

УДК 004.032.26

DOI 10.17513/snt.40243

## НЕЙРОСЕТЕВАЯ МОДЕЛЬ ДЛЯ ПРОГНОЗИРОВАНИЯ ЦЕН НА МОДИФИЦИРОВАННЫЕ БИТУМНЫЕ ВЯЖУЩИЕ

Кондратьева М.И., Бронская В.В., Емельянычева Е.А.,  
Шипин А.В., Башкиров Д.В., Игнашина Т.В.

ФГБОУ ВО «Казанский национальный исследовательский технологический университет»,  
Казань, e-mail: kondratteva@yandex.ru

Целью работы является разработка нейросетевой модели для прогнозирования стоимости модифицированных битумных вяжущих, позволяющей учитывать сезонные колебания цен на компоненты и облегчить их оценку для производителей. В рамках исследования были собраны и проанализированы данные о ценах на компоненты для вяжущих с января 2021 года по август 2024 года, предоставленных Федеральной службой государственной статистики, и средние цены на марки PG 76-28, PG 76-34 и PG 76-40, полученные государственной компанией «Автодор». Модель основана на рекуррентной нейронной сети с использованием LSTM-слоев, что позволяет выявлять временные зависимости в данных. Разработка модели велась в облачной среде Google Colaboratory на языке Python с применением библиотек TensorFlow и Sklearn, что обеспечило гибкость и доступность для работы с большими объемами данных. Прогнозирование цен выполняется с высокой точностью, достигающей 97%, на период до мая 2025 года. Полученные результаты являются инструментом, который может применяться в планировании производственной и экономической деятельности в дорожных компаниях, на производственных площадках и в отделах планирования и экономики производителей битумных вяжущих.

**Ключевые слова:** модифицированные битумные вяжущие, прогнозирование цен, нейросетевое моделирование, рекуррентные нейросети

*Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках государственного задания на оказание государственных услуг (выполнение работ) от 29.12.2022 г. № 075-01508-23-00. Тема исследования «Сверхкритические флюидные технологии в переработке полимеров».*

## NEURAL NETWORK MODEL FOR PREDICTING THE COST OF MODIFIED ASPHALT BINDERS

Kondrateva M.I., Bronskaya V.V., Emelyanycheva E.A.,  
Shipin A.V., Bashkirov D.V., Ignashina T.V.

Kazan National Research Technological University, Kazan, e-mail: kondratteva@yandex.ru

The growth in road construction volumes driven by the implementation of government infrastructure projects is stimulating the development of the modified bituminous binders market. Seasonal fluctuations in the prices of components for these binders complicate the assessment of their cost and profitability. To address this issue, a neural network-based model has been developed to predict price trends for binders according to GOST R 58400-2019. The study involved collecting and analysing data on component prices for modified binders from January 2021 to August 2024, provided by the Federal State Statistics Service, as well as data from the State Company «Russian Highways» on average prices for grades PG 76-28, PG 76-34, and PG 76-40 over the same period. The model is built on a recurrent neural network with LSTM layers, capable of analysing temporal dependencies and forecasting prices up to May 2025. The research was conducted using the Google Colaboratory cloud service in Python with the TensorFlow and Sklearn libraries, enabling a forecast accuracy level of 97%. The results obtained can subsequently be used in planning, providing a tool for managing production and economic activities for road companies, production sites, and the planning and economic departments of modified bituminous binder manufacturers.

**Keywords:** modified bituminous binders, price forecasting, neural network modelling, recurrent neural networks

*The work was carried out with the financial support of the Ministry of Science and Higher Education of the Russian Federation within the framework of the state assignment for the provision of public services (performance of works) dated 12/29/2022, No. 075-01508-23-00. Research topic «Supercritical fluid technologies in polymer processing».*

### Введение

В последние годы в России наблюдается значительное увеличение объемов дорожного строительства. Это связано с реализацией таких крупных проектов, как Национальный проект «Безопасные и качественные дороги» от 2018 года, «Транспортная стратегия Российской Федерации до 2030 года

с прогнозом до 2035 года», а также расширенный пятилетний план дорожного строительства на 2024–2028 годы, утвержденный распоряжением Правительства Российской Федерации от 25 декабря 2023 года. Данные программы способствуют активному строительству транспортных коридоров, что, в свою очередь, стимулирует рост рынка битумных вяжущих.

Анализ рынка битумных вяжущих показывает, что за последние десять лет производство модифицированных битумных вяжущих в российской дорожно-строительной отрасли удвоилось, значительно опережая развитие рынка базового битума [1]. Модифицированное битумное вяжущее – это продукт, получаемый путем применения современных технологий производства битума и его смешения с различными модификаторами-добавками. Чаще всего основным компонентом для модификации дорожных битумов являются линейные термоэластопласты на основе стирол-бутадиен-стирола (СБС), которые придают модифицированному битумному вяжущему повышенную эластичность, расширенный интервал работоспособности, высокую трещиностойкость и теплостойкость [2, с. 48–49]. В результате получаемый материал с улучшенными эксплуатационными характеристиками обеспечивает дорожному полотну высокое качество и долговечность, что является ключевыми факторами для обеспечения безопасной и надежной инфраструктуры нашей страны.

Модифицированные битумные вяжущие выпускаются в том числе по технологии SuperPave (Superior Performance Pavements – дорожное покрытие с превосходными характеристиками), адаптированной в России в стандарт ГОСТ Р 58400-2019, который позволяет маркировать вяжущие с учетом их реологических характеристик. Согласно данному стандарту, битумное вяжущее выпускается под марками PG X-Y, где X – верхнее значение марки, соответствующее максимально допустимой температуре эксплуатации битума, а Y – нижнее значение марки, соответствующее минимально допустимой температуре эксплуатации. Применение данного стандарта способствует улучшению качества дорог и повышению их устойчивости к различным эксплуатационным воздействиям и климатическим условиям [3].

Несмотря на явные преимущества модифицированных битумных вяжущих, сезонные колебания цен и спроса на их компоненты создают сложность при оценке конечной стоимости вяжущего и прогнозировании конечной прибыли. Решением является применение искусственной нейронной сети, способной прогнозировать стоимость модифицированных битумных вяжущих. Такой подход позволит более точно оценивать затраты и планировать бюджет дорожных проектов, минимизируя риски и повышая их экономическую эффективность.

Искусственная нейронная сеть (ИНС) – это абстрактная модель, созданная в со-

ответствии с принципами биологических нейронных сетей, и ее программная или аппаратная реализация. Она состоит из совокупности простых и взаимосвязанных «искусственных нейронов», каждый из которых обрабатывает входные сигналы и передает сигналы другим нейронам [4]. Применение современных ИНС, таких как глубокие нейронные сети (DNN) и рекуррентные нейронные сети (RNN), включая их разновидности, такие как LSTM и GRU, позволило достигнуть значительных успехов в различных областях, включая компьютерное зрение, обработку естественного языка, медицинскую диагностику и финансовые прогнозы [5].

Рекуррентные нейронные сети (RNN) имеют обратные (или перекрестные) связи между нейронами разных слоев, что позволяет им запоминать и воспроизводить последовательности реакций на стимулы. В отличие от классических нейронных сетей, лишенных рекуррентных связей, которые не могут сохранять информацию, рекуррентные сети способны использовать предыдущие выводы для принятия последующих решений [6, 7]. Рекуррентные нейронные сети (RNN) – это тип искусственных нейронных сетей, который обрабатывает последовательные данные, такие как временные ряды, тексты или звуковые сигналы. Проблема затухания или взрыва градиентов при обучении на длинных последовательностях решается с помощью улучшенных архитектур RNN, таких как LSTM и GRU. Эти архитектуры включают механизмы, которые помогают запоминать и контролировать информацию на длительных временных интервалах. RNN широко применяются в задачах обработки естественного языка, распознавания речи, машинного перевода, прогнозирования временных рядов и анализа последовательностей данных [8].

Слой LSTM (Long Short-Term Memory) являются ключевыми элементами рекуррентных нейронных сетей, предназначенными для работы с последовательными данными и временными рядами. Они способны запоминать информацию на длительные промежутки времени, решая проблему исчезающего градиента, часто встречающуюся в традиционных RNN. Каждый слой LSTM состоит из входных, выходных и забывающих ворот, которые контролируют поток информации в ячейке памяти, и самой ячейки памяти, которая хранит информацию. Ворота регулируют, какую часть новой информации сохранить, какую передать на следующий шаг и какую забыть. Использование LSTM-слоев позволяет нейронной сети эффективно обрабатывать дан-

ные с временными зависимостями, такие как последовательности текста, временные ряды и другие последовательные данные.

Таким образом, целью исследования явилась разработка нейросетевой модели по прогнозированию стоимости модифицированных битумных вяжущих на период до февраля 2025 года с использованием рекуррентных нейросетей.

#### Материалы и методы исследования

Нейросетевая модель разрабатывалась в облачном сервисе Google Colaboratory (сокращенно Google Colab) на основе Jupiter Notebook. Данный облачный сервис позволяет работать на языке программирования Python с большим количеством данных (Big Data) без установки дополнительных программ. Благодаря встроенным в программу готовым библиотекам (таким как Sklearn, TensorFlow, PyTorch) Google Colab весьма удобен и эффективен для разработки и тестирования рекуррентных нейронных сетей за счет использования знакомых инструментов и фреймворков. Также данный сервис предоставляет бесплатный доступ к мощным графиче-

ским процессорам (GPU) и тензорным процессорам (TPU), что значительно ускоряет процесс обучения сложных моделей, таких как RNN.

В качестве объекта прогнозирования выбраны марки вяжущих PG 76-28, PG 76-34 и PG 76-40 по ГОСТ 58400-2019 ввиду высокого спроса на них при производстве асфальтобетонных смесей. В целях создания базы данных для построения нейросетевой модели использовались данные из Федеральной службы государственной статистики (Росстат) с января 2021 года по август 2024 года об изменении цен на компоненты для модифицированных битумных вяжущих [9] и средняя стоимость дорожных битумных материалов по ГОСТ 58400-2019 с января 2021 года по август 2024 года по данным Государственной компании «Российские автомобильные дороги» (ГК «Автомдор») [10]. Для доказательства взаимосвязи конечной цены модифицированных вяжущих от цен на их компоненты был произведен расчет материальных затрат на выбранные марки модифицированных вяжущих PG X – Y по данным из Росстата по формуле 1:

$$M_{PG} = B \cdot (0,95 \div 0,97) + СБС \cdot (0,03 \div 0,05), \text{ руб.} \quad (1)$$

где B – средняя цена за 1 т базового битума на рассчитываемый месяц, руб.;

СБС – средняя цена за 1 т СБС на рассчитываемый месяц, руб.

Диапазон содержания добавки-термоэластопласта подбирался исходя из ориентировочной рецептуры на данные марки модифицированных вяжущих.

#### Данные для обучения нейросети

| Марка по ГОСТ Р 58400-2019                   | январь | февраль | март  | апрель | май   | июнь  | июль  | август | сентябрь | октябрь | ноябрь | декабрь |
|----------------------------------------------|--------|---------|-------|--------|-------|-------|-------|--------|----------|---------|--------|---------|
| Приблизительная цена за 2021 год, руб. / 1 т |        |         |       |        |       |       |       |        |          |         |        |         |
| PG 76-28                                     | 29566  | 31512   | 31864 | 34310  | 35626 | 38082 | 42014 | 43165  | 43316    | 44379   | 44379  | 36316   |
| PG 76-34                                     | 30851  | 32882   | 33249 | 35802  | 37175 | 39739 | 43842 | 45043  | 45201    | 45094   | 46309  | 37895   |
| PG 76-40                                     | 32137  | 34252   | 34635 | 37294  | 38723 | 41394 | 45668 | 46919  | 47084    | 46973   | 48239  | 39474   |
| Приблизительная цена за 2022 год, руб. / 1 т |        |         |       |        |       |       |       |        |          |         |        |         |
| PG 76-28                                     | 37880  | 43117   | 44439 | 43489  | 43052 | 44055 | 45882 | 45469  | 45801    | 44951   | 40509  | 31864   |
| PG 76-34                                     | 39526  | 44990   | 46369 | 45378  | 44922 | 45969 | 47876 | 47445  | 47792    | 46905   | 42270  | 33249   |
| PG 76-40                                     | 41174  | 46866   | 48303 | 47270  | 46795 | 47886 | 49872 | 49423  | 49784    | 48860   | 44032  | 34635   |
| Приблизительная цена за 2023 год, руб. / 1 т |        |         |       |        |       |       |       |        |          |         |        |         |
| PG 76-28                                     | 35626  | 31513   | 36616 | 37881  | 43117 | 44438 | 43488 | 43052  | 43569    | 50985   | 49114  | 37494   |
| PG 76-34                                     | 37175  | 32883   | 38208 | 39528  | 44992 | 46370 | 45379 | 44923  | 45462    | 53201   | 51249  | 39124   |
| PG 76-40                                     | 38723  | 34253   | 39800 | 41175  | 46867 | 48302 | 47269 | 46795  | 47356    | 55417   | 53384  | 40754   |
| Приблизительная цена за 2024 год, руб. / 1 т |        |         |       |        |       |       |       |        |          |         |        |         |
| PG 76-28                                     | 36599  | 35637   | 38853 | 46000  | 48000 | 49450 | 51360 | 50000  | 43000    | 37000   |        |         |
| PG 76-34                                     | 38191  | 37187   | 40543 | 48000  | 50000 | 51000 | 53450 | 54560  | 46000    | 39800   |        |         |
| PG 76-40                                     | 39782  | 38736   | 42232 | 50000  | 52000 | 54500 | 55250 | 56450  | 51000    | 49000   |        |         |

Анализ полученных материальных затрат в сравнении со средними ценами на вяжущие по данным ГК «Автодор» показал, что существует четкая зависимость итоговой цены вяжущего от стоимости его компонентов. Это позволяет утверждать, что для эффективного прогнозирования цен на модифицированные битумные вяжущие необходимо учитывать изменения цен на их составляющие компоненты.

Исходные данные для обучения нейронной сети представлены в таблице.

### Результаты исследования и их обсуждение

Исходным этапом разработки рекуррентной нейросетевой модели является загрузка данных о ценах на битум из Excel-файла при использовании библиотеки Pandas для чтения данных и их проверки. Далее эти данные о ценах на выбранные марки модифицированных битумных вяжущих были преобразованы в формат, удобный для дальнейшей обработки. Данный этап работ изображен на рисунке 1.

Для того чтобы нейронная сеть в дальнейшем могла эффективно обучаться, данные были нормализованы с использовани-

ем функции MinMaxScaler из библиотеки Sklearn путем приведения всех цен к диапазону от 0 до 1. Это улучшает производительность модели и упрощает процесс обучения. После этого данные были преобразованы в формат, подходящий для LSTM, с использованием функции create\_dataset: входные данные представляли собой последовательности цен за несколько предыдущих месяцев, а целевые значения – это цены в следующих месяцах.

Перед обучением искусственной нейронной сети важно выполнить масштабирование данных. Один из популярных методов – стандартизация, которая осуществляется путем вычитания среднего значения и деления на стандартное отклонение для каждого признака. Также можно использовать метод tf.keras.utils.normalize, который масштабирует значения в диапазон [0,1]. Данные подаются для модели с одномерным входом, где на вход подаются последние шесть наблюдений за ценами на модифицированные битумные вяжущие, а модель будет обучаться прогнозировать цены на следующий временной шаг. Эти этапы работ изображены на рисунке 2.

```
1 import pandas as pd
2 import numpy as np
3 from sklearn.preprocessing import MinMaxScaler
4 from tensorflow.keras.models import Sequential
5 from tensorflow.keras.layers import LSTM, Dense
6 df = pd.read_excel('/content/Цены.xlsx')
7 df
8 df.iloc[16:17].values
```

Рис. 1. Импорт библиотек и входных данных

```
1 bitumen_prices_reshaped = np.array(PG_76_22).reshape(-1, 1)
2 scaler = MinMaxScaler()
3 normalized_data = scaler.fit_transform(bitumen_prices_reshaped
4 )
5 def create_dataset(data, time_steps=1):
6     X, y = []
7     for i in range(len(data) - time_steps):
8         X.append(data[i:(i + time_steps)])
9         y.append(data[i + time_steps])
10    return np.array(X), np.array(y)
11 time_steps = 6
12 X, y = create_dataset(normalized_data, time_steps)
```

Рис. 2. Преобразование данных

```
1 train_size = int(len(X) * 0.8)
2 X_train, X_test = X[:train_size], X[train_size:]
3 y_train, y_test = y[:train_size], y[train_size:]
4 model = Sequential()
5 model.add(LSTM(units=200, return_sequences=True, input_shape
   = (X_train.shape[1], X_train.shape[2]))) # Первый слой
   LSTM
6 model.add(LSTM(units=150, return_sequences=True)) # Второй
   слой LSTM
7 model.add(LSTM(units=100, return_sequences=True)) # Третий
   слой LSTM
8 model.add(LSTM(units=50, return_sequences=True)) # Четвертый
   слой LSTM
9 model.add(LSTM(units=25)) # Пятый слой LSTM
10 model.add(Dense(units=1)) # Выходной слой
11 model.compile(optimizer='adam', loss='huber_loss')
12 model.fit(X_train, y_train, epochs=350, batch_size=12, verbose
   =2)
```

Рис. 3. Обучение нейросетевой модели

```
1 future_time_steps = 10
2 future_data = np.copy(normalized_data[-time_steps:])
3 predictions = []
4 for _ in range(future_time_steps):
5     prediction = model.predict(future_data[-time_steps:]
   .reshape(1, time_steps, 1))
6     predictions.append(prediction[0][0])
7     future_data = np.append(future_data, prediction)
8
9 predicted_prices = scaler.inverse_transform(np.array
   (predictions).reshape(-1, 1))
10 print(predicted_prices)
```

Рис. 4. Прогнозирование цен

Для обучения было использовано 80% массива данных, а для тестирования – проверки точности модели – 20%. Созданная с использованием библиотек TensorFlow и Keras модель рекуррентной нейронной сети включала несколько слоев LSTM, каждый из которых помогал модели запоминать долгосрочные зависимости данных. В модели были задействованы несколько LSTM-слоев с функцией активации 'relu' и один выходной слой Dense. Нейросетевая модель была скомпилирована с использованием оптимизатора Adam и функцией потерь huber\_loss, после чего была обучена на обучающих данных в течение 350 эпох

с помощью метода model.fit. Все эти шаги изображены на рисунке 3.

После обучения модель использовалась для прогнозирования цен на модифицированные битумные вяжущие по маркам PG X-Y на следующие 10 месяцев, ее код изображен на рисунке 4. Выбор периода в 10 месяцев для прогнозирования цен на вяжущие обусловлен реальными возможностями модели и ограничениями, связанными с внешними факторами. Для создания прогнозируемых данных использовался метод 'model.predict', в котором предсказанные значения поэтапно добавляются в последовательность.




Рис. 5. Сравнение данных ГК «Автодор» и предсказания искусственной нейронной сети на примере PG 76-28 (Серая линия данные ГК «Автодор», красные линия и точки – предсказание искусственной нейронной сети)

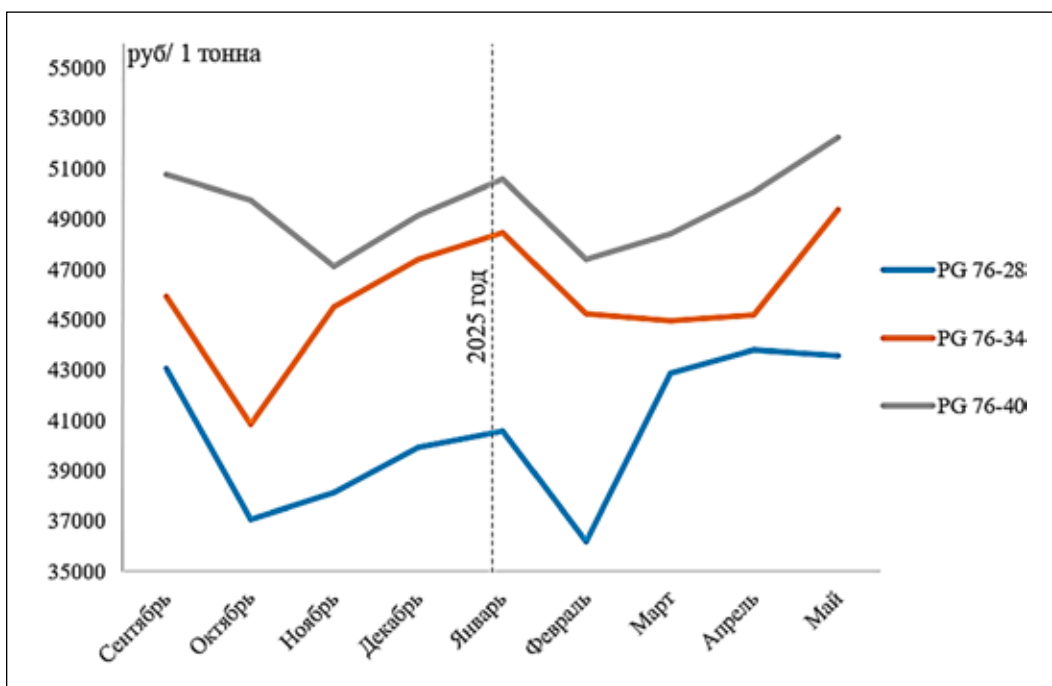


Рис. 6. Спрогнозированные цены на модифицированные битумные вяжущие

Точность модели определялась исходя из имеющихся данных, размещенных в ГК «Автодор», о средней стоимости битумных вяжущих на период сентябрь-октябрь 2024 года (таблица) и данных, рассчитанных

нейросетевой моделью на этот же период (рис. 5). Точность предсказания составила 97%. Данные о прогнозируемых ценах на марки битума PG 76-28, PG 76-34, PG 76-40 представлены на рисунке 6.

### Заключение

Разработанная рекуррентная нейросетевая модель для прогнозирования динамики цен на модифицированные битумные вяжущие по ГОСТ Р 58400-2019 PG X-Y на 10 месяцев до мая 2025 года представляет собой важный инструмент в области планирования и управления производственно-экономической деятельностью. Дорожные компании могут использовать ее для анализа динамики цен на разные марки модифицированных вяжущих, что помогает в планировании и управлении строительными проектами, оптимизируя затраты и стратегии закупок. Производственные площадки могут с ее помощью прогнозировать спрос на марки PG X-Y и соответственно регулировать объемы производства модифицированного битума, что способствует более эффективной организации производства и снижению издержек. Для планово-экономических отделов производственных компаний модель позволяет оценивать влияние цен компонентов модифицированного вяжущего на проектные материальные затраты конечного продукта и прогнозировать маржинальную прибыль, основываясь на данных о цене конкретной марки PG X-Y и проектных материальных затратах продаваемого продукта.

Таким образом, разработанная нейросеть служит эффективным средством для различных аспектов деятельности, связанных с производством и применением модифицированных битумных вяжущих, обеспечивая точное прогнозирование и содействуя стратегическому планированию.

### Список литературы

1. Орлов Д.В. PRO битум и ПБВ – сделано в России // Доклады 2023. Межотраслевая конференция «PRO Битум и ПБВ». 2023. [Электронный ресурс]. URL: <https://www.probitum.pro/report> (дата обращения: 10.05.2024).
2. Абдуллин А.И., Ганиева Т.Ф., Идрисов М.Р., Емельянычева Е.А., Бикмухаметова Г.К., Сибгатуллина Р.И. Битумные вяжущие материалы: учебное пособие. СПб.: Проспект Науки, 2017. 208 с.
3. ГОСТ Р 58400.1-2019. Дороги автомобильные общего пользования. Материалы вяжущие нефтяные битумные. Технические условия с учетом температурного диапазона эксплуатации. М.: Стандартинформ, 2019. 12 с.
4. Bronskaya V.V., Balzamov D.S., Ignashina T.V., Shaikhedinova R.S., Kharitonova O.S., Kondrateva M.I. Improving the efficiency of the water treatment system at the thermal station // EDP Sciences: EDP Sciences, 2023. Vol. 390. P. 05010. DOI: 10.1051/e3sconf/202339005010.
5. Balzamov D.S., Balzamova E.Yu., Bronskaya V.V., Ignashina T.V., Kharitonova O.S. Analysis of the possibility of modernization of the state district power station by building the combined cycle plant // IOP Conference Series: Metrological Support of Innovative Technologies. Krasnoyarsk Science and Technology City Hall of the Russian Union of Scientific and Engineering Associations. 2020. Vol. 1515. P. 042100. DOI: 10.1088/1742-6596/1515/4/042100.
6. Frolov I.N., Firsin A.A., Okhotnikova E.S., Yusupova T.N., Ziganshin M.A. The study of bitumen by differential scanning calorimetry: the interpretation of thermal effects // Petroleum Science and Technology. 2019. Vol. 37. P. 417-424. DOI: 10.1080/10916466.2018.1550499.
7. Okhotnikova E.S., Ganeeva Y.M., Firsin A.A., Yusupova T.N., Frolov I.N. Rheological behavior of recycled polyethylene modified bitumens // Petroleum Science and Technology. 2019. Vol. 37. P. 1136-1142. DOI: 10.1080/10916466.2019.1578796.
8. Ke-Lin De, M.N.s. Swamy Recurrent Neural Networks// Neural Networks and Statistical Learning. 2014. P. 337-353. DOI: 10.1007/978-1-4471-5571-3\_11.
9. Федеральная служба государственной статистики: официальный сайт. Москва, 2024. [Электронный ресурс]. URL: <https://rosstat.gov.ru/> (дата обращения: 15.10.2024).
10. ГК «Автодор». Москва, 2024. [Электронный ресурс]. URL: <https://russianhighways.ru/about/> (дата обращения: 17.10.2024).