

УДК 004.032.26

DOI: [10.26102/2310-6018/2024.45.2.020](https://doi.org/10.26102/2310-6018/2024.45.2.020)

## Интеллектуализация процессов принятия решений в системах управления рисками на базе нейронных сетей семейства ART

С.С. Антипов, В.Л. Бурковский, И.В. Поцбнева

*Воронежский государственный технический университет, Воронеж,  
Российская Федерация*

**Резюме.** В статье рассматривается проблематика применения нейронных сетей семейства ART для оптимизации процесса принятия решений в системах управления рисками. Преимущества такого подхода, такие как способность быстро реагировать на новую информацию и гибкость в обучении, сопоставляются с недостатками, включающими сложности настройки параметров и интерпретации результатов. В следующей части статьи будут изучены различные способы обучения ART-сетей, включая методы без учителя (unsupervised learning) и с учителем (supervised learning), а также ключевые моменты настройки параметров сети. Поднимаются возможные проблемы, связанные с качеством входных данных и сложностью интерпретации выходных данных. В статье также представлен конкретный пример использования нейронных сетей типа ART в сфере строительства для оценки рисков и принятия обоснованных решений. В заключении статьи делается акцент на перспективах использования нейронных сетей семейства ART для кластер-анализа рисков, выявления связанных факторов и группировки их для более эффективного управления. Обсуждаются возможности дальнейшего развития методов принятия решений в управлении рисками с применением нейронных сетей типа ART и их потенциал для обеспечения более точных и прогностических практик.

**Ключевые слова:** нейронные сети типа ART, риски, процессы принятия решений, мониторинг данных, обучение нейронной сети.

**Для цитирования:** Антипов С.С., Бурковский В.Л., Поцбнева И.В. Интеллектуализация процессов принятия решений в системах управления рисками на базе нейронных сетей семейства ART. *Моделирование, оптимизация и информационные технологии.* 2024;12(2). URL: <https://moitvvt.ru/ru/journal/pdf?id=1604> DOI: 10.26102/2310-6018/2024.45.2.020

## Intelligentization of decision-making processes in risk management systems based on neural networks of the art family

S.S. Antipov, V.L. Burkovsky, I.V. Potsebneva

*Voronezh State Technical University, Voronezh, the Russian Federation*

**Abstract.** This article discusses the problems of using neural networks of the ART family to optimize the decision-making process in risk management systems. The advantages of this approach, such as the ability to quickly respond to new information and flexibility in learning, are weighed against disadvantages, including the difficulty of adjusting parameters and interpreting results. The next part of the article will explore various ways to train ART networks, including unsupervised learning and supervised learning methods, as well as key points for configuring network parameters. Possible problems related to the quality of input data and the difficulty of interpreting output data are raised. The article also presents a concrete example of the use of ART-type neural networks in the construction industry to assess risks and make informed decisions. In conclusion, the article focuses on the prospects for using neural networks of the ART family for cluster analysis of risks, identifying related factors and

grouping them for more effective management. The possibilities for further development of decision-making methods in risk management using neural networks such as ART and their potential to provide more accurate and predictive practices are discussed.

**Keywords:** ART-type neural networks, risks, decision-making processes, monitoring data, neural network training.

**For citation:** Antipov S.S., Burkovsky V.L., Potsebneva I.V. Intellectualization of decision-making processes in risk management systems based on neural networks of the ART family. *Modeling, Optimization and Information Technology*. 2024;12(2). URL: <https://moitvvt.ru/ru/journal/pdf?id=1604> DOI: 10.26102/2310-6018/2024.45.2.020 (In Russ.).

## Введение

Традиционные методы анализа рисков в различных объектных областях могут быть недостаточными для обработки больших объемов данных и быстро меняющихся условий. Для успешного функционирования компании и минимизации потенциальных убытков требуется разработка и применение эффективных инструментов управления рисками.

В этом контексте использование искусственного интеллекта и, в частности, нейронных сетей типа ARTMAP (Adaptive Resonance Theory Maps), может стать эффективным инструментом для интеллектуализации процессов принятия решений в системах управления рисками [1].

Одним из основных преимуществ нейронных сетей ART является их способность к адаптации и обучению на основе поступающих данных. Это позволяет им динамически анализировать информацию, выявлять изменения в рисках и оперативно реагировать на них. Кроме того, нейронные сети ART обладают уникальной способностью к разрешению конфликтующей информации и способны строить устойчивые модели даже в условиях высокой неопределенности [2]. Это особенно важно в условиях быстро меняющейся среды, когда каждая минута может иметь решающее значение.

Для интеллектуализации процессов принятия решений в системах управления рисками на базе нейронных сетей семейства ART необходимо провести следующие этапы:

1. Сбор и структурирование данных. Важным шагом является сбор и структурирование данных о рисках, их характеристиках и взаимосвязях. Эти данные будут использоваться для обучения нейронных сетей и создания моделей управления рисками.

2. Обучение нейронных сетей. На этом этапе проводится обучение нейронных сетей на основе собранных данных. С помощью специальных алгоритмов нейронные сети семейства ART могут выявлять закономерности, прогнозировать риски и предлагать оптимальные решения [3].

3. Разработка моделей управления рисками. На основе данных, полученных в процессе обучения нейронных сетей, разрабатываются модели управления рисками. Эти модели могут быть интегрированы в систему управления компанией и использоваться для принятия оперативных решений.

## Материалы и методы

Риск, как концепция из области математики, всегда ассоциируется с вероятностным исходом, который может быть благоприятным или неблагоприятным. В данном случае можно говорить как о риске убытков, так и о возможности получения сверхприбыли. Это связано с тем, что при принятии решений в условиях неопределенности всегда существует вероятность неудачи, но также есть шанс достичь

большого успеха, чем было запланировано. Поэтому, необходимо оценивать риски и принимать решения на основе анализа всех возможных последствий.

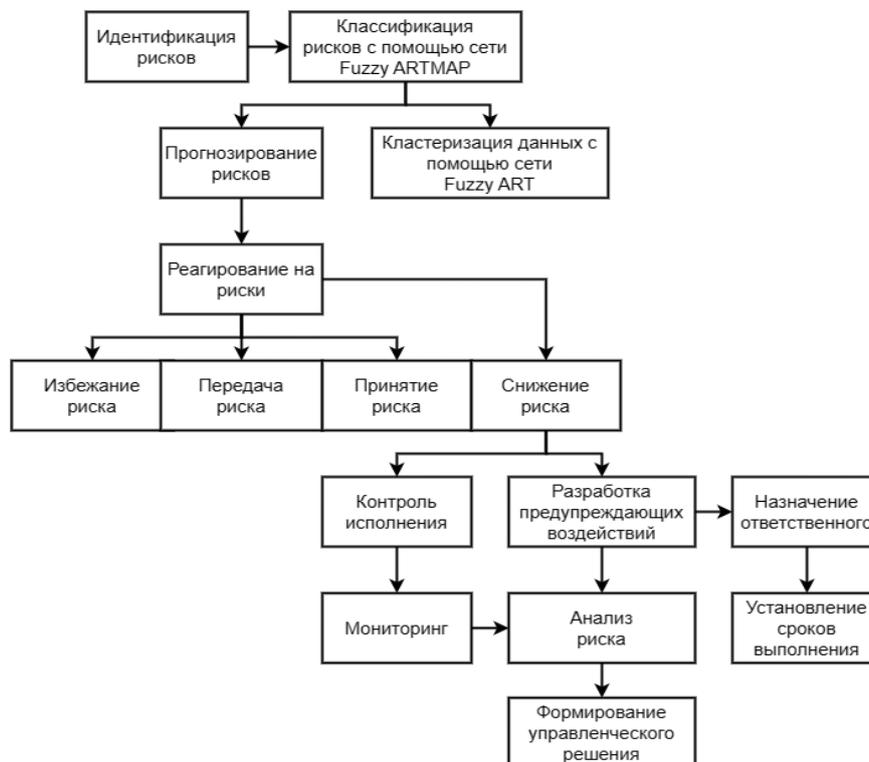


Рисунок 1 – Обобщенная структура процесса управления рисками  
Figure 1 – Generalized structure of the risk management process

Эффективное управление рисками играет ключевую роль в успехе любого бизнеса или организации [4]. Это комплекс процедур и методов, направленных на выявление, оценку и управление потенциальными угрозами, способными негативно повлиять на деятельность предприятий. Структура управления рисками (RMF) представляет собой ключевой инструмент для компаний, который позволяет активно управлять рисками и принимать все необходимые меры для сокращения потенциальных убытков. Обобщенная структура процесса управления рисками представлена на Рисунке 1. Данная система является универсальной для любой области реализации.

В предложенной структуре центральное значение имеют модули: идентификации рисков, прогнозирования и кластеризации рисков. При выборе решающих правил наиболее целесообразным является использование аппарата нечеткой логики на базе алгоритма Мамдани. Для расчета риска представлена формула (1):

$$R = I \cdot P, \quad (1)$$

где  $R$  представляет собой риск;  $P$  является вероятностью того, что данный риск реализуется;  $I$  обозначает тяжесть последствий.

В рамках использования метода Мамдани каждой переменной, которая может повлиять на результат, нужно присвоить степень важности и числовое значение от 1 до 3, где 3 будет означать наибольшую степень риска или влияния на конечный результат.

1.  $R$  – {значительный, приемлемый, незначительный}.
2.  $P$  – {наибольшая, средняя, наименьшая}.
3.  $I$  – {негативные, умеренные, минимальные}.

Такой подход позволяет более точно оценить возможные риски и принять меры для их минимизации (Таблицы 1–3).

Таблица 1 – Обозначения риска и оценки риска  
Table 1 – Risk symbols and risk assessments

Обозначение риска	Обозначение оценки риска
значительный	3
приемлемый	2
незначительный	1

Таблица 2 – Обозначения вероятности реализации и оценки вероятности  
Table 2 – Designations of the Probability of implementation and probability estimates

Обозначение вероятности реализации	Обозначение оценки вероятности
наибольшая	3
средняя	2
наименьшая	1

Таблица 3 – Обозначение последствий риска и оценки последствий  
Table 3 – Designation of risk consequences and assessment of consequences

Обозначение последствий риска	Обозначение оценки последствий
негативные	3
умеренные	2
минимальные	1

Создание базы знаний при таком подходе включает в себя набор правил *Если «...» и «...», то «...»*:

- если Р = «наибольшая» и R = «значительная», то I = «негативные»;
- если Р = «наибольшая» и R = «приемлемый», то I = «умеренные»;
- если Р = «наибольшая» и R = «незначительный», то I = «минимальные»;
- если Р = «средняя» и R = «значительная», то I = «негативные»;
- если Р = «средняя» и R = «приемлемый», то I = «умеренные»;
- если Р = «средняя» и R = «незначительный», то I = «не важный»;
- если Р = «наименьшая» и R = «значительная», то I = «негативные»;
- если Р = «наименьшая» и R = «приемлемый», то I = «умеренные»;
- если Р = «наименьшая» и R = «незначительный», то I = «минимальные».

Идентификация рисков осуществляется через структуризацию, включающую в себя классификацию или кластеризацию. В этом случае информация распределяется по заранее определенным классам или объединяется в кластеры, что упрощает обнаружение возможных отклонений и понимание особенностей входящих данных. Следующим этапом происходит реагирование на риски, где на основе мониторинговых показателей определяются предупреждающие воздействия с последующим формированием управленческих решений. Обобщенная схема процесса поддержки принятия управленческих решений изображена на Рисунке 2.

Данная модель может быть представлена следующим образом:

$$\langle S_t, D_t, F_t, M_t, G_t \rangle,$$

где  $S_t$  обозначает входные данные в определенное время  $t$ ;  $D_t$  является набором кластеров с учетом данных мониторинга;  $F_t$  отображает систему классификации состояний;  $M_t$

представляет собой комплекс управляющих воздействий;  $G_t$  описывает комплекс нейро-нечетких моделей:

- $S_t \rightarrow D_t$  (модель кластеризации);
- $D_t \rightarrow F_t$  (модель классификации);
- $F_t \rightarrow M_t$  (модель построения управленческих решений).



Рисунок 2 – Обобщенная модель процесса принятия управленческих решений  
Figure 2 – Generalized model of the management decision-making process

Для реализации функций классификации и прогнозирования рисков в работе предлагается использовать нейросетевые алгоритмы семейства ART. Описание функционала сети можно представить с помощью общей модели, представленной на Рисунке 3 [5].



Рисунок 3 – Модель функционала сети семейства ART  
Figure 3 – Model of the functionality of the ART family network

В данной статье исследуются нейронные сети Fuzzy ART и Fuzzy ARTMAP. Основная идея заключается в обработке непрерывных входных данных [6]. Для создания кластеров данных используется сеть Fuzzy ART, которая работает на базе нечеткой логики. Fuzzy ARTMAP обучается с учителем и используется именно для решения задач классификации.

Рассмотрим подробнее сеть Fuzzy ART. Все компоненты входных и выходных векторов проходят масштабирование в диапазоне от 0 до 1 для корректной обработки данных мониторинга.

$$y_{ij}^{\text{нов}} = \frac{y_{ij}^{\text{ст}} - y_i^{\text{min}}}{y_i^{\text{max}} - y_i^{\text{min}}}, \quad (2)$$

где  $y_i^{\text{min}}$  – минимальное значение входного вектора  $Y^i$ , а  $y_i^{\text{max}}$  – максимальное значение. Нейросетевая модель Fuzzy ART состоит из слоев, таких как F0, F1 и F2. В свою очередь:

- 1) F0 – отображение текущего вектора входа;
- 2) F1 – обработка данных от F0 с обратной связью от F2;
- 3) F2 – отображение кластера.

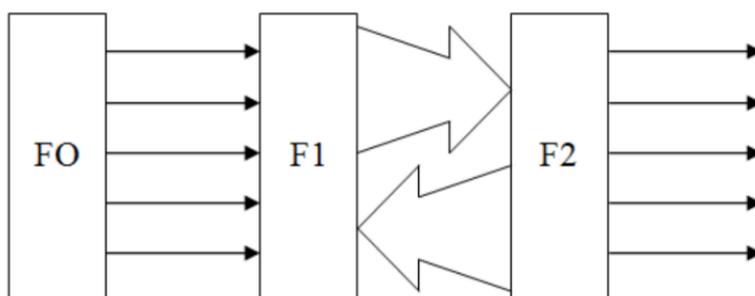


Рисунок 4 – Архитектура сети Fuzzy ART  
Figure 4 – Fuzzy ART network architecture

Изображенная на Рисунке 4 структура сети, где выходным сигналом F0 является вектор  $A = (a_1, \dots, a_M)$ , выходом слоя F1 – вектор  $B = (b_1, \dots, b_M)$ , а F2 – вектор  $C = (c_1, \dots, c_N)$ , позволяет решать задачи кластеризации и регрессии. Каждый элемент вектора C представляет собой взвешенную сумму элементов векторов A и B, умноженных на соответствующие весовые коэффициенты [7].

Стоит отметить ключевые аспекты процесса кластеризации Fuzzy ART:

1. На каждом этапе алгоритм выбирает кластер, который имеет максимальную функцию принадлежности к активным кластерам, т. е.  $r = \text{argmax } P_l, l \in S$ , где S – множество активных кластеров. Это значит, что каждый новый объект будет сравниваться со всеми существующими кластерами и будет отнесен к тому, который наиболее соответствует ему.

2. Функция соответствия используется для проверки сходства между входным вектором  $Y$  и прототипом кластера  $r$ , т. е.  $Y \in r$ , если  $K_r \geq j$ , где  $j$  – критерий сходства. Если сходство достаточно велико (т. е. превышает определенный порог), то объект считается принадлежащим этому кластеру.

$$K_r = \frac{|Y^i \wedge v^r|}{|Y^i|}. \quad (3)$$

3. В случае, когда из существующих кластеров не подходит ни один, система начинает поиск другого подходящего кластера. Если же все кластеры оказываются неактивными, создается новый кластер с весом  $v = Y^i$ .

4. После создания нового кластера происходит процесс обучения, в ходе которого обновляются веса кластеров по формуле (4). Это необходимо для того, чтобы улучшить качество классификации и уменьшить количество ошибок.

$$v^{t+1} = (1 - \beta)v^t + \beta(Y^i \wedge v^t) \quad (4)$$

Для систематизации информации, собранной путем мониторинга, применяется нейронная сеть Fuzzy ARTMAP. Эта сеть способна классифицировать входные данные, за что отвечает блок ARTa в начале процесса функционирования. Блок ARTb, в свою очередь, формирует структуру выходных данных, полученных от ARTa. Эти блоки объединены модулем памяти (STM). В каждом блоке находится два слоя нейронов, которые применяют в своих расчетах методы нечеткой логики.

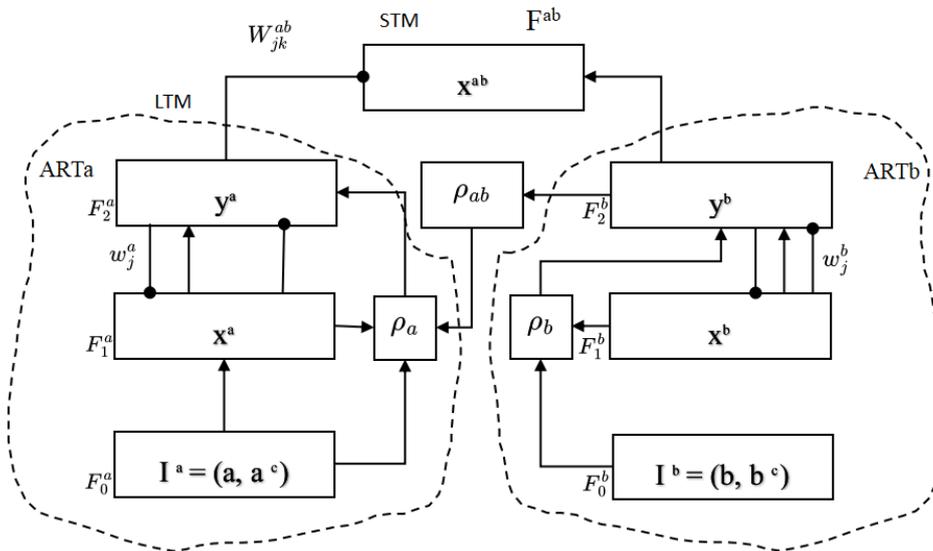


Рисунок 5 – Архитектура сети Fuzzy ARTMAP  
Figure 5 – Fuzzy ARTMAP network architecture

На Рисунке 5 изображена архитектура сети Fuzzy ARTMAP. Как отмечает в своей работе Федутин К. А., «одной из особенностей Fuzzy ARTMAP является наличие дополнительного модуля  $F_{ab}$ , который позволяет сети функционировать автономно в реальном времени. Модуль  $F_{ab}$  в Fuzzy ARTMAP реализует встроенный механизм самоорганизации, ... . Размер слоя  $F_1^a$  соответствует числу выходов сети, в то время как количество нейронов в слое  $F_2^a$  соответствует сформированным к данному моменту кластерам, число которых растет в процессе инкрементного обучения. То есть сеть Fuzzy ARTMAP также, как и Fuzzy ART, относится к классу растущих сетей. Слои нейронов  $F_1^a$  и  $F_2^a$  соединены между собой весовой матрицей  $W^a = (w_{ij}^a)$ , при этом каждый весовой вектор  $w_j^a, j = 1..l$ , представляет собой прототип соответствующего кластера с номером  $j$ » [8].

Для обучения сети Fuzzy ARTMAP необходимо задать параметры входных и выходных векторов, а также критерий останова, который определит, когда обучение завершено. Также важно провести предварительную обработку данных и масштабирование компонентов векторов для достижения оптимальных результатов и улучшения процесса распознавания категорий (Рисунок 6).

Предварительная обработка данных включает в себя очистку данных от шума и выбросов, нормализацию данных и преобразование категориальных переменных в числовые.

Критерии останова определяют условия, при которых обучение считается завершенным. Это может быть достигнуто через определенные пороговые значения точности классификации, минимальное количество ошибок или максимальное количество итераций.

Важно отметить, что выбор параметров входных и выходных данных векторов зависит от конкретной задачи и характеристик данных. Правильный подбор этих параметров может значительно повысить эффективность работы сети Fuzzy ARTMAP.

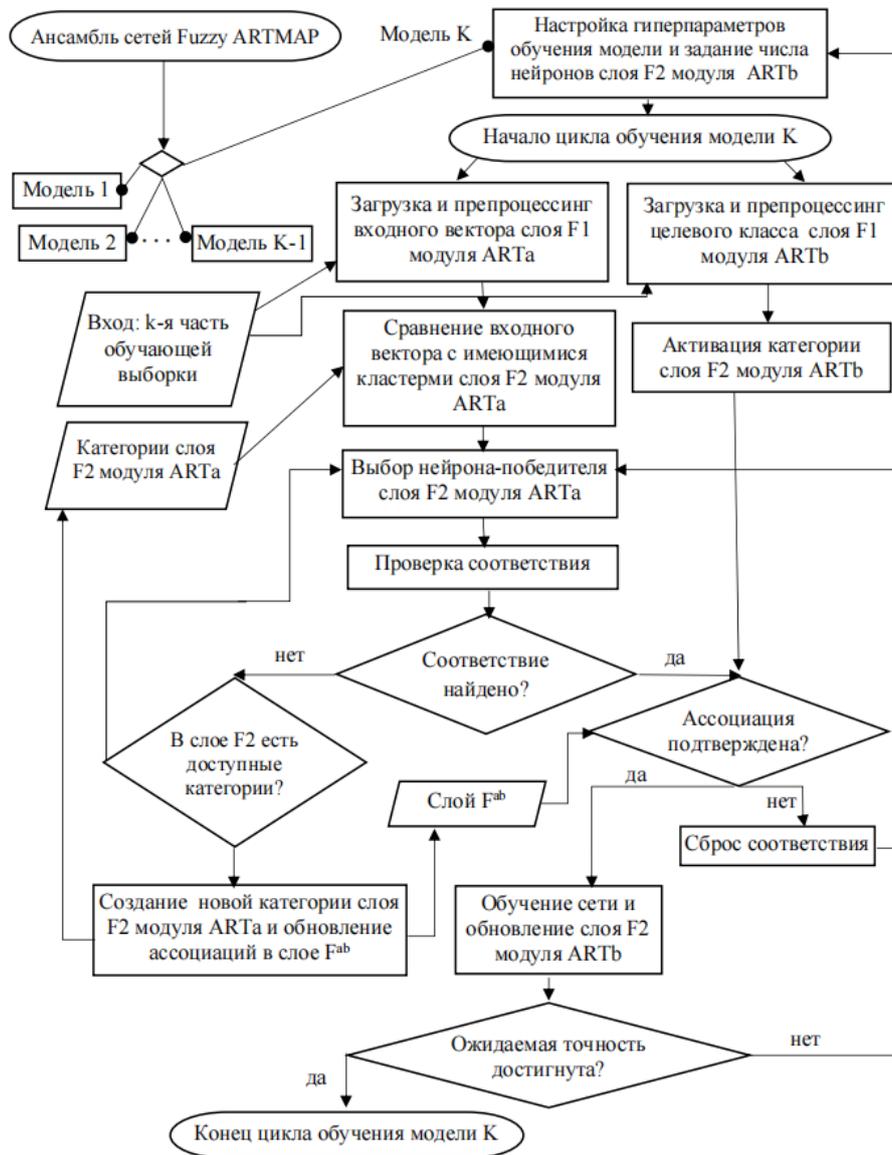


Рисунок 6 – Обучение ансамбля сетей Fuzzy ARTMAP  
Figure 6 – Training of an ensemble of Fuzzy ARTMAP networks

Предложенный алгоритм направлен на улучшение точности классификации путем комбинирования результатов нескольких индивидуальных сетей [9]. Каждая

отдельная сеть обучается на различных подмножествах данных, что позволяет учесть разнообразие входных данных и повысить обобщающую способность модели [10].

Для нивелирования недостатков, таких как сложность настройки параметров, высокие вычислительные затраты сетей семейства ART и так далее, могут быть применены следующие подходы:

1. Использование параллельных вычислений. Высокие вычислительные затраты могут быть снижены путем использования параллельных вычислений. Современные процессоры и графические процессоры (GPU) поддерживают параллельные вычисления, что позволяет ускорить обработку данных.

2. Упрощение архитектуры сети. В некоторых случаях можно упростить архитектуру сети ARTMAP, чтобы уменьшить сложность настройки параметров и вычислительные затраты. Однако это может привести к ухудшению качества работы сети.

3. Использование предварительно обученных моделей. Вместо того чтобы обучать сеть ARTMAP с нуля, можно использовать предварительно обученные модели, которые уже показали хорошие результаты на аналогичных задачах. Это может сократить время и ресурсы, необходимые для настройки параметров.

### Результаты

Рассмотренные в данной статье модели были проверены на практике в составе модулей системы управления рисками в рамках решения проблемы управления строительными предприятиями региона. Разработанная система управления рисками была применена в строительной компании по возведению панельного домостроения. Структура системы представлена следующим образом:

$$\langle S_t, D_t, F_t, T_t, M_t, G_t \rangle,$$

где  $S_t$  обозначает входные данные в определенное время  $t$ ;  $D_t$  является набором кластеров с учетом данных мониторинга;  $F_t$  отображает систему классификации состояний;  $T_t$  является графическим представлением моделей классов или кластеров на карте рисков;  $M_t$  представляет собой комплекс управляющих воздействий;  $G_t$  описывает комплекс нейро-нечетких моделей:

- $S_t \rightarrow D_t$  (модель Fuzzy ART для кластеризации рисков);
- $S_t \rightarrow F_t$  (модель Fuzzy ARTMAP для классификации рисков);
- $S_t \rightarrow M_t$  (модель построения управленческих решений).

### Обсуждение

Благодаря использованию данной системы удалось значительно снизить количество ошибок и проблем при строительстве объектов, а также повысить качество работ. Это достигается за счет комплексного подхода к управлению рисками, который включает в себя анализ потенциальных рисков, разработку мер по их предотвращению или снижению воздействия, а также контроль за выполнением этих мер на всех этапах строительства. Такой подход позволяет заранее предусмотреть возможные проблемы и своевременно принять меры для их устранения, что положительно сказывается на качестве работ и сроках выполнения проектов. Кроме того, использование системы управления рисками позволило оптимизировать процесс принятия решений и ускорить реализацию проектов. Область практического применения в настоящее время уточняется. Приведенный пример связан непосредственно с производственными интересами автора (область оценки рисков в строительстве).

## Заключение

Интеллектуализация процессов принятия решений в системах управления рисками на базе нейронных сетей семейства ART представляет собой перспективное направление развития современных технологий. Этот подход позволяет автоматизировать процесс принятия решений, улучшить качество анализа данных и повысить эффективность работы систем управления рисками. Правильная настройка параметров, оптимальная обработка входных данных и постоянное совершенствование алгоритмов обучения и архитектуры сети позволят использовать сети семейства ART в широком спектре задач обработки и анализа данных, от классификации до прогнозирования и распознавания паттернов.

## СПИСОК ИСТОЧНИКОВ / REFERENCES

1. Carpenter G.A., Grossberg S., Markuzon N., Reynolds J.H., Rosen D.B. Fuzzy ARTMAP: an adaptive resonance architecture for incremental learning of analog maps. In: *Proceedings of 1992 International Joint Conference on Neural Networks (IJCNN '92): Volume 3, 07-11 June 1992, Baltimore, MD, USA*. IEEE; 1992. P. 309–314. <https://doi.org/10.1109/IJCNN.1992.227156>
2. Carpenter G.A., Grossberg S. Adaptive Resonance Theory (ART). In: *The Handbook of Brain Theory and Neural Networks*. Cambridge: MIT Press; 2003. P. 87–90.
3. Versace M., Kozma R.T., Wunsch D.C. Adaptive Resonance Theory Design in Mixed Memristive-Fuzzy Hardware. In: *Advances in Neuromorphic Memristor Science and Applications*. Dordrecht: Springer; 2012. P. 133–153. [https://doi.org/10.1007/978-94-007-4491-2\\_9](https://doi.org/10.1007/978-94-007-4491-2_9)
4. Афонин П.Н. Система управления рисками. Санкт-Петербург: Троицкий мост; 2016. 125 с.  
Afonin P.N. *Sistema upravleniya riskami*. Saint Petersburg: Troitskii most; 2016. 125 p. (In Russ.).
5. Лекун Я. Как учится машина: Революция в области нейронных сетей и глубокого обучения. Москва: Интеллектуальная Литература; 2020. 348 с.  
Lekun Ya. *Kak uchitsya mashina: Revolyutsiya v oblasti neironnykh setei i glubokogo obucheniya*. Moscow: Intellektual'naya Literatura; 2020. 348 p. (In Russ.).
6. Каширина И.Л., Федутинов К.А. Кластеризация непрерывного потока данных на основе обобщенной модели нейронной сети семейства ART. *Системы управления и информационные технологии*. 2018;(1):33–39.  
Kashirina I.L., Fedutinov K.A. Clusterization of continuous data flow based on generalized model of ART neural network. *Sistemy upravleniya i informatsionnye tekhnologii*. 2018;(1):33–39. (In Russ.).
7. Каширина И.Л., Львович Я.Е., Сорокин С.О. Нейросетевое моделирование формирования кластерной структуры на основе сетей ART. *Информационные технологии*. 2017;23(3):228–232.  
Kashirina I.L., Lvovich Ya.E., Sorokin S.O. Neural network modeling of the formation of cluster structures on the basis of the networks ART. *Informatsionnye tekhnologii = Information Technologies*. 2017;23(3):228–232. (In Russ.).
8. Каширина И.Л., Федутинов К.А. Применение сети FUZZY ARTMAP в интеллектуальных системах обнаружения вторжений. *Моделирование, оптимизация и информационные технологии*. 2018;6(3). URL: [https://moit.vvt.ru/wp-content/uploads/2018/07/KashirinaFedutinov\\_3\\_18\\_1.pdf](https://moit.vvt.ru/wp-content/uploads/2018/07/KashirinaFedutinov_3_18_1.pdf)  
Kashirina I.L., Fedutinov K.A. Application of FUZZY ARTMAP network in intelligent systems of invasion detection. *Modelirovanie, optimizatsiya i informatsionnye*

- tekhnologii* = *Modeling, Optimization and Information Technology*. 2018;6(3). (In Russ.). URL: [https://moit.vvt.ru/wp-content/uploads/2018/07/KashirinaFedutinov\\_3\\_18\\_1.pdf](https://moit.vvt.ru/wp-content/uploads/2018/07/KashirinaFedutinov_3_18_1.pdf)
9. Каширина И.Л., Львович Я.Е., Сорокин С.О. Интегральное оценивание эффективности сетевых систем с кластерной структурой. *Экономика и менеджмент систем управления*. 2015;(1-3):330–337.  
Kashirina I.L., Lvovich Ya.E., Sorokin S.O. Integral'noe otsenivanie effektivnosti setevykh sistem s klasternoii strukturoi. *Ekonomika i menedzhment sistem upravleniya*. 2015;(1-3):330–337. (In Russ.).
10. Каширина И.Л., Львович Я.Е., Сорокин С.О. Модели и численные методы оптимизации формирования эффективной сетевой системы с кластерной структурой. *Информационные технологии*. 2015;21(9):657–662.  
Kashirina I.L., Lvovich Ya.E., Sorokin S.O. Models and numerical methods optimization of formation effective network system cluster structure. *Informatsionnye tekhnologii = Information Technologies*. 2015;21(9):657–662. (In Russ.).

### ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Антипов Сергей Сергеевич**, магистрант кафедры систем управления и информационных технологий в строительстве Воронежского государственного технического университета, Воронеж, Российская Федерация.  
*e-mail*: [sergo\\_vzp@mail.ru](mailto:sergo_vzp@mail.ru)

**Sergey S. Antipov**, master's student of the department of Management systems and information technology in construction, Voronezh State Technical University, Voronezh, the Russian Federation.

**Бурковский Виктор Леонидович**, доктор технических наук, профессор, заведующий кафедрой электропривода, автоматизации и управления в технических системах Воронежского государственного технического университета, Воронеж, Российская Федерация.  
*e-mail*: [bvl@vorstu.ru](mailto:bvl@vorstu.ru)

**Viktor L. Burkovsky**, Doctor of Technical Sciences, Professor, Head of the Department of Electric Drive, Automation and Control in Technical Systems, Voronezh State Technical University, Voronezh, the Russian Federation.

**Потсебнева Ирина Валерьевна**, кандидат технических наук, доцент кафедры систем управления и информационных технологий в строительстве, Воронежского государственного технического университета, Воронеж, Российская Федерация.  
*e-mail*: [iposebneva@vgasu.vrn.ru](mailto:iposebneva@vgasu.vrn.ru)

**Irina V. Potsebneva**, Candidate of Technical Sciences, Associate Professor of the department of Management systems and information technology in construction, Voronezh State Technical University, Voronezh, the Russian Federation.

*Статья поступила в редакцию 12.06.2024; одобрена после рецензирования 21.06.2024; принята к публикации 27.06.2024.*

*The article was submitted 12.06.2024; approved after reviewing 21.06.2024; accepted for publication 27.06.2024.*