

УДК 519.876.2

DOI 10.52575/2687-0932-2023-50-4-924-935

## **Представление данных о состоянии популяции и обучение искусственной нейронной сети в задаче управления работой генетическим алгоритмом**

**Петросов Д. А., Андриянов Н.А., Алюнов А.Н., Нежданов Е.В.**

Финансовый университет при Правительстве РФ,

Россия, 125468, г. Москва, Ленинградский проспект, д. 49.

E-mail: dapetrosov@fa.ru, naandriyanov@fa.ru, analyunov@fa.ru, 9207457@mail.ru

**Аннотация.** В статье рассматривается возможность применения рекуррентной искусственной нейронной сети для решения задачи управления генетическим алгоритмом при структурно-параметрическом синтезе имитационных моделей бизнес-процессов. В качестве входов для выбранного класса сетей рассматривается значение функции приспособленности особей популяции, сгруппированных по количеству одинаковых значений. Такого рода подход позволяет стандартизировать размерность входов нейронной сети для популяций различной размерности. В работе представлены примеры данных, полученных при работе адаптированного к решению задачи структурно-параметрического синтеза имитационных моделей бизнес-процессов генетического алгоритма и их визуализация, которые использовались для обучения искусственной нейронной сети. На основе вычислительных данных эксперимента было проведено обучение нескольких видов моделей искусственных нейронных сетей с целью определения класса сетей, способных определить состояние популяции генетического алгоритма в процессе поиска решений. В работе приведены результаты обучения различных искусственных нейронных сетей современными методами глубокого обучения.

**Ключевые слова** имитационное моделирование, рекуррентный класс сетей, эволюционные процедуры, структурно-параметрический синтез, моделирование, глубокое обучение, бизнес-процессы

**Благодарности:** Работа выполнена при финансовой поддержке РФФ (проект №23-31-00127)

**Для цитирования:** Петросов Д.А., Андриянов Н.А., Алюнов А.Н., Нежданов Е.В. 2023. Представление данных о состоянии популяции и обучение искусственной нейронной сети в задаче управления работой генетическим алгоритмом. Экономика. Информатика. 50(4): 924–935. DOI: 10.52575/2687-0932-2023-50-4-924-935

---

## **Presentation of Data on the State of the Population and Training of an Artificial Neural Network in the Problem of Controlling the Operation of a Genetic Algorithm**

**David A Petrosov, Nikita A. Andriyanov, Alexander N. Alyunov, Evgeniy V. Nezhdanov**

Financial University under the Government of the Russian Federation,

Russia, 125468, Moscow, Leningradsky Prospekt, 49

E-mail: dapetrosov@fa.ru, naandriyanov@fa.ru, analyunov@fa.ru, 9207457@mail.ru

**Abstract.** The article discusses the possibility of using a recurrent artificial neural network to solve the problem of controlling a genetic algorithm in the structural-parametric synthesis of simulation models of business processes. As inputs for the selected class of networks, the value of the fitness function of individuals in the population grouped by the number of identical values is considered. This kind of approach allows us to standardize the dimension of neural network inputs for populations of different dimensions. The paper presents examples of data obtained during the work of structural-parametric

synthesis of simulation models of business processes of a genetic algorithm, adapted to the solution of the problem, and their visualization, which were used to train an artificial neural network. Based on the data from the computational experiment, several types of artificial neural networks were trained in order to determine a class of networks capable of determining the state of the population of a genetic algorithm in the process of searching for solutions. The paper presents the results of training various artificial neural networks using modern deep learning methods.

**Keywords:** simulation modeling, recurrent class of networks, evolutionary procedures, structural-parametric synthesis, modeling, deep learning, business processes

**Acknowledgements:** The work was carried out with the financial support of the Russian Science Foundation (project No. 23-31-00127)

**For citation:** Petrosov D.A., Andriyanov N.A., Alyunov A.N., Nezhdanov E.V. 2023. Presentation of Data on the State of the Population and Training of an Artificial Neural Network in the Problem of Controlling the Operation of a Genetic Algorithm. *Economics. Information technologies*. 50(4): 924–935 (in Russian). DOI: 10.52575/2687-0932-2023-50-4-924-935

## Введение

Современные подходы к решению ресурсоемких задач требуют разработки новых методов, которые позволят использовать в вычислениях не только суперкомпьютеры, облачные технологии, вычислительные мощности или GRID-системы, но и применять CPU или CPU+GPGPU на персональном компьютере. К подобного рода вычислениям можно отнести задачи, связанные со структурно-параметрическим синтезом имитационных моделей бизнес-процессов с заданным поведением. В современных исследованиях при решении данной задачи предлагается использование интеллектуальных методов на основе эволюционных процедур, к которым относятся генетические алгоритмы. [Шишкова, 2017; Петросов, Зеленина, 2020; Valerian, Sutrisno, Herwindiati, 2020; Petrosov, Lomazov, Petrosova, 2021; Давронов, 2023]

Проблема применения генетических алгоритмов в задачах, основанных на больших количествах комбинаций решений (к которым относится синтез моделей на заданной элементной базе и комбинировании межэлементных связей на основе заданного поведения), заключается в возможности возникновения частых затуханий и нахождения популяции в локальных экстремумах. Для решения данной проблемы в современных исследованиях предлагается:

- выполнять тщательный выбор и настройку параметров функционирования операторов генетического алгоритма для решения задач в конкретной предметной области;
- совместное использование двух взаимосвязанных генетических алгоритмов, где основной генетический алгоритм выполняет задачу поиска решений, в то время как второй генетический алгоритм решает задачу оптимизации параметров работы основной эволюционной процедуры;
- использование дополнительных операторов генетического алгоритма, которые также адаптируют работу основных операторов к решению задачи [Чеканин, Куликова, 2017, Голышин, 2018; Денисов, Сопов, 2021; Сапрыкина, 2022а; Сапрыкина, 2022б; Дрозин, 2023; Шегай, Попова, 2023; Софронова, 2023; Hahn et al., 2023].

В данном исследовании предлагается использовать COGAN подход, который объединяет в себе возможности генетического алгоритма (ГА) и искусственных нейронных сетей (ИНС). В отличие от распространенного применения COGAN, базирующегося на применении генетического алгоритма (ГА) при обучении искусственной нейронной сети (ИНС), предлагается использовать ИНС в качестве управляющей надстройки, которая изменяет параметры работы операторов ГА в зависимости от состояния популяции.

Для управления процессом поиска предлагается изменять параметры работы операторов ГА, тем самым изменяя их разрушающую способность. Такого рода подход позволит управлять процессом поиска решений и задавать траекторию движения популяции в пространстве решений.

Состояние популяции целесообразно оценивать на основе значений функции приспособленности особей, но структура представления данных может значительно влиять на размерность, обучаемость и работу ИНС.

### Объекты и методы исследования

Объектом исследования в данной работе является ИНС, задача которой сводится к определению и прогнозированию состояния популяции ГА в процессе поиска решений.

В качестве класса ИНС для решения данной задачи были выбраны рекуррентные нейронные сети, которые показали достаточный уровень обучения для решения поставленной задачи при обучении на данных о значении функции приспособленности всех особей популяции (см. рис. 1). В качестве структуры предложено использование: номера особи в популяции (ось абсцисс) и значение функции приспособленности (ось ординат). При этом используются все значения функции приспособленности и возникает проблема, связанная с количеством особей в популяции, так как при решении задач различной размерности экспертами могут быть выполнены разные настройки и эти настройки могут быть изменены в зависимости от решаемых задач, а это повлечет изменения в количестве нейронов во входном слое и как следствие к изменению всей структуры ИНС и повторению процедуры обучения.




Рис. 1. Пример структуры представления данных о состоянии популяции ГА  
Fig. 1. An example of a structure for presenting data on the state of a GA population

В качестве классов состояний популяции ГА рассматриваются следующее:

1. «сходимость»;
2. «наметилась сходимость»;
3. «затухание»;
4. «наметилось затухание»;
5. «невмешательство»;
6. «остановка работы генетического алгоритма».

Для определения класса состояния предлагается применение подхода, который рассматривает значение функции приспособленности особей популяции, сгруппирован-

ных по количеству одинаковых значений в качестве входов для ИНС (см. пример рис. 2). В предложенной структуре данных по оси абсцисс показаны возможные значения функции приспособленности, а по оси ординат – количество особей, обладающих одинаковым значением.

В качестве методов глубокого обучения используются:

1. машина опорных векторов;
2. дерево решений;
3. случайный лес.

В качестве классов нейронных сетей рассматриваются:

1. полносвязанная сеть (4 слоя: 32-64-128-256);
2. LTSTM (128+256);
3. RNN (128+256);
4. GRU (128+256);
5. BiLSTM (128+256+DO).

Обучающая выборка содержит результаты вычислительных экспериментов, полученных при решении задачи структурно-параметрического синтеза имитационных моделей бизнес-процессов на основе элементной базы, описанных сетью Петри ( $PN_{IDEF3}$ ). В элементную базу входит 560 моделей, описанных с применением сетей Петри (за основу взят подход описания технологических особенностей бизнес-процессов в нотации IDEF3: внешние источники объектов, единицы работы, логические перекрестки). Количество входов для синтезируемого процесса – 100 (вектор  $Z_{IN}$ ), а количество выходов – 300 (вектор  $Z_{OUT}$ ). Структура бизнес-процесса – 25 взаимосвязанных подпроцесса. Начальный размер популяции более 30000 особей.

Синтезируемая модель бизнес-процесса должна обладать заданным свойством, то есть способность преобразовывать заданный входной сигнал в эталонный выходной. Тогда заданным свойством модели будем называть пару неотрицательных целочисленных векторов

$$Z_{IN} = (z_1^{IN}, \dots, z_{v_0}^{IN}) \quad \text{и} \quad Z_{OUT} = (z_1^{OUT}, \dots, z_{w_0}^{OUT}),$$

где  $Z_v^{IN}$  – число меток, поступивших в  $v$ -ую входную позицию перед запуском сети  $PN_{IDEF3}$ , моделирующую бизнес-процесс,  $Z_w^{OUT}$  – число меток, появившихся в  $w$ -ой выходной позиции после остановки сети  $PN_{IDEF3}$ ,  $v_0$  и  $w_0$  – число элементов множеств  $IN$  и  $OUT$  соответственно.

Таким образом, поставленная задача сводится к следующей. Среди всех гипотетически возможных моделей бизнес-процесса  $PN_{IDEF3}$  требуется найти такую, которая обладает свойством  $Z_k$ .

Для того, чтобы проверить, обладает ли модель  $PN_{IDEF3}$  свойством  $Z_k$ , необходимо сформировать эту модель, на ее вход  $IN$  подать вектор  $Z_{IN}^K$ , запустить сеть  $PN$  и после ее остановки сравнить количество меток на выходе  $OUT$  с вектором  $Z_{OUT}^K$ .

Меру близости будем определять, привлекая понятие метрического пространства и рассматривая полученный вектор  $Z_{OUT}$  и эталонный вектор  $Z_{OUT}^K$  как элементы евклидова пространства  $\mathfrak{R}^{W_0}$  – множества упорядоченных наборов из  $W_0$  действительных чисел  $x = (x_1, \dots, x_{W_0})$  с расстоянием

$$\rho_1(x, y) = \sum_{w=1}^{W_0} |x_w - y_w|,$$

где  $y = (y_1, \dots, y_{W_0})$ .

Чем меньше  $\rho_1(Z_{OUT}, Z_{OUT}^K)$ , тем ближе модель  $PN_{IDEF3}$  к свойству  $Z_k$ , при  $\rho_1(Z_{OUT}, Z_{OUT}^K)=0$  модель  $PN$  обладает свойством  $Z_k$ . Расстояние  $\rho_1$  будет рассматриваться как целевая функция. Модель  $PN$  должна обладать свойством  $Z_k$ .

Значение целевой функции может быть только целочисленным, так как количество меток в позициях сети Петри является целочисленным.

### Результаты и их обсуждение

Рассмотрим примеры входных данных, которые использовались в качестве обучающей выборки. Генетический алгоритм решает задачу минимизации целевой функции при синтезе имитационной модели бизнес-процесса на основе моделей элементной базы, построенной с применением математического аппарата теории сетей Петри. ИНС должна вмешиваться в работу ГА при возникновении классов состояния популяции 3, 4 и 6 состояния популяции. При вмешательстве ИНС должна регулировать разрушающую способность операторов ГА в большую или меньшую сторону в зависимости от состояния популяции.

При определении такого состояния популяции, как «сходимость», при обучении рекуррентной ИНС рассматривались примеры, подобные представленному на рисунке 2.

Как видно из представленного примера, при решении задачи минимизации количество особей со значением 0 значительное, то есть искомое решение найдено.




Рис.2. Пример состояния популяции «сходимость»  
Fig.2. Example of a population state «convergence»

На рисунке 3 показан пример состояния популяции «наметилась сходимость». В соответствии с представленным рисунком видно, что в настоящее время в популяции нет особей со значением целевой функции равно 0, но существуют особи, которые приблизились к данному значению. В этом случае ИНС не должна предпринимать попыток изменения параметров работы ГА.




Рис.3. Пример состояния популяции «наметилась сходимость»  
Fig.3. An example of a population state “convergence is emerging”

Пример затухания ГА. На рисунке 4 показано данное состояние.




Рис.4. Пример состояния популяции «затухание»  
Fig.4. Example of a population state «decay»

Из данного рисунка видно, что особи группируются далеко от искомого решения, при этом не существует достаточного разброса, который позволит популяции выйти из данного локального экстремума. При этом требуется увеличить разрушающую способность для выхода популяции из локального экстремума.

На рисунке 5 показан пример «наметилось затухание».




Рис. 5. Пример состояния «наметилось затухание»  
Fig.5. An example of the “attenuation has begun” state

Как видно из рисунка, количество особи популяции начинают группироваться возле локального экстремума. В этом случае ИНС также должна предпринять попытку рассеивания популяции по пространству решений, увеличивая разрушающую способность операторов ГА.

Рассмотрим пример такого состояния популяции как «невмешательство». Данный пример показан на рисунке 6.

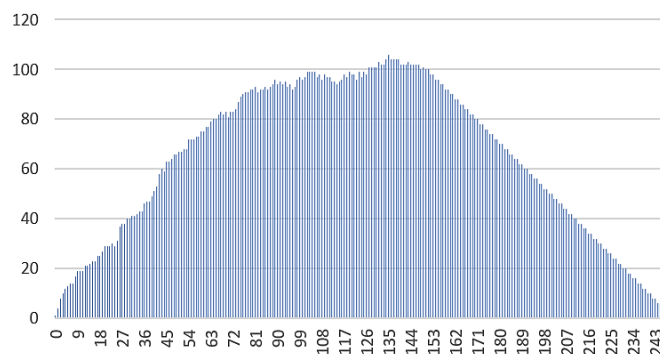


Рис.6. Пример состояния «невмешательство»  
Fig.6. An example of a non-intervention state

Как видно из представленного рисунка, разброс значений целевой функции достаточно большой и при этом наметилась сходимость, то есть особи, приближающиеся к значению целевой функции равному 0.

Такого рода данные вычислительных экспериментов, в количестве более 750 по каждому классу состояний ГА, были использованы для обучения пяти классов ИНС. При обучении выборка была разделена в следующей пропорции: 80% – обучающая и 20% – тестовая. Можно высказать предположение, что модели ИНС с долгосрочной памятью должны показать высокий результат при решении данного класса задач [Андриянов, 2014; Васильев, 2014; Andriyanov, Sluzhivyi, 2019; Kalays T.A., Asan, U. 2022; Zhang, Zhu, Chen, 2023; Zhang X., et al., 2023].

В таблице 1 показаны сравнения моделей на выборке.

Таблица 1  
Table 1

Сравнение моделей на выборке  
Comparison of models on sample

Модель	Accuracy	F1-score	AvgPrecision	AvgRecall
Машина опорных векторов	0.1	0.12	0.22	0.12
Дерево решений	0.77	0.78	0.79	0.82
Случайный лес	1.0	1.0	1.0	1.0
Полносвязная сеть (4 слоя 32-64-128-256)	0.60	0.57	0.59	0.56
LSTM (128+256)	1	1	1	1
RNN (128+256)	0.69	0.67	0.74	0.75
GRU (128+256)	0.94	0.95	0.95	0.95
BiLSTM (128+256+DO)	1.0	1.0	1.0	1.0

На рисунке 7 показан результат обучения модели полносвязанной ИНС.




Рис.7. Результаты обучения полносвязанной ИНС  
Fig.7. Results of training a fully connected ANN

Как видно на представленном изображении, модель является переобученной, так как существует большой разрыв между валидацией и тестом. Это связано с большим количеством параметров и сложностью модели по сравнению с данными

На рисунке 8 показаны результаты обучения LSTM модели ИНС.




Рис. 8. Результат обучения LSTM модели ИНС  
Fig.8. Result of training LSTM ANN model

Как видно из рисунка, модель быстро обучилась, хорошо подходит для данных, развивающихся во времени, которыми можно аппроксимировать развитие функции среди особей.

На рисунке 9 показан результат обучения RNN модели ИНС.




Рис.9. Результат обучения RNN модели ИНС  
Fig. 9. Result of training RNN ANN model

RNN модель показала эффект переобучения и оказалась неспособна уловить общие зависимости в данных, в отличие от LSTM.

На рисунке 10 показан результат обучения GRU модели ИНС.






Рис.10. Результат обучения GRU модели ИНС  
Fig.10. Result of training GRU ANN model

Данная модель показала приемлемые результаты, в них отсутствуют признаки переобучения, что дает возможность высказать предположение, что для решения задачи определения состояния популяции на основе предложенной структуры данных требуется модель с более сложной памятью, чем предоставляет RNN.

На рисунке 11 показан результат обучения BiLSTM+dropout модели ИНС.




Рис.11. Результат обучения BiLSTM+dropout модели ИНС  
Fig.11. Result of training BiLSTM+dropout ANN model

На основе проведенных вычислительных экспериментов можно сказать, что BiLSTM слои наилучшие, а процедура dropout несколько замедлила обучение, что может быть полезно при более сложных наборах данных.

### Заклучение

Предложенная в статье структура данных показала свою состоятельность при обучении ИНС распознавать состояние популяции в ГА в процессе поиска решений. Наилучшие результаты на данной структуре данных показали модели: GRU, LSTM и BiLSTM+dropout на основе метода обучения случайный лес, что говорит о состоятельности предположения об

использовании ИНС с памятью для решения этого класса задач. В развитии данного подхода управления ГА в процессе поиска решений целесообразно рассмотреть вариант применения двух контейнеров ИНС: первый контейнер распознает состояние популяции, второй контейнер принимает решение об изменении разрушающей способности операторов генетического алгоритма. В работе [Petrosov, Lomazov, Petrosova, 2021] было предложено использование вложенных сетей Петри для описания работ ГА в задачах структурно-параметрического синтеза моделей больших дискретных систем с заданным поведением, поэтому в развитии предложенного подхода описание модели ИНС также целесообразно дополнить с применением данного математического аппарата. Использование сетей Петри позволяет применить вычисления на основе GPGPU совместно с CPU, что позволит повысить быстродействие специализированных программных средств за счет матричного представления данных, использующих предложенный подход. Также следует отметить, что управление процессом поиска решений с использованием ИНС в качестве управляющей надстройки, позволит использовать ГА при работе с большими данными, что ранее было усложнено частыми затуханиями.

### Благодарности

*Авторы выражают благодарность Российскому Научному Фонду за финансовую поддержку исследований (проект №23-31-00127).*

### Список литературы

- Андриянов Н.А. 2014. Дискретные дважды стохастические авторегрессионные модели случайных полей. Современные проблемы проектирования, производства и эксплуатации радиотехнических систем, 1(9): 69-71.
- Васильев К.К. 2014. Авторегрессии с кратными корнями характеристических уравнений. Радиотехника, 11: 74–78.
- Гольшин А.Е. 2018. Настройка параметров нечеткого контроллера с помощью генетического алгоритма при управлении динамическим объектом. Актуальные проблемы авиации и космонавтики, 4(14): 21-23.
- Давронов, Ш. Р. 2023. Обзор современных генетических алгоритмов и их применение на практике. Молодой ученый, 36 (483):15-18.
- Денисов М.А., Сопов Е.А. 2021. Генетический алгоритм условной оптимизации для проектирования информативных признаков в задачах классификации. Сибирский аэрокосмический журнал, 1: 18-31.
- Дрозин А.Ю. 2023. Генетический алгоритм построения маршрутов выполнения этапов работ в конвейерной системе. Системный администратор, 5 (246): 94-95
- Петросов Д.А., Зеленина А.Н. 2020. Модель искусственной нейронной сети для решения задачи управления генетическим алгоритмом с применением математического аппарата теории сетей Петри. Моделирование, оптимизация и информационные технологии, 4(31).
- Сапрыкина А.О. 2022а. Настройка параметров эволюционных операторов генетического алгоритма для повышения эффективности поиска решения задачи. Современные научные исследования и инновации, 12 (141): 12-19.
- Сапрыкина А.О. 2022б. Эволюционные операторы и принцип работы генетического алгоритма. Современные научные исследования и инновации, 11 (139):34-41.
- Софронова Е.А. 2023. Вариационный генетический алгоритм и его применение к управлению транспортными потоками в городской среде. International Journal of Open Information Technologies, 4:3-13.
- Чеканин В.А., Куликова М.Ю. 2017. Адаптивная настройка параметров генетического алгоритма. Вестник МГТУ «Станкин», 3(42): 85-89.
- Шагай М.В., Попова Н.Н. 2023. Генетический алгоритм оптимизации путеводных деревьев. Вестник Московского университета. Серия 15: Вычислительная математика и кибернетика, 1:54-61.
- Шишкова Н.А. 2017. Генетический алгоритм как метод оптимизации. Проблемы науки, 5(18): 28-30.

- Andriyanov N.A., Sluzhivyi M.N. 2019. Solution for the problem of the parameters identification for autoregressions with multiple roots of characteristic equations. CEUR Workshop Proceedings, 2391:1-7.
- Hahn Y., Langer T., Meyes R., Meisen T. 2023. Time Series Dataset Survey for Forecasting with Deep Learning. Forecasting, 5: 315-335. <https://doi.org/10.3390/forecast5010017>
- Kalayc T.A., Asan U. 2022. Improving Classification Performance of Fully Connected Layers by Fuzzy Clustering in Transformed Feature Space. Symmetry, 14: 658. <https://doi.org/10.3390/sym14040658>
- Petrosov D.A., Lomazov V.A., Petrosova N.V. 2021. Model of an Artificial Neural Network for Solving the Problem of Controlling a Genetic Algorithm Using the Mathematical Apparatus of the Theory of Petri Nets. Applied Sciences, 11: 3899.
- Valerian G., Sutrisno T., Herwindiati D.E. 2020. Image clustering using genetic algorithm with tournament selection and uniform crossover. IOP Conf. Series: Materials Science and Engineering. doi:10.1088/1757-899X/852/1/012043.
- Zhang J., Zhu F., Chen H. 2023. Two-Threshold-Variable Integer-Valued Autoregressive Model. Mathematics, 11: 3586. <https://doi.org/10.3390/math11163586>
- Zhang X., Zhong Z., Jianjun Z., Ting W., Wing W.Y. 2023. Robust recurrent neural networks for time series forecasting. Neurocomputing, 526: 143-157.

### References

- Andriyanov N.A. 2014. Diskretnye dvazhdy stohasticheskie avtoregressionnye modeli sluchajnyh polej. [Discrete doubly stochastic autoregressive random field models] Sovremennye problemy proektirovaniya, proizvodstva i ekspluatatsii radio-tekhnicheskikh sistem, 1(9): 69-71. (in Russian)
- Vasil'ev K.K. 2014. Avtoregressii s kratnymi kornyami harakteristicheskikh uravne-nij. [Autoregressions with multiple roots of characteristic equations] Radiotekhnika, 11: 74–78. (in Russian)
- Golyshin A.E. 2018. Nastrojka parametrov nechetkogo kontrollera s pomoshch'yu geneti-cheskogo algoritma pri upravlenii dinamicheskim ob»ektom. [Setting the parameters of a fuzzy controller using a genetic algorithm when controlling a dynamic object] Aktual'nye problemy aviatsii i kosmonavtiki, 4(14): 21-23. (in Russian)
- Davronov SH. R. 2023. Obzor sovremennyh geneticheskikh algoritmov i ih primenenie na praktike. [Review of modern genetic algorithms and their application in practice] Molodoj uchenyj, 36 (483):15-18. (in Russian)
- Denisov M.A., Sopov E.A. 2021. Geneticheskij algoritm uslovnoj optimizatsii dlya proektirovaniya informativnyh priznakov v zadachah klassifikatsii. [Genetic algorithm of conditional optimization for designing informative features in classification problems] Sibirskij aerokosmiche-skij zhurnal, 1: 18-31. (in Russian)
- Drozin A.YU. 2023. Geneticheskij algoritm postroeniya marshrutov vypolneniya etapov rabot v konvejernoj sisteme.[ Genetic algorithm for constructing routes for performing work stages in a conveyor system] Sistemnyj administrator, 5 (246): 94-95 (in Russian)
- Petrosov D.A., Zelenina A.N. 2020. Model' iskusstvennoj nejronnoj seti dlya resheniya zadachi upravleniya geneticheskim algoritmom s primeneniem matematicheskogo apparata teorii se-tej Petri.[ Model of an artificial neural network for solving the problem of controlling a genetic algorithm using the mathematical apparatus of Petri net theory] Modelirovanie, optimizatsiya i informacionnye tekhnologii, 4(31) (in Russian)
- Saprykina A.O. 2022a. Nastrojka parametrov evolyucionnyh operatorov geneticheskogo algoritma dlya povysheniya effektivnosti poiska resheniya zadachi.[ Setting the parameters of evolutionary operators of a genetic algorithm to increase the efficiency of finding a solution to a problem] Sovremennye nauchnye issledo-vaniya i innovatsii, 12 (141): 12-19. (in Russian)
- Saprykina A.O. 2022b. Evolyucionnye operatory i princip raboty geneticheskogo algoritma. [Evolutionary operators and the principle of operation of the genetic algorithm] Sovremennye nauchnye issledovaniya i innovatsii, 11 (139):34-41. (in Russian)
- Sofronova E.A. 2023. Variacionnyj geneticheskij algoritm i ego primenenie k upravleniyu transportnymi potokami v gorodskoj srede.[ Variational genetic algorithm and its application to traffic management in an urban environment] International Journal of Open Information Technologies, 4:3-13. (in Russian)
- CHekanin V.A., Kulikova M.YU. 2017. Adaptivnaya nastrojka parametrov geneticheskogo algoritma. [Adaptive tuning of genetic algorithm parameters.] Vestnik MGTU «Stankin», 3(42): 85-89. (in Russian)

- SHegaj M.V., Popova N.N. 2023. Geneticheskij algoritm optimizacii putevodnyh derev'ev. [Genetic algorithm for optimizing guiding trees] Vestnik Moskovskogo universiteta. Seriya 15: Vychislitel'naya matematika i kibernetika, 1:54-61. (in Russian)
- SHishkova N.A. 2017. Geneticheskij algoritm kak metod optimizacii. [Genetic algorithm as an optimization method] Problemy nauki, 5 (18): 28-30. (in Russian)
- Andriyanov N.A., Sluzhivyi M.N. 2019. Solution for the problem of the parameters identification for autoregressions with multiple roots of characteristic equations. CEUR Workshop Proceedings, 2391:1-7.
- Hahn Y., Langer T., Meyes R., Meisen T. 2023. Time Series Dataset Survey for Forecasting with Deep Learning. Forecasting, 5: 315-335. <https://doi.org/10.3390/forecast5010017>
- Kalayc T.A., Asan U. 2022. Improving Classification Performance of Fully Connected Layers by Fuzzy Clustering in Transformed Feature Space. Symmetry, 14: 658. <https://doi.org/10.3390/sym14040658>
- Petrosov D.A., Lomazov V.A., Petrosova N.V. 2021. Model of an Artificial Neural Network for Solving the Problem of Controlling a Genetic Algorithm Using the Mathematical Apparatus of the Theory of Petri Nets. Applied Sciences, 11: 3899.
- Valerian G., Sutrisno T., Herwindiati D.E. 2020. Image clustering using genetic algorithm with tournament selection and uniform crossover. IOP Conf. Series: Materials Science and Engineering. doi:10.1088/1757-899X/852/1/012043.
- Zhang J., Zhu F., Chen H. 2023. Two-Threshold-Variable Integer-Valued Autoregressive Model. Mathematics, 11: 3586. <https://doi.org/10.3390/math11163586>
- Zhang X., Zhong Z., Jianjun Z., Ting W., Wing W.Y. 2023. Robust recurrent neural networks for time series forecasting. Neurocomputing, 526: 143-157.

**Конфликт интересов:** о потенциальном конфликте интересов не сообщалось.

**Conflict of interest:** no potential conflict of interest related to this article was reported.

Поступила в редакцию 14.11.2023

Received November 14, 2023

Поступила после рецензирования 02.12.2023

Revised December 02, 2023

Принята к публикации 04.12.2023

Accepted December 04, 2023

## ИНФОРМАЦИЯ ОБ АВТОРАХ

## INFORMATION ABOUT THE AUTHORS

**Петросов Давид Арегович**, кандидат технических наук, доцент, доцент департамента анализа данных и машинного обучения, Финансовый университет при Правительстве РФ, г. Москва, Россия

**David A. Petrosov**, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Data Analysis and Machine Learning, Financial University under the Government of the Russian Federation, Moscow, Russia

**Андрьянов Никита Андреевич**, кандидат технических наук, доцент департамента анализа данных и машинного обучения, Финансовый университет при Правительстве РФ, г. Москва, Россия

**Nikita A. Andriyanov**, Candidate of Technical Sciences, Associate Professor of the Department of Data Analysis and Machine Learning, Financial University under the Government of the Russian Federation, Moscow, Russia

**Алюнов Александр Николаевич**, кандидат технических наук, доцент, доцент департамента анализа данных и машинного обучения, Финансовый университет при Правительстве РФ, г. Москва, Россия

**Alexander N. Alyunov**, Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Data Analysis and Machine Learning, Financial University under the Government of the Russian Federation, Moscow, Russia

**Нежданов Евгений Валерьевич**, заместитель директора Центра компетенций «Цифровая экономика», Финансовый университет при Правительстве РФ, г. Москва, Россия

**Evgeniy V. Nezhdanov**, Deputy Director of the Digital Economy Competence Center, Financial University under the Government of the Russian Federation, Moscow, Russia