте энергетического перехода и глобальной нестабильности, не до конца изучены и могут описываться преимущественно качественными характеристиками. Часто отсутствует достаточная количественная информация для формализованного описания поведения системы в изменяющихся условиях. Процессы, протекающие в ТЭК, изменчивы во времени и описываются сложными нелинейными зависимостями, что позволяет классифицировать его как сложную слабо формализованную социально-экономическую систему. Исходя из вышеизложенного анализа, становится очевидной необходимость разработки методов прогнозирования в условиях ограниченной информации. Таким образом, целью настоящего исследования является разработка метода прогнозирования в условиях малых выборок и неопределённости, адаптированного к специфике ТЭК.

Основная часть работы

1. Описание решаемой задачи

Постановка задачи исследования связана с управлением слабо формализованной системой, обладающей высокой степенью неопределённости и множеством взаимосвязанных внутренних и внешних факторов. Такая система имеет сложную структуру взаимодействий, что требует разработки комплексных подходов для её моделирования и прогнозирования поведения. Исследуемая система формализуется как упорядоченная пара $S = \langle M, R \rangle$, где $M = \{M_C, M_B, M_U, M_Q, M_O\}$ представляет собой множество моделей, от-

ражающих наше представление о системе (включая когнитивную, поведенческую, управленческую, качественную и экспертную), а $R \subseteq M \times M$ – отношение между этими компонентами. Когнитивная модель M_c описывается ориентированным графом $G = \langle V, E \rangle$, в котором узлы V соответствуют контролируемым и неконтролируемым факторам, а дуги E характеризуются весами $w_{ij} \in [-1, 1]$, отражающими силу причинно-следственных связей. Для моделирования поведения системы используется регрессионная модель M_B , управляющая модель M_U предназначена для формирования воздействий на систему, а модель оценки качества M_Q обеспечивает оценку точности и адекватности результатов с использованием таких метрик, как $MAE, MAPE, RMSE, R^2$ а также тестов на мультиколлинеарность и автокорреляцию. Компонент M_O реализует метод аналитических сетей для оценки относительной важности факторов.

Основную сложность при работе с данной системой вызывает ограниченный объём доступных данных, что накладывает существенные ограничения на построение моделей и проведение статистических оценок. Метод аналитических сетей используется для компенсации недостатка данных путём интеграции экспертных знаний и формирования весов факторов, которые далее используются в прогностической модели. Прогнозирование выполняется с помощью регрессионной модели:

$$\hat{Y}(t) = \beta_0 + \sum_{i=0}^n \beta_i (w_i \cdot X_i(t, u_t)) + \varepsilon(t), \quad (1)$$

где $\hat{Y}(t)$ – прогнозируемое значение в момент времени t , β_0 и β_i – параметры регрессии, n – число факторов, $X_i(t, u_t)$ – значение фактора в момент времени t , зависящее от управляющего воздействия u_t , $\varepsilon(t)$ – случайная ошибка.

В рамках рассматриваемой задачи рассматривается целевая переменная u_t , вектор факторных переменных $x_t = (x_{1t}, \dots, x_{12t})$ и вектор управляющих воздействий u_t . В соответствии с постановкой задачи x_t раскладывается на эндогенную компоненту $x_t^{(endo)}$, описывающую внутренние производственные и финансовые показатели исследуемой подсистемы (газового бизнеса), и экзогенную компоненту $x_t^{(exo)}$, представляющую внешние рыночные, макроэкономические и регуляторной среды. Управляющие переменные u_t формируются как подмножество эндогенных показателей, которые могут изменяться в результате управленческих решений и входят в модель неявно через зависимость $x_t^{(endo)} = f(x_t^{(exo)}, u_t)$. Вместе с тем, с учётом системообразующей роли газового сектора в российской экономике, изменения его производственных и финансовых показателей могут оказывать опосредованное влияние на макроэкономические параметры, включая обменный курс рубля. Предлагаемая модель ориентирована на количественную оценку этого влияния. Конкретный состав эндогенных, экзогенных и управляющих переменных уточняется в разделе «Результаты и их обсуждение».

Цель управления заключается в минимизации функционала потерь:

$$\min_{u \in U^T} \sum_t^T w_t (Y_t - \hat{Y}_t(u_t))^2, \quad (2)$$

где w_t – весовой коэффициент, Y_t – наблюдаемое значение, а \hat{Y}_t – прогнозируемое. Ограниченная выборка данных требует особого подхода к калибровке моделей, включая проверку их устойчивости и адекватности на небольших объёмах информации. Таким образом, основной задачей является создание метода управления слабо формализованной системой в условиях недостаточной выборки данных, которая обеспечивала бы стабильность и точность прогнозов.

Объект и предмет исследования:

Объектом исследования является топливно-энергетический комплекс как сложная слабо формализованная система, характеризующаяся множеством взаимодействующих факторов, нелинейными зависимостями и высокой степенью внешней и внутренней неопределённости. Предметом исследования выступают методы прогнозирования, ориентированные на решение задач управления слабо формализованными системами через прогнозирование.

Гипотеза исследования:

Использование гибридного метода, сочетающего методы аналитических сетей, регрессионного анализа и когнитивного моделирования, позволит значительно повысить точность прогнозирования и эффективность управления слабо формализованными системами. Апробация предложенного подхода на исторических данных продемонстрирует его превосходство над традиционными отраслевыми моделями, что выражается в снижении ошибок прогнозирования, таких как *RMSE*, *MAE* и *MAPE*.

Задачи исследования:

1. Провести системный анализ существующих методов прогнозирования временных рядов, включая подходы на основе нечеткой логики, нейросетевого моделирования, когнитивного моделирования, метода аналитических сетей и регрессионных моделей. Выявить ограничения и преимущества существующих методов в контексте слабой формализуемости исследуемых систем.
2. Разработать и исследовать метод прогнозирования экономических временных рядов, основанный на гибридном подходе, направленный на повышение точности прогностической модели.
3. Построить модель нечеткой когнитивной карты, отражающую прогнозирование курса доллара по отношению к рублю, с учётом ключевых причинно-следственных взаимосвязей в российском газовом бизнесе.
4. Разработать регрессионную модель прогнозирования курса доллара по отношению к рублю.

Решение поставленных задач позволило внести вклад в развитие методов машинного обучения для прогнозирования временных рядов в слабо формализованных системах.

2. Методика исследования

Обзор текущего состояния методов прогнозирования временных рядов

Прогнозирование временных рядов представляет собой ключевую задачу в аналитике данных, где точность модели имеет решающее значение для принятия управленческих решений. Среди современных подходов выделяются одиночные, ансамблевые и гибридные методы, каждый из которых имеет свои особенности и области применения [5]. Одиночные методы подразделяются на статистические и эконометрические методы, нейросетевые, методы глубокого обучения [5, 6].

Статистические методы являются фундаментальной основой анализа временных рядов. Особое место среди них занимает регрессионный анализ, который позволяет выявлять и количественно оценивать взаимосвязи с переменными. Регрессионный анализ начинается с построением многофакторной модели. Стандартный процесс включает оценку параметров модели многофакторной регрессионной модели. Наиболее распространенным методом является метод наименьших квадратов (МНК), который минимизирует сумму квадратов отклонений между фактическими и прогнозируемыми значениями:

$$\hat{\theta}_{\text{МНК}} = (X^T X)^{-1} X^T Y, \quad (3)$$

где $\hat{\theta}_{\text{МНК}}$ – вектор оптимальных оценок параметров регрессии, найденных методом наименьших квадратов, X^T – транспонированная матрица X . Однако, при наличии гетероскедастичности или коррелированных ошибок применяются модификации МНК. Среди модификаций выделяют обобщенный метод наименьших квадратов (ОМНК) и взвешенный метод наименьших квадратов (ВМНК). ОМНК формализуется следующим образом:

$$\hat{\theta}_{\text{ОМНК}} = (X^T \Sigma^{-1} X)^{-1} X^T Y, \quad (4)$$

где Σ – положительно определенная ковариационная матрица ошибок наблюдений. ВМНК представляется в следующем виде:

$$\hat{\theta}_{\text{ВМНК}} = (X^T W X)^{-1} X^T W Y, \quad (5)$$

где W – диагональная матрица весов, элементы которой w_i компенсируют неоднородность дисперсий (гетероскедастичность) остатков.

В общем случае модель многофакторной регрессии описывается следующим выражением [7]:

$$Y = f(X_1, X_2, \dots, X_N) + \varepsilon, \quad (6)$$

где Y – прогнозируемая переменная, X_1, X_2, \dots, X_N – независимые переменные, влияющие на прогнозируемую величину, а ε – случайная компонента (ошибка модели), предполагаемая нормально распределенной и независимой.

Линейная многофакторная регрессионная модель, принимает следующий вид [7]:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_N X_N + \varepsilon, \quad (7)$$

где $\beta_0, \beta_1, \beta_2, \dots, \beta_N$ – коэффициенты регрессии, подлежащие определению на основе данных, ε – случайная компонента (ошибка модели).

Эконометрические методы, такие как ARIMA и её модификации (например, SARIMA, ARIMAX), остаются популярными благодаря своей эффективности при работе со стационарными и линейными временными рядами [8]. Они применяются в задачах, где данные демонстрируют линейные зависимости, и широко используются в экономике и финансах для анализа временных рядов, таких как ВВП, инфляция или биржевые индексы.

Методы машинного обучения, такие как метод опорных векторов (SVM), решающие деревья (DT) и ансамбли деревьев (Random Forest), активно применяются для прогнозирования временных рядов [9].

Для решающих деревьев задача регрессии выражается как среднее значение целевой переменной в соответствующей листовой вершине:

$$\hat{y}(x) = \frac{1}{|R_j|} \sum_{i \in R_j} y_i, \quad (8)$$

где $\hat{y}(x)$ – прогнозируемое значение целевой переменной, $|R_j|$ – количество объектов в вершине R_j , y – фактическое значение. Для случайного леса задача регрессии формулируется усреднением прогнозов всех деревьев в ансамбле:

$$\hat{y}(x) = \frac{1}{N} \sum_{i=1}^N b_i(x), \quad (9)$$

где $\hat{y}(x)$ – прогнозируемое значение целевой переменной $b_i(x)$ – прогноз i -го дерева решений для значения x , N – количество деревьев в ансамбле. К недостаткам перечисленных методов можно отнести трудоемкость вычислений при работе с крупномасштабными выборками.

Среди моделей машинного обучения в последние годы активно используются нейросетевые методы и методы, основанные на нейросетях глубокого обучения. Нейронные сети, включая многослойные перцептроны (MLP), рекуррентные нейронные сети (RNN), сети с долговременной кратковременной памятью (LSTM), успешно справляются с нелинейными зависимостями [10, 11].

Формального подхода к выбору характеристик искусственные нейронных сетей (ANN) не существует, в подавляющем большинстве случаев используются многослойные перцептроны (MLP), нейронные сети общей регрессии (GRNN), радиальный базис функциональные сети (RBFN), нечеткая сеть ARTMAP, вероятностная нейронная сеть (PNN) [10, 11]. Несмотря на то, что ANN успешно справляются с задачами прогнозирования временных рядов, им свойственны такие ограничения, как склонность к попаданию в локальные оптимумы, высокая зависимость от типичных выборок, чувствительность к начальным весам, медленная скорость обучения и проблема переобучения. Вышеупомянутые ограничения иногда приводят к тому, что ANN не могут обеспечить удовлетворительную точность предсказания [12].

Последние несколько лет для построения прогнозов стали активно использоваться методы глубокого обучения, использующие такие виды нейронных сетей, как сверточные нейронные сети (CNN), глубокие нейронные сети (DNN), рекуррентные нейронные сети (RNN) и нейронные сети с долговременной кратковременной памяти (LSTM), архитектуры-трансформеры [1, 13].

Помимо этого, хорошо зарекомендовали себя гибридные и ансамблевые методы прогнозирования временных рядов, которые используются для повышения точности прогноза [5, 12, 14]. Основное различие заключается в том, каким образом они интегрируют

различные модели и как предсказывают результат: ансамблевые методы используют независимые модели с последующим объединением результатов, а гибридные методы создают единую последовательную цепочку моделей, где каждая последующая использует результаты предыдущей.

При формировании ансамбля, как правило решаются следующие задачи: выбор соответствующих базовых алгоритмов, выбор стратегии ансамблирования и формирование решающего правила для объединения результатов. В качестве стратегии ансамблирования, как правило используется бэггинг, бустинг или стэкинг [15]. Бэггинг предполагает обучение нескольких моделей на подвыборках данных и последующее усреднение результатов. Бустинг оптимизирует модель, добавляя новые алгоритмы, компенсирующие ошибки предыдущих. Стекинг представляет собой метод, при котором прогнозы базовых моделей объединяются с помощью метамодели. В отличие от простого усреднения, стэкинг использует обучаемую метамодель, которая может учитывать относительную важность и точность каждой базовой модели, что часто приводит к более высокой точности предсказаний. В современной парадигме ансамблевого обучения выделяют следующие ключевые реализации: случайный лес, градиентный бустинг, усовершенствованный градиентный бустинг (XGBoost), оптимизированные реализации градиентного бустинга с быстрым построением бинарных деревьев (LightGBM), бустинг, адаптированный для работы с категориальными признаками (CatBoost), адаптивный алгоритм с итеративной корректировкой весов (AdaBoost) [16–18].

В работе [19] авторы провели сравнительный анализ эффективности нечётких когнитивных карт и классической регрессии при построении моделей системной динамики. На выборке из 250 точек данных средняя ошибка НКК составила 28%, тогда как регрессионный анализ продемонстрировал точность 10%. Это указывает на преимущество последнего при работе с относительно небольшими наборами данных.

Гибридные методы, как правило, сочетают статистические методы с подходами глубокого обучения для более точного прогнозирования [12, 20]. В некоторых случаях перед применением гибридных методов прогнозирования данные можно разделить на линейные и нелинейные компоненты – например, для этого можно использовать такие функции «вейвлет-преобразования», как «дискретное вейвлет-преобразование» [21].

Исследования показывают различные результаты применения гибридных подходов. Так, в работах [22–25] предложен оригинальный подход к построению прогнозов, где регрессионный анализ выступает в роли инструмента параметрической идентификации для определения весовых коэффициентов связей в НКК. Полученная модель используется как динамическая. Эффективность метода была проверена на задаче управления развитием сельскохозяйственных территорий с использованием временного ряда данных за период 2000–2017 гг. (204 наблюдения), однако авторы не приводят данных о сравнительной точности предложенного подхода.

В работе [26] автор данной статьи предложил иной подход, в рамках которого нечёткие когнитивные карты используются экспертами для выявления и формализации причинно-следственных связей между факторами, а также для интеграции дополнительных факторов в модель на основе экспертных оценок. Процесс моделирования включает комплексную оценку исследуемой ситуации с последующей количественной формализацией выявленных взаимосвязей. Определённые в ходе когнитивного анализа весовые коэффициенты причинно-следственных связей интегрируются в итоговую регрессионную модель. Существенной особенностью данного подхода является возможность модификации и расширения модели посредством включения новых концептов и связей. Применение данного подхода на малой выборке (36 временных точек) обеспечило точность прогноза по метрике MAPE на уровне 11,15% для прогнозируемого года.

В ряде работ отечественных авторов, гибридные подходы опираются на когнитивные нечеткие карты и регрессионные модели, нечеткие когнитивные карты и нейронечеткой сети ANFIS, нечеткие деревья решений или модели нечетких иерархий [27]. В этих работах идеи когнитивного моделирования, развиваемые В. Коско для моделирования динамических систем, были реализованы в виде инструментария нечетких когни-

тивных карт. НКК отражают структуру причинно-следственных связей между значимыми факторами ситуации. Её формируют в результате перевода когнитивных представлений и убеждений лиц, принимающих решения, и экспертов на формальный язык [28, 29].

Такие гибридные подходы особенно актуальны при исследовании сложных, слабо формализованных социально-экономических систем. Особенностью таких систем является то, что одни их факторы можно измерить количественно, а другие носят качественный, относительный характер. При этом для количественных факторов могут существовать статистические данные, в то время как для качественных единственным источником информации остаются знания экспертов. Стандартные подходы к идентификации НКК обычно ориентированы на работу с информацией только одного типа – либо статистической, либо экспертной.

Критерии сравнения методов

Основными метриками оценки качества прогноза являются [30]:

$$MAE = \frac{\sum |Y(t) - \hat{Y}(t)|}{n}, \quad (10)$$

MAE (средняя абсолютная ошибка) вычисляет среднее прогнозов $\hat{Y}(t)$ от фактических значений $Y(t)$, игнорируя знак отклонений. Устойчив к выбросам, измеряется в единицах исходных данных.

$$RMSE = \sqrt{\frac{\sum (Y(t) - \hat{Y}(t))^2}{n}}, \quad (11)$$

RMSE (корень из среднеквадратической ошибки) включает возведение отклонений в квадрат, что делает метрику более чувствительной к большим ошибкам. Единицы измерения совпадают с исходными данными.

$$MAPE = \left(\sum_{t=1}^n \left| \frac{Y(t) - \hat{Y}(t)}{Y(t)} \right| \right) \frac{100}{n}, \quad (12)$$

MAPE (средняя абсолютная процентная ошибка) измеряет среднюю абсолютную процентную ошибку. *MAPE* может быть чувствителен к малым значениям $Y(t)$, однако удобен для сравнения моделей.

$$R^2 = 1 - \frac{\sum (Y(t) - \hat{Y}(t))^2}{\sum (Y(t) - \bar{Y})^2}, \quad (13)$$

R^2 (коэффициент детерминации) показывает долю дисперсии, объясненной моделью. Диапазон значения принимает [0; 1].

$$RSE = \frac{\sum (Y(t) - \hat{Y}(t))^2}{n - 2}, \quad (14)$$

RSE (стандартная ошибка регрессии) оценивает точность предсказаний в исходных единицах измерения. Меньшие значения указывают на лучшую модель.

Анализируя ансамблевые и гибридные модели, невозможно однозначно определить, какой из подходов обеспечивает наилучшие общие результаты для всех данных, поскольку эффективность прогнозирования существенно зависит от специфики исходных временных рядов. Проведенный сравнительный анализ показывает преимущество комбинированных подходов над базовыми моделями. Так, при прогнозировании валютных пар INR/USD на рынке FOREX ансамблевые методы показали существенное улучшение точности: применение LSBoost снизило показатель *MAPE* с 0,863 до 0,715, а Bagging – до 0,695 [31]. А гибридные модели демонстрируют впечатляющие результаты при прогнозировании валютных курсов. Комбинация ARIMA и LSTM для прогнозирования курсов доллара и фунта позволила уменьшить *RMSE* с 0,022 до 0,0143 и снизить *MAPE* с 0,487 до 0,204 [32]. Значительный потенциал гибридных подходов подтверждается и при работе с макроэкономическими показателями. В частности, при прогнозировании индекса потребительских цен комбинация ARIMA и BPNN обеспечила снижение *RMSE* более чем в 2,5 раза – с 1,252 до 0,453 [33].

Особенно показательны результаты применения гибридных моделей на российских макроэкономических данных. При прогнозировании денежных доходов населения комбинация ARIMA с различными нейронными архитектурами (LSTM, RNN, GRU) продемонстрировала существенное улучшение метрик качества: $RMSE$ снизился с 7,01 до значений от 2,89 до 5,4, а MAE – с 5,86 до 2,35-5,03 [34].

Эффективность гибридных подходов подтверждается и в других прикладных задачах. Так, при прогнозировании промышленного потребления энергоресурсов в Москве комбинация нечетких когнитивных карт (НКК) с ANFIS позволила снизить $MAPE$ с 2,35 до 1,62 [35]. Аналогичные результаты получены при прогнозировании выручки от реализации газа, где гибридная модель НКК-регрессия обеспечила снижение $RMSE$ с 6340,7 до 5418,4 и $MAPE$ с 13,03 до 11,15 [26].

Представленные результаты убедительно демонстрируют преимущество ансамблевых и гибридных подходов в задачах прогнозирования временных рядов по сравнению с использованием отдельных базовых моделей.

На основе гибридного подхода, объединяющего нечеткое когнитивное картирование и регрессионный анализ был разработан авторский метод прогнозирования, состоящий из шести последовательных этапов обработки данных. Предложенный метод характеризуется повышенной точностью, устойчивостью к шумам и адаптивностью в условиях неопределенности, что делает его особенно эффективным при работе с временными рядами в условиях ограниченной выборки данных.

Отличительной особенностью данного метода является совместное использование различных методов прогнозирования, где достоинства одних вычислительных моделей компенсируют недостатки других, что создает синергетический эффект. Нечеткое когнитивное картирование в сочетании с методом аналитических сетей позволяет эффективно использовать экспертные знания при неполноте данных и проводить комплексную оценку причинно-следственных связей. Регрессионный анализ, используемый на последних стадиях, компенсирует потенциальные неточности прогнозов, получаемых на основе нечеткого когнитивного картирования. При этом недостатки классического регрессионного анализа, такие как чувствительность к выбросам и аномалиям, успешно устраняются благодаря предварительной обработке данных методами нечеткого когнитивного картирования. Особую значимость имеет применение метода аналитических сетей Т. Саати, который эффективно решает проблему мультиколлинеарности путем учета и устранения взаимозависимостей и обратных связей.

Структура разработанного метода представлена на рис. 1, где наглядно отражена последовательность выполнения всех этапов и взаимодействие компонентов модели.

Предлагаемый метод прогнозирования временных рядов

Рассмотрим подробно компоненты, которые участвуют в реализации метода и способствуют формализации неопределенности и повышению точности регрессионной модели.

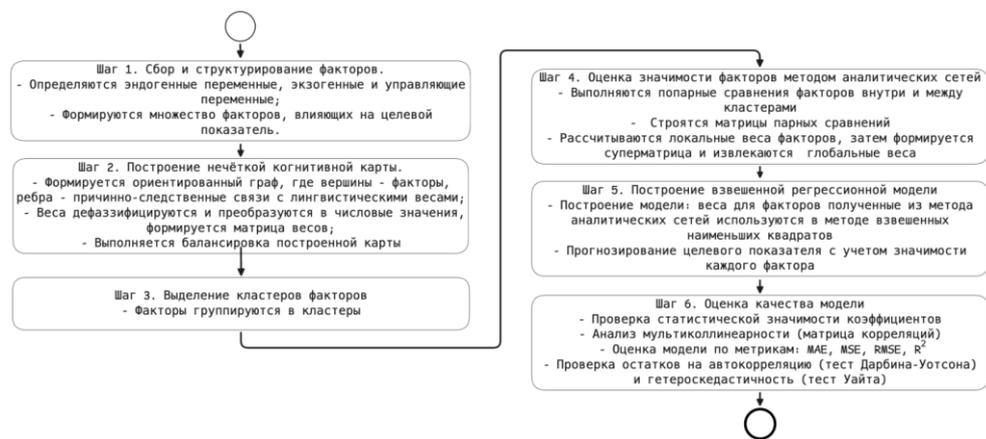


Рис. 1. Разработанный метод построения регрессионной модели

Источник: составлено авторами

Шаг 1. Сбор и структурирование факторов

На начальном этапе формируется перечень факторов, влияющих на целевой показатель, с их последующей систематизацией для моделирования. Унифицированный перечень будет использоваться всеми участниками при построении нечеткой когнитивной карты. Основные процедуры: идентификация факторов (составление перечня на основе отраслевой литературы, отчетности и экспертных интервью с учётом эндогенных (производственные показатели, финансы) и экзогенных (рыночные условия, регулирование) факторов), классификация, верификация источников данных и их подготовка. В дальнейшем под эндогенными факторами понимаются количественные производственные и финансовые показатели управляемой подсистемы (в нашем примере – газового бизнеса), тогда как экзогенные факторы описывают внешнюю рыночную, макроэкономическую и регуляторную среду. В контексте настоящего исследования термин «экзогенный» используется относительно подсистемы газового бизнеса и трактуется как «неподдающийся прямому управленческому воздействию», что не исключает существования более широких обратных связей на уровне национальной экономики.

Шаг 2. Построение нечеткой когнитивной карты

Взаимосвязи между факторами представляются в виде ориентированного взвешенного графа:

$$G = \langle C, E \rangle, \quad (15)$$

где C – множество вершин (факторов системы), E – множество ребер (дуг), представляющих причинно-следственные связи. Множество вершин агрегированной НКК формируется как объединение множеств факторов, предложенных в индивидуальных картах. Аналогично множество ребер E формируется как объединение всех предложенных связей. Весовые коэффициенты определяются экспертным путём на основе лингвистических оценок («слабое положительное», «сильное отрицательное»), задаваемых лингвистическими переменными. Каждому значению лингвистической переменной $t_k \in T_{ij}$ ставится в соответствие треугольное нечеткое число $t_k = (a_k, b_k, c_k)$, где $a_k < b_k < c_k$ и стандартной функции принадлежности $\mu(x_i)$. Индивидуальные нечеткие оценки по каждой дуге (C_i, C_j) агрегируются оператором нечеткого усреднения: покомпонентно усредняются параметры (a_k, b_k, c_k) треугольных чисел только тех карт, где связь присутствует, после чего выполняется дефаззификация агрегированного числа. При наличии противоположных знаков влияния по одной и той же дуге результирующее направление связи определяется по принципу большинства. Итоговые числовые значения приводятся к общей шкале $w_{ij} \in [-1, 1]$. Для каждой дуги $(C_i, C_j) \in E$ определяется весовой коэффициент w_{ij} , где:

- ◆ $w_{ij} > 0$: положительное влияние (усиление C_j при росте C_i);
- ◆ $w_{ij} < 0$: отрицательное влияние (ослабление C_j при росте C_i);
- ◆ $w_{ij} = 0$: отсутствие прямого влияния (C_i на фактор C_j).

Пусть вершина $C_\gamma \in C$ соответствует целевой переменной. На основе структуры графа G , весов w_i и механизма нечеткого вывода (дефаззификация) для каждого фактора $C_i \in C$ вычисляются наиболее значимые факторы для C_γ . Дефаззификация лингвистических оценок выполняется методом центра тяжести:

$$z = \frac{\sum \mu(x_i) \cdot x_i}{\sum \mu(x_i)}, \quad (16)$$

где $\mu(x_i)$ – значение функции принадлежности, x_i – значение универсальной шкалы. После преобразования проводится проверка совместимости факторов и моделирование распространения их влияния с помощью медианных операторов, удовлетворяющих аксиомам нормировки, неубывания, непрерывности и бисимметричности. Влияние от одного фактора C_i на фактор C_j с учетом их совместимости вычисляется как новое значение фактора-приемника C_j по формуле:

$$C_j = \text{med}(C_i, w_{ij}; c_{ij}), \quad (17)$$

где C_i – текущее значение фактора-источника, w_{ij} – вес связи, а $c_{ij} \in [0,1]$ – степень совместимости данных факторов, выступающая параметром операции. Степень совместимости факторов c_{ij} рассчитываются по формуле [36]:

$$c_{ij} = \frac{v_{ij}^+}{v_{ij}^+ + v_{ij}^-}, \quad (18)$$

где v_{ij}^+ и v_{ij}^- – положительные и отрицательные компоненты консонанса, отражающие степень согласованности C_i на C_j . Выходной результат данного компонента – совместимые факторы. Далее вычисляется мера влияния $I_{FCM}(C_Y) \geq 0$ на вершину V_Y с учётом балансировки факторов формируется подмножество факторов $C^{(1)} = \{C_i \in C | I_{FCM}(C_i) \geq \tau\}$, где $\tau > 0$, τ_1 – порог значимости, обладающих существенным влиянием на целевую переменную. На рис. 2 приведен фрагмент алгоритма построения ННК.

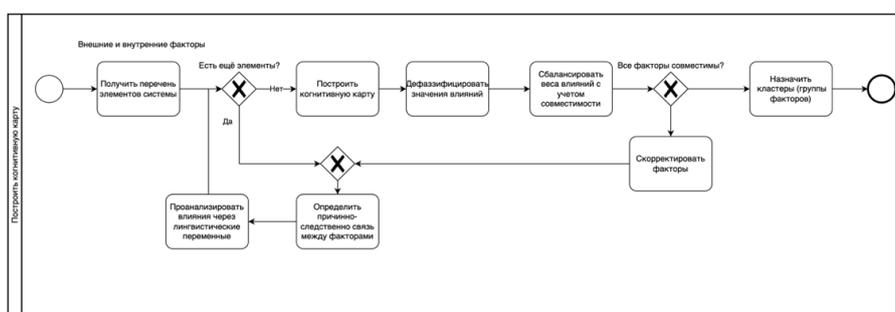


Рис. 2. Фрагмент алгоритма построения и балансировки факторов для нечеткой когнитивной карты (нотация BPMN)

Источник: составлено авторами

Шаг 3. Выделение кластеров факторов

Метод аналитических сетей (МАС) применяется для определения относительной значимости факторов системы и силы их взаимовлияния. Кластеризация факторов осуществляется путём экспертного разбиения множества факторов C на непересекающиеся подмножества (кластеры) $K = \{K_1, K_2 \dots K_k\}$, где $C = \cup_{k=1}^n K_k$ – объединение всех кластеров, $K_i \cap K_j = \emptyset$ при $i \neq j$ – условие непересекаемости кластеров. Такой подход позволяет структурировать множество факторов и обеспечить более точный анализ их взаимосвязей и значимости в рамках исследуемой системы.

Шаг 4. Оценка значимости факторов методом аналитических сетей

На основе экспертных оценок формируется матрица парных сравнений $A = [a_{ij}]$, где a_{ij} отражает относительное влияние фактора i на фактор j . Для контроля непротиворечивости суждений по матрице A вычисляется максимальное собственное значение λ_{max} , индекс согласованности при этом вычисляется, как:

$$ИС = \frac{\lambda_{max} - n}{n - 1}, \quad (19)$$

где n – размерность матрицы парных сравнений.

Отношение согласованности:

$$ОС = \frac{ИС}{СИ}, \quad (20)$$

где СИ – индекс по Саати. Условие $ОС < 0,1$ свидетельствует о приемлемой согласованности экспертных оценок [37].

По матрице A рассчитывается вектор весовых коэффициентов (приоритетов) $W = [w_1, w_2, \dots, w_i]$, где w_i – количественная мера значимости фактора C_i в рамках рассматриваемой системы. Нормализация выполняется для каждого фактора C_i внутри кластера: вычисляется сумма оценок по всем факторам $S_j = \sum_{i=1}^n a_{ij}$, нормализованный вес определяется $w_j' = \frac{a_{ij}}{S_j}$. Сумма всех нормализованных весов равна единице, т.е. $\sum_{j=1}^n w_j' = 1$. Затем строится матрица попарных сравнений между кластерами и рассчитывается нормализованный вес между кластерами. Далее строится суперматрица матрица W_{super} , где блоки W_{ij} содержат векторы локальных приоритетов, показывающая влияние элементов кластера друг на друга, если элементы независимы, то блок заполняется нулями. Вычисление взвешенной суперматрицы по следующей формуле:

$$W_{limit} = \lim_{p \rightarrow \infty} (W_{weight})^p, \tag{21}$$

где W_{weight} – взвешенная суперматрица, p – степень, в которую возводится W_{weight} , W_{limit} – предельная суперматрица. Столбцы матрицы W_{limit} сходятся к одинаковым векторам, которые представляют собой глобальные веса факторов. Эти веса являются итоговым результатом метода аналитических сетей и отражают относительную важность каждого фактора в системе. На основании этих глобальных весов выполняется выбор наиболее значимых факторов по заданному порогу $\tau_2 > 0$ выполняется $V^* = \{W_j \in V^{(1)} | p_j \geq \tau_2\} = \{V_1, \dots, V_n\}$, где V^* – уточненное подмножество значимых факторов. На рис. 3 приведен фрагмент алгоритма выявления важных факторов.

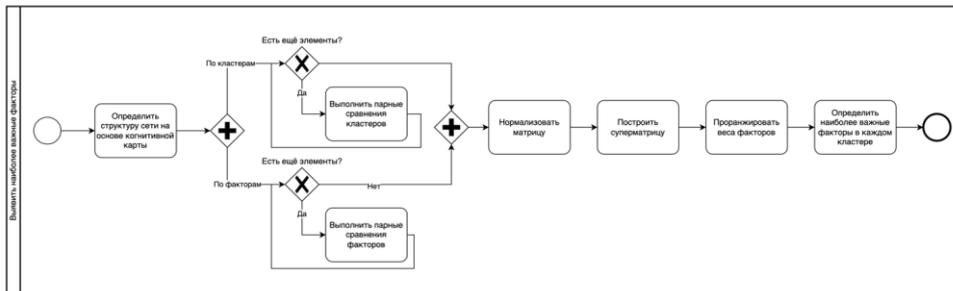


Рис. 3. Фрагмент алгоритма выявления важных факторов (нотация BPMN)

Источник: составлено авторами

Шаг 5. Построение взвешенной регрессионной модели

Коэффициенты модели оцениваются с весами, учитывающими значимость факторов:

$$w_i^{набл} = \sum_{j=1}^m w_j |x_{ij}|, \tag{22}$$

где $w_i^{набл}$ – вес -ого наблюдения, w_j – вес, отражающий значимость j -го фактора из МАС, x_{ij} – значение j -го фактора в i -ом наблюдении, m – количество факторов. Матрица весов наблюдений W является диагональной матрицей размерностью $n \times n$, где на главной диагонали расположены веса наблюдений w_i . Использование весов позволяет выделить на уровне модели наиболее значимые по мнению экспертов наборы данных, что интегрирует экспертные оценки в регрессионную модель. Оценки коэффициентов модели вычисляются по следующей формуле [38]:

$$\hat{\beta} = (X^T W X)^{-1} X^T W \hat{Y}, \tag{23}$$

где X – матрица факторов (размерность $n \times m$, где n – количество наблюдений, m – число факторов), \hat{Y} – вектор наблюдений целевого показателя (размерность $n \times 1$), W – диагональная матрица весов наблюдений (размерность $n \times n$). Цель модели – минимизация взвешенной среднеквадратичной ошибки:

$$\min \sum_i^n w_i (Y_i - \hat{Y}_i)^2, \quad (24)$$

где Y_i – фактическое значение целевой переменной для i -го наблюдения, \hat{Y}_i – предсказанное значение целевой переменной для i -го наблюдения, w_i – вес i -го наблюдения, рассчитанный по формуле 2.22 с учетом значимости факторов.

Итоговая модель:

$$\hat{Y}(t) = \hat{\beta}_0 + \sum_{i=1}^n \hat{\beta}_i (X_i(t)) + \varepsilon(t), \quad (25)$$

где $\hat{Y}(t)$ – прогнозируемое значение в момент времени t , $\hat{\beta}_0$ – свободный член модели, n – число факторов, $\hat{\beta}_i$ – оцененные коэффициенты регрессии, рассчитанные методом взвешенных наименьших квадратов с учетом веса (значимости) для фактора C_i , $X_i(t)$ – значение фактора в момент времени t , $\varepsilon(t)$ – случайная ошибка в момент времени. На рис. 4 приведен фрагмент алгоритма построения и проверки итоговой прогностической модели.

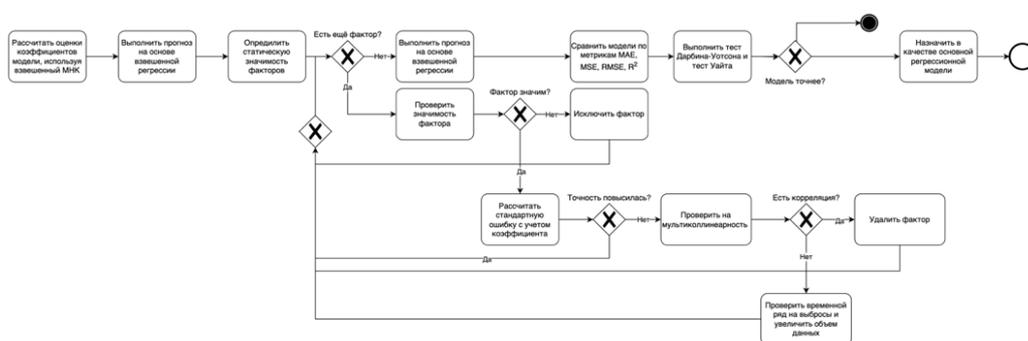


Рис. 4. Фрагмент алгоритма построения и проверки взвешенной регрессионной модели (нотация BPMN)

Источник: составлено авторами

Шаг 6. Оценка модели по метрикам качества

Для оценки модели выполняется проверка нулевой гипотезы $H_0: \beta_i = 0$ против $H_1: \beta_i \neq 0$ с использованием t-статистики. Используя p-value проверяется наименее значимые факторы. Вместе с оценкой значимости производят проверку на мультиколлинеарность для факторов $Corr(X_i, X_j)$. Далее для оценки значимости каждого коэффициента регрессии $\hat{\beta}_i$ вычисляется стандартная ошибка $SE(\hat{\beta}_i)$ по формуле:

$$SE(\hat{\beta}_i) = \hat{\sigma} \sqrt{((X'X)^{-1})_{ii}}, \quad (26)$$

где $\hat{\sigma}$ – стандартная ошибка регрессии, вычисляемая по формуле:

$$\hat{\sigma} = \sqrt{\frac{1}{n-p} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}, \quad (27)$$

X – матрица факторов, X' – транспонированная матрица X , $(X'X)^{-1}$ – обратная матрица, $((X'X)^{-1})_{ii}$ – i -й диагональный элемент обратной матрицы, который соответствует стандартной ошибке $\hat{\beta}_i$.

Используем стандартными метриками качества моделей $MAE, MSE, RMSE, R^2$ на основе формул (11)-(14).

Проанализируем остатки e_t на предмет отсутствия автокорреляции и гомоскедастичности. Для этого используются тест Дарбина-Уотсона:

$$DW = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=2}^n e_t^2}, \quad (28)$$

где результаты теста интерпретируются следующим образом:

$DW \approx 2$ – отсутствует автокорреляция остатков;

$DW < 2$ – положительная автокорреляция, т.е. ошибки последовательно зависят друг от друга;

$DW > 2$ – отрицательная автокорреляция.

Для оценки гетероскедастичности используется тест Уайта, где определяется зависит ли дисперсия остатков от независимых переменных и их комбинаций. Вспомогательная регрессия:

$$e_i^2 = \alpha_0 + \alpha_1 X_{i1} + \dots + \alpha_n X_{in} + \varepsilon_i, \quad (29)$$

где α_0 – свободный член вспомогательной регрессии, $\alpha_1, \dots, \alpha_n$ – коэффициенты вспомогательной регрессии, $X_{i1}, X_{i2}, \dots, X_{in}$ – независимые переменные, ε_i – случайная ошибка вспомогательной регрессии.

Статистика Уайта:

$$\chi^2 = nR^2, \quad (30)$$

где n – определяет количество наблюдений. В свою очередь χ^2 сравнивается с критическим распределением хи-квадрат χ_{df}^2 , где под df понимается число факторов, учтенных в вспомогательной регрессии. Результат оценки теста Уайта оценивается по χ^2 , если он превышает критическое значение на заданных уровнях значимости α , то отвергаем нулевую гипотезу H_0 : гетероскедастичность присутствует, если меньше критического значения, то можно считать, что дисперсия ошибок постоянна.

3. Результаты и их обсуждение

Исходная многофакторная линейная регрессия:

$$Y = 68,7 + 0,41x_1 + 0,21x_4 + 0,36x_5 - 0,24x_6 + 0,32x_{10} + 0,29x_{12} + \varepsilon, \quad (31)$$

где x_1 – цена на нефть, x_4 – спрос на природный газ в РФ, x_5 – ставка ЦБ, x_6 – объем обязательной продажи выручки, x_{10} – объемы добычи газа в РФ, x_{12} – себестоимость газа. Для решения задачи прогнозирования влияния газового сектора на динамику курса доллара по отношению к рублю на основе исходной регрессионной модели факторов была разработана и построена нечеткая когнитивная карта с применением предложенного метода (рис. 5). В исследовании приняли участие девять экспертов – научные сотрудники одного из научно-исследовательских институтов ПАО «Газпром», а также ведущие преподаватели Финансовой академии при Правительстве РФ и МГТУ им. Н.Э. Баумана, специализирующиеся в области газовой промышленности. На этапе формирования НКК участвовало 6 экспертов. Совместно с экспертами был сформирован расширенный перечень факторов до 50, оказывающих значимое влияние на исследуемую зависимость, а также установлены причинно-следственные связи между ними. В качестве исходных данных использовались факторы, включённые в базовую регрессионную модель, а также данные, образующие временной ряд, содержащий 36 наблюдений, представленных с месячной дискретностью. В построенной нечеткой когнитивной карте был исключен фактор x_4 спрос на природный газ в РФ, который был в исходной регрессионной модели. После определения состава новых факторов и выявления связей между ними осуществлялась оценка степени влияния на основе лингвистических переменных, отражающих характер и силу взаимовлияния факторов. Полученные экспертные оценки были впоследствии дефаззифицированы и агрегированы для вычисления итоговых весовых коэффициентов факторов. На заключительном этапе выполнялась балансировка модели, обеспечивающая согласованность структуры и стабильность результирующих весов.

Таблица 1

Кластеры факторов, выявленные по результатам анализа

Кластеры	Факторы	Интерпретация
Кластер 1 (C_1): Конъюнктура мировых рынков газа и нефти	x_1 – цена на нефть, x_2 – экспортные цены на природный газ, x_3 – цена газа на экспорт	Определяют внешнюю конъюнктуру и экспортные доходы
Кластер 2 (C_2): Макроэкономические условия РФ	x_5 – ставка ЦБ, x_6 – объем обязательной продажи валютной выручки, x_7 – приток внешних инвестиций,	Характеризируют внутреннюю финансовую устойчивость
Кластер 3 (C_3): Валютные и контрактные риски	x_8 – соотношение долгосрочных контрактов в разных валютах, x_9 – обменный курс рубля к юаню	Определяют валютную структуру выручки и валютные риски
Кластер 4 (C_4): Производственные показатели	x_{10} – объемы добычи природного газа в РФ, x_{11} – объемы поставок газа в Китай, x_{12} – себестоимость газа, x_{13} – транспортные расходы	Процесс производства и реализации природного газа

Источник: составлено авторами

Матрицы попарных сравнений формировались по шкале Саати (1-9) с соблюдением условий обратной симметрии ($a_{ij} = 1/a_{ji}$) и единичных значений на диагонали $a_{ij} = 1$. После агрегирования индивидуальных оценок трех экспертов, используя геометрическое среднее была получена интегрированная матрица попарных оценок. Для примера на рис. 6 представлены агрегированные матрицы попарных сравнения для кластера 1 и матрица попарных сравнений кластеров между собой.

Матрица парных сравнений для кластера 1				Матрица парных сравнения кластеров				
	x_1	x_2	x_3		C_1	C_2	C_3	C_4
x_1	1	2,38	3	C_1	1	1,7	1,3	1
x_2	0,42	1	2,37	C_2	0,59	1	1,3	1,7
x_3	0,33	0,42	1	C_3	0,77	0,77	1	0,8
				C_4	1	0,59	1,25	1

Рис. 6. Агрегированные матрица парных сравнений для кластера 1 и матрица парных сравнений кластеров

Источник: составлено авторами

Для агрегированной матрицы кластера 1 максимальное собственное значение составило $\lambda_{max} \approx 3,039$, индекс согласованности ИС $\approx 0,019$, отношение согласованности ОС $\approx 0,034$. Для агрегированной матрицы типа «кластер-кластер» получены $\lambda_{max} \approx 4,016$, ИС $\approx 0,036$, ОС $\approx 0,039$. Во всех случаях ОС $< 0,1$, что свидетельствует о приемлемой согласованности и групповых суждений как внутри кластера, так и между кластерами.

На следующем этапе на основе совокупности агрегированных матриц попарных сравнений была построена суперматрица методом аналитических сетей. Путем её нормировки и последовательного возведения в степень до сходимости, получена итоговая суперматрица, столбцы которой задают глобальные веса факторов. Рассчитанные таким образом глобальные веса приведены в табл. 2.

Таблица 2

Факторы, выявленные по результатам анализа и их глобальные веса

Факторы	Итоговый глобальный вес
x_1 – цена на нефть	0,18
x_2 – экспортные цены на природный газ	0,09
x_3 – цена газа на экспорт	0,05
x_5 – ставка ЦБ РФ	0,12
x_6 – объем обязательной продажи выручки	0,07
x_7 – приток внешних инвестиций в валюте	0,06
x_8 – соотношение долгосрочных контрактов	0,10
x_9 – обменный курс рубля к юаню	0,08
x_{10} – объемы добычи газа в РФ	0,08
x_{11} – объемы поставок газа в Китай	0,07
x_{12} – себестоимость газа	0,06
x_{13} – транспортные расходы	0,04

Источник: составлено автором

Используя формулу 2.24 расчета коэффициентов β для взвешенного метода наименьших квадратов, были получены итоговые коэффициенты регрессии.

$$Y = 0,42 + 0,31 \cdot x_1 + 0,22 \cdot x_2 + 0,15 \cdot x_3 - 0,18 \cdot x_5 - 0,14 \cdot x_6 - 0,12 \cdot x_7 + 0,20 \cdot x_8 + 0,17 \cdot x_9 - 0,11 \cdot x_{10} - 0,10 \cdot x_{11} + 0,09 \cdot x_{12} + 0,07 \cdot x_{13} + \varepsilon, \quad (32)$$

где x_1 – цена на нефть, x_2 – экспортные цены на природный газ, x_3 – цена газа на экспорт, x_5 – ставка ЦБ, x_6 – объем обязательной продажи выручки, x_7 – приток внешних инвестиций в валюте, x_8 – соотношение долгосрочных контрактов, x_9 – обменный курс рубля к юаню, x_{10} – объемы добычи газа в РФ, x_{11} – объемы поставок газа в Китай, x_{12} – себестоимость газа, x_{13} – транспортные расходы.

Реализация шагов 4–6 (оценка значимости факторов методом аналитических сетей, построение взвешенной регрессионной модели и оценка качества модели) осуществлялась с использованием программного обеспечения, зарегистрированного в Роспатенте [40]. Средняя погрешность вычислений составила $\pm 5\%$ при уровне доверия 95%, что обусловлено вариативностью оценок качества моделей в рамках процедур перекрёстной валидации.

В результате построения многофакторной регрессионной модели по предложенному методу и сопоставления полученных результатов с классическим подходом были получены значения, представленные в табл. 3.

Таблица 3

Сравнение точности прогнозирования для задачи курс доллара по отношению к рублю: многофакторная регрессия и взвешенная регрессия

Модель	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i>
Исходная многофакторная линейная регрессия	0,38	0,30	11,65%
Взвешенная регрессия (гибридный метод)	0,22	0,18	7,12%

Из табл. 3 видно, что при использовании предложенного метода точность прогноза увеличилась на 42% по *RMSE* (среднеквадратичная ошибка снизилась с 0,38 до 0,22), на 40% по *MAE* (средняя абсолютная ошибка снизилась с 0,30 до 0,18) и на 39% по *MAPE* (средняя абсолютная процентная ошибка уменьшилась с 11,65% до 7,12%).

Выводы. В ходе исследования задачи прогнозирования была проведена оценка эффективности предложенного гибридного метода. Анализ метрик качества продемонстрировал значительное улучшение показателей прогнозирования. Среднеквадратичная ошибка (*RMSE*) снизилась с 0,38 до 0,22, что свидетельствует о существенном повышении точности модели. Параллельно наблюдалось уменьшение средней абсолютной ошибки (*MAE*) с 0,30 до 0,18. Важным снижением стало сокращение средней абсолютной процентной ошибки (*MAPE*), которая уменьшилась – с 11,65% до 7,12%.

Разработанный в рамках настоящего исследования метод уточнения многопараметрических регрессионных моделей, основанный на принципах нечеткого когнитивного анализа и метода аналитических сетей, демонстрирует значительный потенциал для прогнозирования финансово-экономических показателей российского газового бизнеса. Отличительной особенностью метода является возможность интеграции экспертных оценок и качественных взаимосвязей факторов в традиционные процедуры количественного моделирования. Это обеспечивает существенное повышение точности и надежности получаемых прогнозных значений, что особенно важно при принятии управленческих решений в условиях неопределенности газового рынка.

Практическая значимость метода определяется его способностью учитывать как количественные, так и качественные характеристики исследуемых процессов, что делает его эффективным инструментом для решения сложных задач прогнозирования в газовой отрасли.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Китова О.В., Дьяконова Л.П., Китов В.А., Савинова В.М. Применение нейронных сетей для прогнозирования социально-экономических временных рядов // *Russian Economic Bulletin*. – 2020. – Т. 3, № 5. – С. 188-201.
2. Ярушев С.А., Аверкин А.Н., Ефремова Н.А. Гибридные нечеткие когнитивные карты в задачах поддержки принятия решений и прогнозирования // *Программные продукты, системы и алгоритмы*. – 2017. – № 4. – С. 18-18.
3. Долгов Ю.А., Долгов А.Ю., Столяренко Ю.А. Анализ выборок малого объема и их применение // *Вестник Приднестровского университета. Серия: Физико-математические и технические науки. Экономика и управление*. – 2013. – № 3 (45). – С. 79-90. – EDN XVSWBJ.
4. Воробьев Г.Г. Нечеткие когнитивные карты в искусственном интеллекте // *MCE.SU: «Математика. Компьютер. Образование»*. – 2010. – URL: <https://www.mce.biophys.msu.ru/archive/doc61132/doc.pdf> (дата обращения: 01.07.2025).
5. Cheng L., Yu T. A new generation of AI: A review and perspective on machine learning technologies applied to smart energy and electric power systems // *International Journal of Energy Research*. – 2019. – Vol. 43, No. 6. – P. 1928-1973.
6. Андрианова Е.Г., Головин С.А., Зыков С.В., Леско С.А., Чукалина Е.Р. Обзор современных моделей и методов анализа временных рядов динамики процессов в социальных, экономических и социотехнических системах // *Российский технологический журнал*. – 2020. – № 8 (4). – С. 7-45.
7. Арутюнов А.Л., Иванюк В.А., Цвиркун А.Д. Разработка инструментальных средств прогнозирования в социально-экономических системах // *Управление развитием крупномасштабных систем*. – 2015. – С. 241-293.
8. Ivanyuk V., Sunchalin A., Sunchalina A. Development of an intelligent ensemble forecasting system // *Advances in Intelligent Systems and Computing*. – 2020. – Vol. 1294. – P. 491-500. – DOI: 10.1007/978-3-030-63322-6_40.
9. Parray I.R., Khurana S.S., Kumar M., Altalbe A.A. Time Series Data Analysis of Stock Price Movement Using Machine Learning Techniques // *Soft Computing*. – 2020. – No. 24. – P. 16509-16517. – <https://doi.org/10.1007/s00500-020-04957-x>.
10. Аламир Х.С., Заргарян Е.В., Заргарян Ю.А. Модель прогнозирования транспортного потока на основе нейронных сетей для предсказания трафика на дорогах // *Известия ЮФУ. Технические науки*. – 2021. – № 6 (223). – С. 124-132.
11. Зелезецкий Д.В. Глубокое обучение в задаче прогнозирования финансовых временных рядов // *Тр. Московского физико-технического института*. – 2024. – Т. 16, № 3 (63). – С. 35-48.
12. Sina L.B., Secco C.A., Blazevic M., Nazemi K. Hybrid Forecasting Methods—A Systematic Review // *Electronics*. – 2023. – No. 12. – P. 2019. – <https://doi.org/10.3390/electronics12092019>.

13. *Alharbi M.H.* Prediction of the Price of Advanced Global Stock Markets Using Machine Learning: Comparative Analysis // *Journal of Financial Risk Management*. – 2024. – Vol. 13, No. 4. – P. 689-702.
14. *Ivanyuk V.* The method of residual-based bootstrap averaging of the forecast ensemble // *Financial Innovation*. – 2023. – Vol. 9, No. 1. – P. 37.
15. *Wu H., Levinson D.* The ensemble approach to forecasting: A review and synthesis // *Transportation Research Part C: Emerging Technologies*. – 2021. – Vol. 132. – P. 103357.
16. *Ke G. et al.* Lightgbm: A highly efficient gradient boosting decision tree // *Advances in neural information processing systems*. – 2017. – Vol. 30.
17. *Chen T., Guestrin C.* Xgboost: A scalable tree boosting system // *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. – 2016. – P. 785-794.
18. *Freund Y., Schapire R.E.* A decision-theoretic generalization of on-line learning and an application to boosting // *Journal of computer and system sciences*. – 1997. – Vol. 55, No. 1. – P. 119-139.
19. *Posmakov N.P., Emelyanenko A.S., Kireev V.S.* Fuzzy Cognitive Map Ensembles to Solve Regression and Time Series Tasks // *2022 Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*. – IEEE, 2022. – P. 406-409.
20. *Katwal S., Shrestha R., Sharma G.* Analysis of Website Traffic Time Series Forecasting using ARIMA, Prophet, and LSTM RNN // *International Journal of Research Publications*. – 2024. – No. 146 (1). – P. 316-326. – doi: 10.47119/IJRP1001461420246271.
21. *Wu X. et al.* The development of a hybrid wavelet-ARIMA-LSTM model for precipitation amounts and drought analysis // *Atmosphere*. – 2021. – Vol. 12, No. 1. – P. 74.
22. *Подгорская С.В. и др.* Построение нечетких когнитивных моделей социально-экономических систем на примере модели управления комплексным развитием сельских территорий // *Бизнес-информатика*. – 2019. – Т. 13, № 3. – С. 7-19.
23. *Холодова М.А., Подвесовский А.Г., Исаев Р.А.* Нечеткая когнитивная модель стратегического управления агропродовольственным рынком // *Модели, системы, сети в экономике, технике, природе и обществе*. – 2022. – № 2 (42). – С. 106-125.
24. *Захарова А.А., Подвесовский А.Г., Исаев Р.А.* Нечеткие когнитивные модели в управлении слабоструктурированными социально-экономическими системами // *Информационные и математические технологии в науке и управлении*. – 2020. – № 4 (20). – С. 5-23.
25. *Зимонина Ю.В., Исаев Р.А., Подвесовский А.Г.* Подсистема обмена данными в составе системы поддержки принятия решений на основе когнитивного моделирования «ИГЛА»: архитектура и особенности реализации // *Физико-техническая информатика (СРТ2020)*. – 2020. – С. 12-16.
26. *Романов Р.М.* Построение и применение нечетких когнитивных карт для оценки влияния капитальных проектов на финансовые результаты компании // *Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки*. – 2025. – № 1 (2). – С. 62-67. – DOI 10.37882/2223-2966.2025.01-2.17.
27. *Аверкин А.Н., Ярушев С.А., Павлов В.Ю.* Когнитивные гибридные системы поддержки принятия решений и прогнозирования // *Программные продукты и системы*. – 2017. – Т. 30, № 4. – С. 632-642. – DOI: 10.15827/0236-235X.120.632-642.
28. *Avdeeva Z.K., Grebenyuk E.A., Kovriga S.V.* Cognitive modelling-driven time series forecasting for predicting target indicators in non-stationary processes // *IFAC-PapersOnLine*. – 2021. – Vol. 54, No. 13. – P. 91-96.
29. *Кулинич А.А.* Компьютерные системы анализа ситуаций и поддержки принятия решений на основе когнитивных карт: подходы и методы // *Проблемы управления*. – 2011. – № 4. – С. 31-45.
30. *Бабешко Л.О., Орлова И.В.* Эконометрика и эконометрическое моделирование в Excel и R. – 2021.
31. *Handa R.* Prediction of foreign exchange rate using regression techniques. – 2017.
32. *Yilmaz F.M., Arabaci O.* Should deep learning models be in high demand, or should they simply be a very hot topic? A comprehensive study for exchange rate forecasting // *Computational Economics*. – 2021. – Vol. 57, No. 1. – P. 217-245.
33. *Hadwan M. et al.* A Hybrid Neural Network and Box-Jenkins Models for Time Series Forecasting // *Computers, Materials & Continua*. – 2022. – Vol. 70, No. 3.
34. *Пашишов Б., Петрусевич Д.А.* Анализ нейросетевых моделей для прогнозирования временных рядов // *Russian Technological Journal*. – 2024. – Т. 12, № 4. – P. 106-116.
35. *Борисов В.В., Луферов В.С.* Метод многомерного анализа и прогнозирования состояния сложных систем и процессов на основе нечетких когнитивных темпоральных моделей // *Системы управления, связи и безопасности*. – 2020. – № 2. – С. 1-23. – DOI: 10.24411/2410-9916-2020-10201.
36. *Борисов В.В., Федюлов А.С.* «Совместимые» нечеткие когнитивные карты // *Системы компьютерной математики и их приложения*. – 2016. – № 17. – С. 41-43.

37. *Saatu T.L.* Принятие решений при зависимостях и обратных связях: аналитические сети: пер. с англ. О.Н. Андрейчиковой / науч. ред. А.В. Андрейчиков, О.Н. Андрейчикова. – 2-е изд. – М.: ЛИБРОКОМ: URSS, 2009. – 357 с. – ISBN 978-5-397-00844-0.
38. *Eng K., Chen Y.Y., Kiang J.E.* User's guide to the weighted-multiple-linear-regression program (WREG version 1.0): US Geological Survey Techniques and Methods, book 4, chap, viewed nd, from <http://pubs.usgs.gov/tm/tm4a8>. – 2009. – P. 21.
39. *Гусева А.И., Романов Р.М.* Программа для ЭВМ «Программное приложение для визуализации и построения нечетких когнитивных карт в задачах управления слабо формализованными системами», свидетельство о государственной регистрации программы для ЭВМ № 2025660016 от 21.04.2025. Патентообладатель НИЯУ МИФИ (Россия). – 2025.
40. *Романов Р.М., Гусева А.И.* Программа для ЭВМ «Программное средство анализа и построения регрессионной модели на основе метода аналитических сетей для слабо формализованных систем», свидетельство о государственной регистрации программы для ЭВМ № 2025686199 от 30.09.2025. Патентообладатель НИЯУ МИФИ (Россия). – 2025.

REFERENCES

1. *Kitova O.V., D'yakonova L.P., Kitov V.A., Savinova V.M.* Primenenie neyronnykh setey dlya prognozirovaniya sotsial'no-ekonomicheskikh vremennykh ryadov [Application of neural networks for forecasting socio-economic time series], *Russian Economic Bulletin*, 2020, Vol. 3, No. 5, pp. 188-201.
2. *Yarushev S.A., Averkin A.N., Efremova N.A.* Gibridnye nechetkie kognitivnye karty v zadachakh podderzhki prinyatiya resheniy i prognozirovaniya [Hybrid fuzzy cognitive maps in decision support and forecasting problems], *Programmnye produkty, sistemy i algoritmy* [Software products, Systems and Algorithms], 2017, No. 4, pp. 18-18.
3. *Dolgov Yu.A., Dolgov A.Yu., Stolyarenko Yu.A.* Analiz vyborok malogo ob"ema i ikh primeneniye [Analysis of small samples and their application], *Vestnik Pridnestrovskogo universiteta. Seriya: Fiziko-matematicheskie i tekhnicheskie nauki. Ekonomika i upravlenie* [Bulletin of Pridnestrovian University. Series: Physical, Mathematical and Technical Sciences. Economics and Management], 2013, No. 3 (45), pp. 79-90. EDN XVSWBJ.
4. *Vorob'ev G.G.* Nечеткие когнитивные карты в искусственном интеллекте [Fuzzy cognitive maps in artificial intelligence], *MCE.SU: «Matematika. Komp'yuter. Obrazovanie»* [MCE.SU: "Mathematics. Computer. Education"], 2010. Available at: <https://www.mce.biophys.msu.ru/archive/doc61132/doc.pdf> (accessed 01 July 2025).
5. *Cheng L., Yu T.* A new generation of AI: A review and perspective on machine learning technologies applied to smart energy and electric power systems, *International Journal of Energy Research*, 2019, Vol. 43, No. 6, pp. 1928-1973.
6. *Andrianova E.G., Golovin S.A., Zykov S.V., Les'ko S.A., Chukalina E.R.* Obzor sovremennykh modeley i metodov analiza vremennykh ryadov dinamiki protsessov v sotsial'nykh, ekonomicheskikh i sotsiotekhnicheskikh sistemakh [Review of modern models and methods for analyzing time series of process dynamics in social, economic and sociotechnical systems], *Rossiyskiy tekhnologicheskii zhurnal* [Russian Technological Journal], 2020, No. 8 (4), pp. 7-45.
7. *Arutyunov A.L., Ivanyuk V.A., Tsvirkun A.D.* Razrabotka instrumental'nykh sredstv prognozirovaniya v sotsial'no-ekonomicheskikh sistemakh [Development of forecasting tools in socio-economic systems], *Upravlenie razvitiem krupnomasshtabnykh sistem* [Management of large-scale systems development], 2015, pp. 241-293.
8. *Ivanyuk V., Sunchalin A., Sunchalina A.* Development of an intelligent ensemble forecasting system, *Advances in Intelligent Systems and Computing*, 2020, Vol. 1294, pp. 491-500. DOI: 10.1007/978-3-030-63322-6_40.
9. *Parray I.R., Khurana S.S., Kumar M., Altalbe A.A.* Time Series Data Analysis of Stock Price Movement Using Machine Learning Techniques, *Soft Computing*, 2020, No. 24, pp. 16509-16517. Available at: <https://doi.org/10.1007/s00500-020-04957-x>.
10. *Alamir Kh.S., Zargaryan E.V., Zargaryan Yu.A.* Model' prognozirovaniya transportnogo potoka na osnove neyronnykh setey dlya predskazaniya trafika na dorogakh [A model for predicting traffic flow based on neural networks for predicting road traffic], *Izvestiya YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2021, No. 6 (223), pp. 124-132.
11. *Zeletzkiy D.V.* Glubokoe obuchenie v zadache prognozirovaniya finansovykh vremennykh ryadov [Deep learning in the problem of forecasting financial time series], *Tr. Moskovskogo fiziko-tekhnicheskogo instituta* [Transactions of the Moscow Institute of Physics and Technology], 2024, Vol. 16, No. 3 (63), pp. 35-48.

12. Sina L.B., Secco C.A., Blazevic M., Nazemi K. Hybrid Forecasting Methods—A Systematic Review, *Electronics*, 2023, No. 12, pp. 2019. Available at: <https://doi.org/10.3390/electronics12092019>.
13. Alharbi M.H. Prediction of the Price of Advanced Global Stock Markets Using Machine Learning: Comparative Analysis, *Journal of Financial Risk Management*, 2024, Vol. 13, No. 4, pp. 689-702.
14. Ivanyuk V. The method of residual-based bootstrap averaging of the forecast ensemble, *Financial Innovation*, 2023, Vol. 9, No. 1, pp. 37.
15. Wu H., Levinson D. The ensemble approach to forecasting: A review and synthesis, *Transportation Research Part C: Emerging Technologies*, 2021, Vol. 132, pp. 103357.
16. Ke G. et al. Lightgbm: A highly efficient gradient boosting decision tree, *Advances in neural information processing systems*, 2017, Vol. 30.
17. Chen T., Guestrin C. Xgboost: A scalable tree boosting system, *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785-794.
18. Freund Y., Schapire R.E. A decision-theoretic generalization of on-line learning and an application to boosting, *Journal of computer and system sciences*, 1997, Vol. 55, No. 1, pp. 119-139.
19. Posmakov N.P., Emelyanenko A.S., Kireev V.S. Fuzzy Cognitive Map Ensembles to Solve Regression and Time Series Tasks, *2022 Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*. IEEE, 2022, pp. 406-409.
20. Katwal S., Shrestha R., Sharma G. Analysis of Website Traffic Time Series Forecasting using ARIMA, Prophet, and LSTM RNN, *International Journal of Research Publications*, 2024, No. 146 (1), pp. 316-326. doi: 10.47119/IJRP1001461420246271.
21. Wu X. et al. The development of a hybrid wavelet-ARIMA-LSTM model for precipitation amounts and drought analysis, *Atmosphere*, 2021, Vol. 12, No. 1, pp. 74.
22. Podgorskaya S.V. i dr. Postroenie nechetkikh kognitivnykh modeley sotsial'no-ekonomicheskikh sistem na primere modeli upravleniya kompleksnym razvitiem sel'skikh territoriy [Construction of fuzzy cognitive models of socio-economic systems using the example of a management model for integrated development of rural areas], *Biznes-informatika* [Business Informatics], 2019, Vol. 13, No. 3, pp. 7-19.
23. Kholodova M.A., Podvesovskiy A.G., Isaev R.A. Nechetkaya kognitivnaya model' strategicheskogo upravleniya agropodovol'stvennym rynkom [Fuzzy cognitive model of strategic management of the agri-food market], *Modeli, sistemy, seti v ekonomike, tekhnike, prirode i obshchestve* [Models, Systems, Networks in Economics, Technology, Nature and Society], 2022, No. 2 (42), pp. 106-125.
24. Zakharova A.A., Podvesovskiy A.G., Isaev R.A. Nechetkie kognitivnye modeli v upravlenii slabostrukturirovannymi sotsial'no-ekonomicheskimi sistemami [Fuzzy cognitive models in the management of weakly structured socio-economic systems], *Informatsionnye i matematicheskie tekhnologii v nauke i upravlenii* [Information and Mathematical Technologies in Science and Management], 2020, No. 4 (20), pp. 5-23.
25. Zimonina Yu.V., Isaev R.A., Podvesovskiy A.G. Podsystema obmena dannymi v sostave sistemy podderzhki prinyatiya resheniy na osnove kognitivnogo modelirovaniya «IGLA»: arkhitektura i osobennosti realizatsii [Data exchange subsystem as part of the decision support system based on cognitive modeling "IGLA": architecture and implementation features], *Fiziko-tekhnicheskaya informatika (CPT2020)* [Physical and Technical Informatics (CPT2020)], 2020, pp. 12-16.
26. Romanov R.M. Postroenie i primenenie nechetkikh kognitivnykh kart dlya otsenki vliyaniya kapital'nykh projektov na finansovye rezul'taty kompanii [Construction and application of fuzzy cognitive maps for assessing the impact of capital projects on the company's financial results], *Sovremennaya nauka: aktual'nye problemy teorii i praktiki. Seriya: Estestvennye i tekhnicheskie nauki* [Modern Science: Current Problems of Theory and Practice. Series: Natural and Technical Sciences], 2025, No. 1 (2), pp. 62-67. DOI 10.37882/2223-2966.2025.01-2.17.
27. Averkin A.N., Yarushev S.A., Pavlov V.Yu. Kognitivnye gibridnye sistemy podderzhki prinyatiya resheniy i prognozirovaniya [Cognitive hybrid systems for decision support and forecasting], *Programmnye produkty i sistemy* [Software Products and Systems], 2017, Vol. 30, No. 4, pp. 632-642. DOI: 10.15827/0236-235X.120.632-642.
28. Avdeeva Z.K., Grebenyuk E.A., Kovriga S.V. Cognitive modelling-driven time series forecasting for predicting target indicators in non-stationary processes, *IFAC-PapersOnLine*, 2021, Vol. 54, No. 13, pp. 91-96.
29. Kulnich A.A. Komp'yuternye sistemy analiza situatsiy i podderzhki prinyatiya resheniy na osnove kognitivnykh kart: podkhody i metody [Computer systems for situation analysis and decision support based on cognitive maps: approaches and methods], *Problemy upravleniya* [Problems of Management], 2011, No. 4, pp. 31-45.
30. Babeshko L.O., Orlova I.V. Ekonometrika i ekonometriceskoe modelirovanie v Excel i R [Econometrics and econometric modeling in Excel and R], 2021.
31. Handa R. Prediction of foreign exchange rate using regression techniques, 2017.

32. *Yilmaz F.M., Arabaci O.* Should deep learning models be in high demand, or should they simply be a very hot topic? A comprehensive study for exchange rate forecasting, *Computational Economics*, 2021, Vol. 57, No. 1, pp. 217-245.
33. *Hadwan M. et al.* A Hybrid Neural Network and Box-Jenkins Models for Time Series Forecasting, *Computers, Materials & Continua*, 2022, Vol. 70, No. 3.
34. *Pashshoev B., Petrusevich D.A.* Analiz neyrosetevykh modeley dlya prognozirovaniya vremennykh ryadov [Analysis of neural network models for time series forecasting], *Russian Technological Journal* [Russian Technological Journal], 2024, Vol. 12, No. 4, pp. 106-116.
35. *Borisov V.V., Luferov V.S.* Metod mnogomernogo analiza i prognozirovaniya sostoyaniya slozhnykh sistem i protsessov na osnove nechetkikh kognitivnykh temporal'nykh modeley [Method of multivariate analysis and forecasting of the state of complex systems and processes based on fuzzy cognitive temporal models], *Sistemy upravleniya, svyazi i bezopasnosti* [Control, Communications and Security Systems], 2020, No. 2, pp. 1-23. DOI: 10.24411/2410-9916-2020-10201.
36. *Borisov V.V., Fedulov A.S.* «Sovmestimye» nechetkie kognitivnye karty [“Compatible” fuzzy cognitive maps], *Sistemy komp'yuternoy matematiki i ikh prilozheniya* [Systems of Computer Mathematics and Their Applications], 2016, No. 17, pp. 41-43.
37. *Saati T.L.* Prinyatie resheniy pri zavisimostyakh i obratnykh svyazyakh: analiticheskie seti [Decision making with dependencies and feedbacks: analytical networks]: trans. from Engl. by O.N. Andreychikov, scientific ed. A.V. Andreychikov, O.N. Andreychikova. 2nd ed. Moscow: LIBROKOM: URSS, 2009, 357 p. ISBN 978-5-397-00844-0.
38. *Eng K., Chen Y.Y., Kiang J.E.* User's guide to the weighted-multiple-linear-regression program (WREG version 1.0): US Geological Survey Techniques and Methods, book 4, chap, viewed nd, from <http://pubs.usgs.gov/tm/tm4a8>, 2009, pp. 21.
39. *Guseva A.I., Romanov R.M.* Programma dlya EVM «Programmnoe prilozhenie dlya vizualizatsii i postroeniya nechetkikh kognitivnykh kart v zadachakh upravleniya slabo formalizovannymi sistemami», svidetel'stvo o gosudarstvennoy registratsii programmy dlya EVM № 2025660016 ot 21.04.2025. Patentoobladatel' NIYaU MIFI (Rossiya) [Computer program “Software application for visualization and construction of fuzzy cognitive maps in control problems of weakly formalized systems”, certificate of state registration of computer program No. 2025660016 dated April 21, 2025. Patent holder: National Research Nuclear University MEPHI (Russia)], 2025.
40. *Romanov R.M., Guseva A.I.* Programma dlya EVM «Programmnoe sredstvo analiza i postroeniya regressionnoy modeley na osnove metoda analiticheskikh setey dlya slabo formalizovannykh sistem», svidetel'stvo o gosudarstvennoy registratsii programmy dlya EVM № 2025686199 ot 30.09.2025. Patentoobladatel' NIYaU MIFI (Rossiya) [Computer program “Software for analysis and construction of regression models based on the analytical network method for weakly formalized systems”, certificate of state registration of computer program No. 2025686199 dated September 30, 2025. Patent holder: National Research Nuclear University MEPHI (Russia)], 2025.

Гусева Анна Ивановна – Национальный исследовательский ядерный университет «МИФИ»; e-mail: aiguseva@mephi.ru; г. Москва, Россия; тел.: 89037530059; д.т.н.; профессор кафедры экономики и менеджмента в промышленности.

Романов Родион Модестович – Национальный исследовательский ядерный университет «МИФИ»; e-mail: rodion.romanov.m@yandex.com; г. Москва, Россия; тел.: 89859567629; инженер-исследователь кафедры экономики и менеджмента в промышленности.

Guseva Anna Ivanovna – National Research Nuclear University MEPHI; e-mail: aiguseva@mephi.ru; Moscow, Russia; phone: +79037530059; dr. of eng. sc.; professor of Department of Economics and Management in Industry.

Romanov Rodion Modestovich – National Research Nuclear University MEPHI; e-mail: rodion.romanov.m@yandex.com; Moscow, Russia; phone: +79859567629; Research of Engineer Department of Industrial Economics and Management.