



## Интервальная ART-нейронная сеть для решения задач кластеризации при анализе образов с интервальными атрибутами

А. Ю. Кучмин<sup>а</sup>, доктор техн. наук, ведущий научный сотрудник, [orcid.org/0000-0003-0699-6112](https://orcid.org/0000-0003-0699-6112), [radiotelescope@yandex.ru](mailto:radiotelescope@yandex.ru)

С. С. Расова<sup>а</sup>, канд. физ.-мат. наук, старший научный сотрудник, [orcid.org/0000-0002-1272-1839](https://orcid.org/0000-0002-1272-1839)

И. Л. Тарасова<sup>а</sup>, канд. техн. наук, старший научный сотрудник, [orcid.org/0000-0002-2282-150X](https://orcid.org/0000-0002-2282-150X)

<sup>а</sup>Институт проблем машиноведения Российской академии наук, Большой пр. В. О., 61, Санкт-Петербург, 191718, РФ

**Введение:** в системах машинного зрения при обработке результатов экспериментов и моделировании интеллектуальных систем широко используются методы на основе адаптивного резонанса. Такие системы могут работать в условиях неопределенности, для описания которой используются интервальные данные. Но известные методы теории адаптивного резонанса не оперируют таким типом данных. **Цель:** разработать динамическую нейронную сеть на основе теории адаптивного резонанса для анализа образов с интервальными атрибутами и создать методы ее обучения. **Результаты:** предложена структура интервальной нейронной сети с использованием теории адаптивного резонанса, которая позволяет решать задачу кластеризации данных при анализе многомерных образов с интервальными атрибутами в условиях действия различного рода помех и искажений. На ее основе разработана компьютерная программа для моделирования данной нейронной сети при решении указанной задачи. Проведено численное моделирование представленной интервальной нейронной сети, показавшее высокую эффективность при анализе зашумленных образов. Сеть обладает свойством самообучения. Анализ предложенных моделей мер близости (бинарной, меры близости 1, меры близости 2) входных образов нейронной сети и хранящихся в памяти продемонстрировал их схожую эффективность, но лучшей точностью обладает мера близости 2, которая и рекомендуется в качестве основной. **Практическая значимость:** описанная интервальная нейронная сеть расширяет возможности машинного зрения, мобильных роботов, может использоваться для создания систем анализа конфигурации пространства, в котором данный робот функционирует. Сеть может применяться также для выявления скрытых закономерностей при анализе экспериментальных данных, при создании информационно-советующих систем, работающих в условиях интервальной неопределенности.

**Ключевые слова** — искусственные нейронные сети, теория адаптивного резонанса, интервальные вычисления, интервальные нейронные сети, распознавание образов.

**Для цитирования:** Кучмин А. Ю., Расова С. С., Тарасова И. Л. Интервальная ART-нейронная сеть для решения задач кластеризации при анализе образов с интервальными атрибутами. *Информационно-управляющие системы*, 2026, № 2, с. 16–26. doi:10.31799/1684-8853-2026-2-16-26, EDN: NUDWKF

**For citation:** Kuchmin A. Yu., Rasova S. S., Tarasova I. L. Interval ART neural network for clustering images with interval attributes. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2026, no. 2, pp. 16–26 (In Russian). doi:10.31799/1684-8853-2026-2-16-26, EDN: NUDWKF

### Введение

Современные информационно-управляющие системы работают в условиях наличия всевозможных неопределенностей и ограничений [1–4]. Поэтому разрабатывать математические модели подобных систем и алгоритмы управления необходимо с учетом данных неопределенностей. Наиболее простой подход в описании подобного рода систем — это использование интервальных методов и моделей. В настоящее время интервальные методы интенсивно развиваются [5–9], что позволяет обращаться к ним при решении задач распознавания образов и управления сложными физико-техническими системами. Большое внимание в современной теории управления уделяется применению интеллектуаль-

ных средств [10–12], в частности, существуют такие парадигмы, как нечеткие системы, нейронные сети, эмерджентные системы, эволюционные методы и т. д., каждая из которых имеет свои преимущества и недостатки. Перспективным при распознавании образов и управлении является использование нейронных сетей не только прямого распространения, но и рекуррентных с памятью, например нейронных сетей на основе теории адаптивного резонанса (ART-нейронных сетей) [13–21]. Все больше в интеллектуальных системах объединяются различные парадигмы искусственного интеллекта в целях сочетания сильных свойств методов и возможностей устранения недостатков. Это направление под названием «гибридные интеллектуальные системы» в настоящий момент эффективно развивается.

Нейронные сети обладают высокой обобщающей способностью, поэтому выбор данной парадигмы и объединение с методами интервального анализа позволяют еще больше расширить это свойство. Создание новых видов интервальных нейронных сетей — важная и актуальная задача. ART-нейронные сети имеют преимущество над сетями прямого распространения, поэтому является перспективным их развитие и объединение с интервальными методами, что до недавнего времени не разрабатывалось. В частности, ART-нейронные сети с применением гибридного подхода объединялись с нечеткой логикой, эволюционными методами, но не использовались для анализа интервальных данных.

### Основные сведения об ART-нейронных сетях

Теория адаптивного резонанса предложена Гроссбергом и Карпендером в 1987 г. для решения задач кластеризации данных, что привело к разработке ART-алгоритмов сначала для бинарных данных, а впоследствии — непрерывных и нечетких данных. Затем на базе разработанных алгоритмов были созданы ART-нейронные сети. Гроссберг и Карпендер пытались решить задачу стабильности и пластичности при распознавании образов, которая заключается в необходимости усваивать новые знания при сохранении уже проверенной информации, что моделирует процесс восприятия и обучения человеком. Требуется соблюсти баланс между фрагментированием нового поступающего знания и обобщением данного знания, что нашло реализацию в виде нового класса динамических нейронных сетей — ART-нейронных сетей. В основе технологии лежит идея генерации отклика нейронной сети и сравнение данного отклика с входным образом при выполнении специального теста под названием «тест бдительности». Коэффициент бдительности — это некоторый пороговый коэффициент, определяющий близость поступающей новой информации к уже хранящейся в нейронной сети. Если входной образ близок к отклику, который хранится в памяти нейронной сети, то входной образ добавляется в память оператором обобщения. Таким образом формируются кластеры, которые используются при решении задачи распознавания образов. Классическая ART-сеть состоит из двух слоев, каждый из которых представляет собой самоорганизующуюся карту Кохонена. Они соединяются между собой входными звездами и выходными звездами, которые являются элементами нейронной сети. Также используется специальный блок для вычисления коэффициента бдительности, который управля-

ет активностью нейронов второй самоорганизующейся карты Кохонена. Используемые виды ART-нейронных сетей работают с бинарными, непрерывными и нечеткими данными. В задачах распознавания образов и интеллектуальном управлении приходится оперировать различного рода неопределенностями, одними из самых простых моделей которых являются интервальные. Поэтому насущно создание гибридной нейронной сети на основании ART-технологии и интервальных вычислений. Цель данной работы — разработка ART-нейронной сети, оперирующей интервальными данными.

### Основные сведения об интервальных вычислениях

Теория интервальных вычислений — это интенсивно развивающееся направление, основная идея которого заключается в использовании интервальных данных при решении различного рода задач математического анализа, теории управления, искусственного интеллекта и пр. Данный подход разрабатывается уже долгое время (работы Э. Р. Хансена, Ю. И. Шокина, В. И. Левина, С. П. Шарого и др.). В 2015 г. был принят международный стандарт интервальных вычислений IEEE 1788-2015. Следует отдельно отметить вклад В. И. Левина в разработку методов исследования систем, работающих в условиях неопределенности. Основным математическим объектом интервальных вычислений является интервал и связанные с ним величины, такие как интервальные функции и производные от них математические объекты. Можно разделить операции над интервалами как над множествами (объединение, пересечение и т. д.) и интервальную арифметику, когда используются обычные математические операции, но над интервальными данными (сложение, вычитание, умножение, деление и др.). Обобщая работы упомянутых ученых, можно сделать вывод, что интервальные методы являются простым механизмом учета различного рода неопределенностей при описании поведения систем. В реальных системах мы получаем параметры, которые с определенной долей достоверности находятся в некоторых интервалах, поэтому выбор интервальных методов определяется самим типом данных, получаемых с измерительных систем. С другой стороны, существующие методы интервального анализа не совсем применимы для решения задач интеллектуального управления и распознавания образов в динамических системах, так как на каждом этапе вычислений возможно увеличение диапазонов интервальных оценок, что часто приводит к вырождению задач.

Также необходима разработка методов обучения с использованием интервальных данных в системах с искусственным интеллектом. Поэтому объединение технологии ART-нейронных сетей и интервальных вычислений позволит получить методы обучения с использованием интервальных данных.

### Структура интервальной ART-нейронной сети

Принципы работы ART-нейронной сети обеспечивают выполнение трех основных операций: сравнения входящего образа с образом, хранящимся в нейронной сети; вычисления меры близости этих двух образов и вычисления порога бдительности; обобщения входящего образа на основании информации, хранящейся в нейронной сети. Для каждой операции необходимо определить математическую модель. Так как мы оперируем интервальными данными, математические операции тоже должны носить интервальный характер. Операция сравнения должна характеризоваться концентрацией информации, и для этого лучше всего подходит операция пересечения интервалов. Поскольку приходится одновременно оперировать несколькими входными величинами в нейронной сети, мы получаем вектор параметров, элементы которого являются интервалом. Такой математический объект носит название бруска. Мы решаем задачу пересечения данных брусков. Результат пересечения двух интервалов тоже является интервалом. По итогу операции пересечения мы сокращаем неопределенность.

Для операции вычисления меры близости входного образа и хранящегося в нейронной сети могут быть выбраны следующие модели.

1. Бинарная. Если интервалы имеют хотя бы один общий элемент, тогда функция близости двух интервалов равна единице, в противном случае нулю. Для каждого элемента бруска функции близости суммируются, и вычисляется их среднее значение, которое берется в качестве меры близости двух образов.

2. Мера близости 1. Для двух интервалов вводится следующая мера близости. На первом этапе вычисляется пересечение входного интервала и хранящегося в нейронной сети. Затем определяется длина полученного интервала. Функция близости двух интервалов находится как отношение вычисленной длины интервала, полученного после операции пересечения, к длине эталонного интервала, который хранится в нейронной сети. В случае, если длина эталонного интервала равна нулю (интервал вырождается в число), а результат пересечения интервалов

не является пустым множеством, функция близости равна единице. Если результат пересечения интервалов является пустым множеством, а эталонный интервал представляет собой число, функция близости равна нулю. Следует отметить, что эталонный интервал не может быть пустым множеством. Таким образом, вычисляется функция близости для каждого элемента бруска, а далее находится их среднее значение.

3. Мера близости 2. Вычисляется по аналогии с мерой близости 1. Находится интервал пересечения двух соответствующих интервалов: одного из входящего образа и второго эталонного, хранящегося в нейронной сети. Определяется его длина. Функция близости двух интервалов вычисляется как отношение длины интервала пересечения входного и эталонного интервалов к максимальному значению из длин входного и эталонного интервалов. В случае, если входной и эталонный интервалы являются вырожденными и равными друг другу, функция близости равна единице. В случае, если оба интервала являются вырожденными и неравными друг другу, функция близости равна нулю. Входной и эталонный интервалы не могут быть пустыми множествами. Далее функция близости вычисляется для соответствующих элементов входного и эталонного брусков, а мера близости вычисляется как среднее значение функции близости.

Следующей мы рассмотрим операцию обобщения информации нейронной сетью. В классическом ART-алгоритме используется операция объединения входного и эталонного образов, если превышен порог бдительности. Операция объединения для интервальных данных в общем случае приводит к появлению математических объектов, которые не являются интервалами, а интервал будет только в случае, если оба интервала имеют хотя бы одно общее значение. Нам требуется получать результат в виде интервала для всех возможных случаев данных, с которыми оперирует нейронная сеть. Поэтому мы будем использовать арифметическую операцию вычисления среднего для нескольких интервалов:


$$\bar{a} = \frac{1}{N} \sum_i a_i,$$

где  $\bar{a}$  — осредненный интервал;  $N$  — число интервалов;  $i$  — индекс интервала;  $a_i$  —  $i$ -й интервал.

Результатом вычисления среднего для интервалов будет тоже интервал, что соответствует нашим критериям. Наша нейронная сеть является динамической и обладает памятью на  $N$ -е число образов одного кластера. Поэтому будет выполняться осреднение по всем этим образам.

Предлагаемая интервальная ART-нейронная сеть состоит из двух слоев, соединенных между собой соответствующими связями. В первом слое решается задача вычисления интервалов пересечения между входным образом и эталонными образами, хранящимися в памяти нейронной сети, которые являются центрами кластеров. В структуру нейронной сети входит также блок вычисления меры близости входного образа и эталонных образов. Соответственно, в качестве меры близости может быть выбрана одна из рассмотренных выше. После вычисления мер близости для всех эталонных образов вычисляется максимальное значение и соответствующий ему эталонный образ. В случае если существует несколько эталонных образов с одинаковой мерой близости, то выбирается первый по очередности. Уровень бдительности рассчитывается исходя из меры близости входного образа и эталонных образов нейронной сети. В простейшем случае уровень бдительности рассчитывается как максимум значений мер близости входного образа и эталонных образов нейронной сети. Если уровень бдительности ниже заданного порогового значения (порог 1, параметр пластичности), то создается новый эталонный образ, который является входным образом. Если уровень бдительности больше некоторого порогового значения (порог 2, параметр жесткости), то считается, что сеть распознала образ, и этот образ является эталонным образом с соответствующим номером. Входной образ помещается в память второго слоя в раздел, соответствующий эталону-победителю. Объем памяти в данном разделе ограничен, и при его превышении происходит осреднение эталонного образа и образов, хранящихся в памяти соответствующего раздела. Таким образом модифицируется эталонный образ. Если уровень бдительности не превышает порога 2, то определяется эталонный образ по максимуму меры близости между входным образом и эталонными. Выбирается тот эталонный образ, для которого мера близости максимальна. Запись входного образа в память второго слоя не производится.

Интервальную ART-нейронную сеть (рисунок) составляют следующие блоки: слой 1, слой 2 и вспомогательные блоки. Слой 1 включает в себя блоки сравнения  $C_1, \dots, C_n$ , на которых осуществляется сравнение входного образа  $VO$  и эталонов, хранящихся в памяти нейронной сети. Каждый блок сравнения вычисляет меру близости эталона и входного образа. Слой 2 состоит из  $n$  каналов, каждый из которых связан с соответствующим эталоном. Каждый канал состоит из блока эталона  $\Theta_i$ , блока осреднения  $BO$  и блока памяти  $BP$ . Блок памяти хранит информацию обо всех распознанных образах, мера близости которых превышает порог 2. Блок памяти име-



■ Структура интервальной ART-нейронной сети для решения задач кластеризации  
 ■ Structure of an interval ART neural network for solving clustering tasks

ет ограниченную емкость. При переполнении памяти происходит осреднение образов, хранящихся в блоке памяти, и эталона, хранящегося в блоке эталона. После этого память освобождается, а в блок эталона записывается новое значение эталона. Управление схемой совершается с помощью блока управления  $БУ$  и коммутаторов  $K_1$  и  $K_2$ . Блок управления вычисляет номер эталона-победителя и коммутирует соответствующий канал передачи данных. Блок управления осуществляет управление записью в блоке памяти через коммутатор  $K_1$ , а также выдачу данных эталона-победителя через коммутатор  $K_2$  на выход с названием «распознанный образ»  $PO$ . В случае, если мера близости эталона-победителя ниже порога 1, блок управления расширяет слой 1 и 2, добавляя новые каналы.

Предлагаемая структура интервальной ART-нейронной сети, как мы видим, обладает свойством самообучения, что выражается в добавлении новых эталонных образов и их модификации за счет операции обобщения. Следует отметить, что, варьируя значениями порогов 1 и 2, можно управлять процессом стабильности и пластичности при решении задач распознавания образов нейронной сетью. Так, если порог 1 имеет малое значение, то новые эталонные образы будут добавляться реже. Если порог 2 очень высокий, то добавление новых образов в память второго слоя тоже будет реже, что в свою очередь существенно скажется на свойстве обобщения нейронной сети.

### Алгоритм моделирования интервальной ART-нейронной сети

В данном разделе описывается алгоритм программы, моделирующей работу интервальной ART-нейронной сети. В качестве входных образов используются бруски с интервальными атрибутами, характеризующие классифицируемые объекты.

1. Начало.

2. Вводятся параметры нейронной сети: порог 1 (параметр пластичности), порог 2 (параметр жесткости), максимальная длина интервала атрибута, размер памяти нейронной сети, база эталонных образов  $\mathbf{e}_i = [e_{i,1}, \dots, e_{i,m}]$ , полученных на стадии обучения нейронной сети (если обучение проводилось), где  $e_{i,1}, \dots, e_{i,m}$  — атрибуты эталона, заданные в виде интервалов.

3. Выбирается тип меры близости: 0 — бинарная, 1 — мера близости 1, 2 — мера близости 2.

4. Вводится входной образ с интервальными атрибутами  $\mathbf{v} = [v_1, \dots, v_m]$ , где  $v_1, \dots, v_m$  — атрибуты входного образа, заданные в виде интервалов. Атрибуты должны быть нормализованными и находиться в диапазоне от нуля до единицы.

5. Записывается входной образ в первый слой нейронной сети.

6. В первом слое сравниваются входной образ и эталонные образы, хранящиеся в памяти второго слоя нейронной сети. Если эталонные образы отсутствуют, то сохраненный в первом слое образ копируется в память второго слоя и становится эталонным.

7. В результате сравнения входного образа с эталонными для каждого эталонного образа рассчитывается величина меры близости. Для каждого атрибута образа вычисляется функция близости исходя из типа выбранной меры близости. Для бинарной меры близости функция вычисляется по формуле  $f_{i,j} = \begin{cases} 1, & \text{если } |e_{i,j} \cap v_j| > 0 \\ 0, & \text{если } |e_{i,j} \cap v_j| = 0 \end{cases}$ .

В случае меры близости 1 используется выражение  $f_{i,j} = \frac{|e_{i,j} \cap v_j|}{|e_{i,j}|}$ , а для меры близости 2 расчет ведется по формуле  $f_{i,j} = \frac{|e_{i,j} \cap v_j|}{\max(|e_{i,j}|, |v_j|)}$ .

Потом для всего выбранного эталонного образа находится среднее значение функции близости, которое является значением меры близости для данного эталонного образа.

8. Находится максимальное значение меры близости и выбирается соответствующий ему эталонный образ. Рассчитывается уровень бдительности как максимум мер близости эталонов.

9. Если уровень бдительности меньше параметра пластичности, то входной образ записывается в память второго слоя как новый эталонный образ.

10. Если уровень бдительности выше порога жесткости, то выходом нейронной сети является соответствующий эталонный образ. Входной образ копируется в память второго слоя соответствующего эталонного образа. Если количество образов  $\mathbf{b}_{i,k}$  в памяти раздела второго слоя сети, соответствующего эталонному образу, равно максимальному значению, происходит осреднение эталонного образа и образов в памяти по

формуле  $\mathbf{e}_i = \frac{\mathbf{e}_i^*}{N+1} + \frac{1}{N+1} \sum_k \mathbf{b}_{i,k}$ , где  $\mathbf{e}_i^*$  — ис-

ходный  $i$ -й эталонный образ. Полученное среднее значение записывается в качестве эталонного образа, при этом осуществляется контроль величины длины интервальных атрибутов исходя из заданного максимального значения. Если длина интервалов атрибутов больше, их величина уменьшается до максимального размера.

11. В случае если уровень бдительности ниже параметра жесткости, но выше параметра пластичности, то на выход нейронной сети подается соответствующий эталонный образ. Запись в память не осуществляется.

12. Производится запись в файл параметров нейронной сети и состояния памяти нейронной сети и базы эталонных образов.

13. Конец.

Предлагаемый алгоритм работы нейронной сети формирует эталонные образы в ходе функционирования нейронной сети. Для повышения помехоустойчивости эталонные образы в памяти сети могут быть получены в ходе обучения по тестовым выборкам, когда может быть проверена правильность формирования эталонных образов. Алгоритм функционирования нейронной сети при обучении аналогичен описанному выше и отличается тем, что результат обучения записывается в некоторую структуру, где сохраняются такие параметры нейронной сети, как тип меры близости, параметр жесткости, параметр пластичности, максимальная длина интервала атрибута, база эталонных образов, база памяти второго слоя нейронной сети, которые могут быть загружены в нейронную сеть для ее моделирования, что повышает эффективность распознавания образов.

Проанализируем и охарактеризуем рассмотренный алгоритм.

Новый алгоритм обладает сходимостью и при конечном числе входных образов формирует конечное число эталонов: один или больше. Алгоритм устойчив к проблеме размывания границ эталонов, так как длина интервалов атрибу-

тов эталонов ограничена сверху. Алгоритм имеет свойство адаптивности и через пороговые значения порога 1, порога 2 регулирует детализацию кластеризации.

Алгоритм обладает фундаментальной новизной на уровне архитектуры и представляет собой дальнейшее развитие нейронных сетей на основе теории адаптивного резонанса для случая интервальных данных. Предлагаемый алгоритм в отличие от классического подхода ART работает с интервальной неопределенностью на уровне архитектуры в трех режимах: создание, уточнение, идентификация. В отличие от классического ART распознаются блоки памяти для сохранения распознанных образов и в дальнейшем применяется контролируемое осреднение, что позволяет повысить эффективность соблюдения баланса между пластичностью и стабильностью при распознавании. Математическая новизна представлена на уровне модели и заключается в предложении новых мер близости на основе адаптации мер Жаккара. Алгоритмическая новизна заключается в трехуровневом механизме принятия решений, что обеспечивает разделение функций обнаружения новых образов и уточнение известных эталонов. Практическая новизна состоит в возможности решать задачи с неопределенностью, кластеризации образов с интервальными атрибутами, что может повысить эффективность систем медицинской диагностики, систем онлайн-обучения и принятия решений с неопределенностью, адаптивных систем управления.

### Результаты компьютерного моделирования интервальной ART-нейронной сети

Для реализации интервальной ART-нейронной сети был разработан пакет компьютерных программ [22], позволяющий проводить подготовку тестовых данных с различными уровнями погрешности, обучение нейронной сети на тестовых и реальных данных, а также выполнять ее моделирование. Структура данных для обучения и моделирования представляет собой последовательность образов анализируемых объектов, каждый из которых задается в виде матрицы размерности  $m \times 2$ , где  $m$  — количество атрибутов анализируемого образа. Каждая строка образа кодирует атрибут в виде интервального значения. Первый элемент строки — нижняя граница интервала, второй элемент строки — верхняя граница интервала. Все образы имеют одинаковое количество атрибутов. Интервалы атрибутов нормализуются и масштабируются в диапазоне от 0 до 1 таким образом, что интервал атрибута является подынтервалом интервала [0, 1].

Нейронная сеть обрабатывает каждый образ последовательности в отдельности. Выходом сети является образ-победитель, который также задается в виде матрицы  $m \times 2$ , структура которой аналогична входному образу. Кроме того, в сеть при ее моделировании и обучении загружаются дополнительные величины:

- имя файла с обучающими данными;
- имя файла с реальными данными;
- параметр жесткости;
- параметр пластичности;
- максимальная длина интервала атрибута;
- размер памяти нейронной сети;
- тип меры близости.

В качестве выходных данных в файл записывается база данных полученных эталонных образов, которые сформированы при решении задачи кластеризации. Каждый эталонный образ является центром соответствующего кластера, в который группируются данные.

Обучение и тестирование нейронной сети осуществлялось на выборках, сгенерированных с помощью соответствующей программы, позволяющей формировать последовательность тестовых образов, которые зашумляются с соответствующим уровнем погрешности, меняющимся в диапазоне от 0 до 100 % от минимального расстояния между задаваемыми эталонными тестовыми образами и максимальной длины атрибута тестового эталонного образа. Для более удобного анализа работы нейронной сети количество тестовых эталонных образов было ограничено четырьмя. Каждый тестовый эталонный образ имел пять атрибутов.

Поскольку нейронная сеть решает задачу кластеризации данных, возникает проблема сравнения выходного образа и тестового эталонного образа, который был зашумлен и подавался на вход. Поэтому точность распознавания образа определялась с помощью вычисления меры близости зашумленного тестового эталонного образа и отклика сети с использованием меры близости 2.

Обучение нейронной сети проводилось на выборке, сформированной из зашумленных эталонных тестовых образов с амплитудой помехи 10 %, при этом зашумлялась и ширина интервалов атрибутов, и изменение центров этих интервалов (таким образом, изменялась и ширина интервалов атрибутов, и их смещение). Длина обучающей выборки составила 4000 образов. Анализ базы эталонов нейронной сети показал, что при небольших амплитудах шума все три методики вычисления меры близости (бинарная, мера близости 1, мера близости 2) демонстрировали высокую эффективность. Средняя мера близости эталонных образов нейронной сети и тестовых эталонных образов, закодированных в обучающей последовательности, составила 0,98.

База эталонных образов нейронной сети была загружена в программу моделирования сети. Далее выполнялись эксперименты с тестовыми выборками, которые зашумлялись в диапазоне изменения амплитуды помехи от 0 до 100 %, и проводились тесты различных моделей мер близости. Результаты приведены в табл. 1 (эффективность распознавания образов с использованием мер близости 1 и 2 совпадают).

Моделирование проходило при следующих параметрах нейронной сети:

- параметр жесткости – 0,6;
- параметр пластичности – 0,1;
- максимальная длина интервала атрибута – 0,1;
- размер памяти нейронной сети – 5.

Меры близости (табл. 1) вычислялись следующим образом. Для каждой амплитуды шума генерировалась тестовая последовательность длиной 4000 образов с использованием четырех тестовых эталонных образов, которые зашумлялись. Данная выборка подавалась на вход нейронной сети, и рассчитывались выходные образы – результат распознавания нейронной сети. С помощью модели меры близости 2 выходной образ сравнивался с соответствующим тестовым эталонным образом, который был зашумлен. В дальнейшем для всей выборки рассчитывалась средняя мера близости, которая отображена в таблице.

Анализируя данные в табл. 1, следует отметить, что хуже всех проявила себя бинарная мера близости, а мера близости 1 и мера близости 2 показали схожие результаты. Однако следует учитывать, что при обучении нейронной сети при мере близости 1 были сформированы эталонные образы нейронной сети, которые меньше отличались от тестовых базовых образов по сравнению с мерой близости 2. Можно сказать, что эффективности этих мер схожи.

Следующий эксперимент посвящен анализу стабильности формирования эталонных образов нейронной сети в зависимости от вида меры близости и амплитуды шума во входящей выборке. Обучающая выборка будет формироваться аналогично предыдущим экспериментам, а анализ близости эталонных образов нейронной сети тестовым эталонным образам будет осуществляться также с помощью меры близости 2.

Результаты моделирования, приведенные в табл. 2, показывают, что разработанная интервальная ART-нейронная сеть обладает хорошей эффективностью при решении задач распознавания образов с интервальными атрибутами. Данная нейронная сеть решает задачу кластеризации и позволяет находить скрытые взаимосвязи в последовательности анализируемых образов, что является важным свойством сети,

■ **Таблица 1.** Эффективность распознавания образов от вида методики расчета меры близости при моделировании

■ **Table 1.** Pattern recognition efficiency versus the type of proximity measure calculation method in modeling

Амплитуда помехи, %	Бинарная мера близости	Меры близости 1 и 2
<b>Шум смещает центры интервалов атрибутов образов при неизменной их длине</b>		
0	0,9924	0,9924
10	0,6810	0,9042
20	0,6347	0,8135
30	0,5952	0,7225
40	0,5474	0,7807
50	0,4872	0,6080
60	0,4248	0,4385
70	0,3579	0,4491
80	0,2904	0,3735
90	0,2155	0,0957
100	0,0127	0,0011
<b>Шум изменяет длины интервалов атрибутов образов при неизменных положениях их центров</b>		
0	0,9924	0,9924
10	0,9057	0,9057
20	0,8167	0,8167
30	0,7271	0,7271
40	0,6372	0,8680
50	0,5468	0,9277
60	0,4562	0,9277
70	0,3655	0,9277
80	0,2747	0,9277
90	0,1839	0,7336
100	0,0930	0

которое связано с ее самообучением. Были проанализированы различные типы мер близости и их влияние на качество работы нейронной сети. Показано, что наилучшей эффективностью обладает модель меры близости 2. Модель меры близости 1 не сильно уступает по эффективности мере близости 2, но формирует менее стабильные кластеры по сравнению с мерой близости 2. Мера близости 2 более точно позволяет оценить схожесть двух образов с интервальными атрибутами. Именно поэтому она была выбрана как эталон для расчета эффективности работы нейронной сети.

Как уже сказано, данный алгоритм является дальнейшим развитием теории нейронных сетей на основе ART для адаптации их к работе с неопределенностью. Известны два алгоритма: нечеткая ART и байесова ART. Нечеткая ART оперирует нечеткими множествами, байесова ART оперирует вероятностными характеристиками. Предлагаемый алгоритм оперирует интервальными данными. Все три вида могут быть использованы для описания интервальной

■ **Таблица 2.** Точность формирования эталонных образов нейронной сети от вида методики расчета меры близости при моделировании

■ **Table 2.** Accuracy of neural network prototype formation versus the type of proximity measure calculation method in modeling

Амплитуда помехи, %	Бинарная мера близости	Мера близости 1	Мера близости 2
<b>Шум смещает центры интервалов атрибутов образов при неизменной их длине</b>			
0	1	1	1
10	0,9836	0,9842	0,9842
20	0,9439	0,9685	0,9685
30	0,9451	0,9519	0,9519
40	0,9335	0,9274	0,9274
50	0,6824	0,9080	0,9079
60	0,8861	0,8842	0,8831
70	0,6139	0,8595	0,8558
80	0,8692	0,8085	0,8617
90	0,8181	0,7462	0,7617
100	0,8362	0,7070	0,7527
<b>Шум изменяет длины интервалов атрибутов образов при неизменных положениях их центров</b>			
0	1	1	1
10	0,9900	0,9845	0,9845
20	0,9739	0,9800	0,9800
30	0,9610	0,9684	0,9684
40	0,9418	0,9469	0,9469
50	0,9327	0,9424	0,9325
60	0,9418	0,9441	0,9463
70	0,9211	0,9265	0,9342
80	0,8922	0,9257	0,9335
90	0,9080	0,9078	0,9194
100	0,8600	0,9260	0,9172

неопределенности, но первые два делают это опосредованно, а в предлагаемом алгоритме используются методы интервального анализа, что повышает его эффективность в случае интервальных данных.

Выполнялось сравнение интервальной ART-нейронной сети, которая является динамической и рекуррентной, с интервальными сетями прямого распространения (интервальным перцептроном). Интервальный перцептрон решает задачу классификации, однако классы формируются на стадии обучения, и можно рассматривать этот процесс как задачу кластеризации. Возникает проблема выбора топологии интервального перцептрона. Необходимо применять сложные методы его обучения, стабильность которых зависит от качества обучающей выборки: чем эта выборка больше, тем эффективность обучения будет выше. В сравнении с ним интервальная ART-нейронная сеть имеет более компактную топологию (меньшее число настраиваемых па-

раметров), обладает большей помехоустойчивостью, свойством самообучения и проявляет высокую эффективность при небольших размерах обучающих выборок. При тех же обучающих выборках многослойный перцептрон показал более низкую эффективность, которую можно преодолеть, увеличивая число обучающей выборки и, как следствие, сложность его топологии.

## Заключение

В статье предложена новая динамическая нейронная сеть на основе теории адаптивного резонанса для анализа многомерных образов с интервальными атрибутами. Данная сеть является гибридной и объединяет в себе две технологии: искусственные нейронные сети и методы интервального анализа данных. Настоящая работа закрывает пробел в теории ART-нейронных сетей, в частности, существовали сети для анализа бинарных, непрерывных, нечетких, но не было нейронной сети для работы с интервальными данными. Соответственно, предложена двухслойная интервальная динамическая нейронная сеть на основе ART, которая использует методы интервальных вычислений. Как и другие виды нейронных сетей данного семейства, предлагаемая сеть предназначена для решения задач кластеризации многомерных данных и поиска скрытых закономерностей. Было выполнено численное моделирование данной нейронной сети и показана ее эффективность на тестовых примерах решения задачи распознавания многомерных образов с интервальными атрибутами при наличии шума и различного рода искажений. Показано, что сеть обладает высокой эффективностью и формирует стабильные кластеры с использованием методов самообучения. Отличительной особенностью предлагаемой нейронной сети является вычисление в первом слое меры близости входного образа и образов, хранящихся в памяти нейронной сети. Рассмотрены три основные модели вычисления меры близости: бинарная, мера близости 1 и мера близости 2. Все три меры показали высокую эффективность, однако мера близости 2 в ряде экспериментов показала большую эффективность и идеологически лучше других описывает близость двух интервальных образов. Поэтому она рекомендуется для использования в качестве основной. Дальнейшие исследования данной нейронной сети будут направлены на ее применение в различных областях интеллектуальных электромеханических систем для создания систем машинного зрения, систем принятия решений и анализа экспериментальных данных.



## Финансовая поддержка

Работа выполнена в рамках государственного контракта Министерства науки и высшего образования Российской Федерации № 124041500008-1

## Литература

1. Yang C., Wang Q., Lu W., Li Y. Integrated uncertain optimal design strategy for truss configuration and attitude–vibration control in rigid–flexible coupling structure with interval uncertainties. *Nonlinear Dynamics*, 2025, vol. 113, no. 3, pp. 2215–2238. <https://doi.org/10.1007/s11071-024-10291-w>
2. Калашников П. В. Применение сценарного подхода к анализу и управлению рисками при функционировании сложных динамических систем в условиях интервальной неопределенности. *Транспорт и информационные технологии*, 2023, т. 13, № 3, с. 224–236. doi:10.12731/2227-930X-2023-13-3-224-236. <https://ijournal-as.com/jour/index.php/ijas/article/view/237> (дата обращения: 29.01.2025).
3. Lai Y., Shi Y., Han Y., Shao Y., Qi M., Li B. Exploring uncertainty in regression neural networks for construction of prediction intervals. *Neurocomputing*, 2022, vol. 481, pp. 249–257. doi:10.1016/j.neucom.2022.01.084
4. Носков С. И., Кириллова Т. К., Ведерников В. С. Взвешивание наблюдений выборки при построении линейной регрессии по данным с интервальной неопределенностью для независимых переменных. *Известия высших учебных заведений. Северо-Кавказский регион. Технические науки*, 2024, № 4 (224), с. 51–56. doi:10.17213/1560-3644-2024-4-51-56
5. Шарый С. П. *Конечномерный интервальный анализ*. Новосибирск, XYZ, 2022. 654 с.
6. Баженов А. Н., Жилин С. И., Кумков С. И., Шарый С. П. *Обработка и анализ интервальных данных*. М., Ижевск, Институт компьютерных исследований, 2024. 356 с.
7. Выгодчикова И. Ю., Горский М. А., Максимов Д. А., Халиков М. А. *Теоретические подходы и инструментарий моделирования динамических рядов интервальных данных*. М., Академия Естествознания, 2025. 184 с.
8. Червяков А. А., Никульчев Е. В. Робастное интервальное прогнозирование временных рядов. *International Journal of Open Information Technologies*, 2023, vol. 11, no. 4, pp. 122–128. <http://injoit.org/index.php/j1/article/view/1540> (дата обращения: 18.09.2025).
9. Болотнов А. М., Купцова А. Ф. Нестандартные интервальные операции при решении прикладных задач. *Современные наукоемкие технологии*, 2023, № 2, с. 17–22. doi:10.17513/snt.39518
10. Rossi F., Bernardeschi C., Cococcioni M. Neural networks in closed-loop systems: Verification using interval arithmetic and formal prover. *Engineering Applications of Artificial Intelligence*, 2024, vol. 137. <https://doi.org/10.1016/j.engappai.2024.109238>
11. Canillas S. F., da Silva R. J., Minussi C. R. *Behavioral Diagnosis on Individual Electricity Consumption: Formulation Using a Neural Network Based on Adaptive Resonance Theory*. 2025, 20 p. doi:10.20944/preprints202507.2247.v1. <https://www.preprints.org/manuscript/202507.2247/v1> (дата обращения: 10.09.2025).
12. Федутин К. А., Каширина И. Л. Разработка средств интеллектуальной поддержки принятия решений на основе данных мониторинга. *Вестник Воронежского института высоких технологий*, 2023, № 3 (46). <https://vestnikvvt.ru/ru/journal/article?id=192&ysclid=mfpb0cflzk954566701> (дата обращения: 19.08.2025).
13. Buhanov D., Chernikov S., Polyakov V., Panchenko M. Detection of video image modification using a classifier based on adaptive resonance theory. *International Scientific and Practical Conference on Information Technologies and Intelligent Decision Making Systems*, Springer, 2022, pp. 23–32. [https://doi.org/10.1007/978-3-031-31353-0\\_3](https://doi.org/10.1007/978-3-031-31353-0_3)
14. Bargsten V., Kirchner F. Actuator-level motion and contact episode learning and classification using adaptive resonance theory. *Intelligent Service Robotics*, 2023, vol. 16, no. 5, pp. 537–548. <https://doi.org/10.1007/s11370-023-00481-7>
15. Da Silva L. E. B., Rayapati N., Wunsch D. C. iCVI-ARTMAP: Using incremental cluster validity indices and adaptive resonance theory reset mechanism to accelerate validation and achieve multiprototype unsupervised representations. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, vol. 34, no. 12, pp. 9757–9770. doi:10.1109/TNNLS.2022.3160381
16. Pourpanah F., Lim C. P., Etemad A., Wu Q. J. An ensemble semi-supervised adaptive resonance theory model with explanation capability for pattern classification. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, vol. 8, no. 1, pp. 814–827. doi:10.1109/TETCI.2023.3285932
17. Czmil S., Kluska J., Czmil A. An empirical study of a simple incremental classifier based on vector quantization and adaptive resonance theory. *International Journal of Applied Mathematics and Computer Science*, 2024, vol. 34, no. 1, pp. 149–165. doi:10.61822/amcs-2024-0011
18. Wu W., Hu Y., Xu K., Qin L., Yin Q. Self-organizing memory based on adaptive resonance theory for vision

and language navigation. *Mathematics*, 2023, vol. 11, no. 19. <https://doi.org/10.3390/math11194192>. <https://www.mdpi.com/2227-7390/11/19/4192> (дата обращения: 27.08.2025).

19. Zangana H., Mustafa F. M., Omar M. Advances in adaptive resonance theory for object identification and recognition in image processing. *Jurnal Ilmiah Computer Science*, 2025, vol. 3, no. 2, pp. 86–100. <https://doi.org/10.58602/jics.v3i2.41>

20. Zangana H., Mohammed A. K., Omar M., Mustafa F. M., Vitianingsih A. V. Adaptive resonance theory-based approach for robust and efficient face recognition. *Vokasi Unesa Bulletin of Engineering, Technology and Applied Science*, 2025, vol. 2, no. 3, pp. 602–618. <https://doi.org/10.26740/vubeta.v2i3.38709>. <https://journal.unesa.ac.id/index.php/vubeta/article/view/38709> (дата обращения: 15.03.2025).

38709. <https://journal.unesa.ac.id/index.php/vubeta/article/view/38709> (дата обращения: 15.03.2025).

21. Masuyama N., Nojima Y., Toda Y., Loo C. K., Ishibuchi H., Kubota N. Privacy-preserving continual federated clustering via adaptive resonance theory. *IEEE Access*, 2024, vol. 12, pp. 139692–139710. doi:10.1109/ACCESS.2024.3467114. <https://ieeexplore.ieee.org/abstract/document/10689590> (дата обращения: 18.03.2025).

22. Свидетельство о государственной регистрации программы для ЭВМ № 2025617415. Программа для моделирования интервальной нейронной сети с самообучением по технологии ART, Кучмин А. Ю. (RU), Тарасова И. Л. (RU); заявл. 14.03.2025; опубл. 25.03.2025.

UDC 681.5

doi:10.31799/1684-8853-2026-2-16-26

EDN: NUDWKF

### Interval ART neural network for clustering images with interval attributes

A. Yu. Kuchmin<sup>a</sup>, Dr. Sc., Tech., Leading Researcher, [orcid.org/0000-0003-0699-6112](https://orcid.org/0000-0003-0699-6112), [radiotelescope@yandex.ru](mailto:radiotelescope@yandex.ru)

S. S. Rasova<sup>a</sup>, PhD, Phys.-Math., Senior Researcher, [orcid.org/0000-0002-1272-1839](https://orcid.org/0000-0002-1272-1839)

I. L. Tarasova<sup>a</sup>, PhD, Tech., Senior Researcher, [orcid.org/0000-0002-2282-150X](https://orcid.org/0000-0002-2282-150X)

<sup>a</sup>Institute for Problems in Mechanical Engineering of the Russian Academy of Science, 61, Bol'shoi Pr. V. O., 199178, Saint-Petersburg, Russian Federation

**Introduction:** In machine vision systems, experimental data processing, and intelligent system modeling, methods based on adaptive resonance are widely used. These systems can operate under uncertainty, which is described using interval data. However, the existing methods of adaptive resonance theory do not operate with this type of data. **Purpose:** To develop a dynamic neural network based on adaptive resonance theory for the analysis of images with interval-valued attributes and to create its training methods. **Results:** We propose a structure of an interval neural network based on adaptive resonance theory, which enables solving the problem of data clustering in the analysis of multidimensional images with interval-valued attributes under various types of noise and distortions. We develop a computer program to simulate this neural network for solving problems of analyzing multidimensional images with interval-valued attributes. We have conducted Numerical simulation of this interval neural network has been conducted, demonstrating high efficiency in analyzing noisy images. The proposed network possesses self-learning capability. Various models of proximity measures between input patterns and stored patterns in the neural network have been analyzed. We propose three proximity measure models: binary measure, proximity measure 1, and proximity measure 2, which show similar effectiveness. However, proximity measure 2 has demonstrated better accuracy and is recommended as the primary one. **Practical relevance:** The proposed interval neural network can serve as a foundation for machine vision, mobile robots, as well as for creating systems to analyze the configuration of the space in which a robot operates. Furthermore, this neural network can be applied to identify hidden patterns in the analysis of experimental data and can be used in creating information and advisory systems operating under interval uncertainty.

**Keywords** – artificial neural networks, adaptive resonance theory, interval computations, interval neural networks, pattern recognition.

**For citation:** Kuchmin A. Yu., Rasova S. S., Tarasova I. L. Interval ART neural network for clustering images with interval attributes. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2026, no. 2, pp. 16–26 (In Russian). doi:10.31799/1684-8853-2026-2-16-26, EDN: NUDWKF

### Financial support

The work was carried out within the framework of the state assignment of the Ministry of Science and Higher Education of the Russian Federation for the Institute for Problems in Mechanical Engineering of the Russian Academy of Science (No. 124041500008-1).

### References

1. Yang C., Wang Q., Lu W., Li Y. Integrated uncertain optimal design strategy for truss configuration and attitude-vibration control in rigid-flexible coupling structure with interval uncertainties. *Nonlinear Dynamics*, 2025, vol. 113, no. 3, pp. 2215–2238. <https://doi.org/10.1007/s11071-024-10291-w>
2. Kalashnikov P. V. Application of the scenario approach to the analysis and control of risks in the operation of complex dynamic systems under conditions of interval uncertainty. *Transportation and Information Technologies in Russia*, 2023, vol. 13, no. 3, pp. 224–236 (In Russian). doi:10.12731/2227-930X-2023-13-3-224-236. Available at: <https://ijournal-as.com/jour/index.php/ijas/article/view/237> (accessed 29 January 2025).
3. Lai Y., Shi Y., Han Y., Shao Y., Qi M., Li B. Exploring uncertainty in regression neural networks for construction of prediction intervals. *Neurocomputing*, 2022, vol. 481, pp. 249–257. doi:10.1016/j.neucom.2022.01.084
4. Noskov S. I., Kirillova T. K., Vedernikov V. S. Weighting of sample observations when constructing a linear regression on data with interval uncertainty for independent variables.

- Bulletin of Higher Educational Institutions. North Caucasus Region. Technical Sciences*, 2024, no. 4, pp. 51–56 (In Russian). doi:10.17213/1560-3644-2024-4-51-56
5. Sharyi S. P. *Konechomernyi interval'nyi analiz* [Finite interval analysis]. Novosibirsk, XYZ Publ., 2022. 654 p. (In Russian).
  6. Bajenov A. N., Jilin S. I., Kumkov S. I., Sharyi S. P. *Obrabotka i analiz interval'nykh dannykh* [Processing and analysis of interval data]. Moscow, Izhevsk, Institut komp'yuternykh issledovaniy Publ., 2024. 356 p. (In Russian).
  7. Vygodchikova I. Yu., Gorskii M. A., Maksimov D. A., Halikov M. A. *Teoreticheskie podhody i instrumentarii modelirovaniya dinamicheskikh ryadov interval'nykh dannykh* [Theoretical approaches and tools for modeling dynamic series of interval data]. Moscow, Akademiya Estestvoznaniya Publ., 2025. 184 p. (In Russian).
  8. Chervyakov A. A., Nikulchev E. V. Robust interval time series forecasting. *International Journal of Open Information Technologies*, 2023, vol. 11, no. 4, pp. 122–128 (In Russian). Available at: <http://injoit.org/index.php/j1/article/view/1540> (accessed 18 September 2025).
  9. Bolotnov A. M., Kuptsova A. F. Non-standard interval operations in solving applied problems. *Modern High Technologies*, 2023, no. 2, pp. 17–22 (In Russian). doi:10.17513/snt.39518
  10. Rossi F., Bernardeschi C., Cococcioni M. Neural networks in closed-loop systems: Verification using interval arithmetic and formal prover. *Engineering Applications of Artificial Intelligence*, 2024, vol. 137. <https://doi.org/10.1016/j.engappai.2024.109238>
  11. Canillas S. F., da Silva R. J., Minussi C. R. *Behavioral Diagnosis on Individual Electricity Consumption: Formulation Using a Neural Network Based on Adaptive Resonance Theory*. 2025, 20 p. doi:10.20944/preprints202507.2247.v1. Available at: <https://www.preprints.org/manuscript/202507.2247/v1> (accessed 10 September 2025).
  12. Fedutinov K. A., Kashirina I. L. Development of intelligent decision support tools based on monitoring data. *Vestnik Voronezhskogo instituta vysokih tehnologii*, 2023, no. 3 (46). Available at: <https://vestnikvvt.ru/ru/journal/article?id=192&ysclid=mfpb0cflzk954566701> (accessed 19 August 2025) (In Russian).
  13. Buhanov D., Chernikov S., Polyakov V., Panchenko M. Detection of video image modification using a classifier based on adaptive resonance theory. *International Scientific and Practical Conference on Information Technologies and Intelligent Decision Making Systems*, Springer, 2022, pp. 23–32. [https://doi.org/10.1007/978-3-031-31353-0\\_3](https://doi.org/10.1007/978-3-031-31353-0_3)
  14. Bargsten V., Kirchner F. Actuator-level motion and contact episode learning and classification using adaptive resonance theory. *Intelligent Service Robotics*, 2023, vol. 16, no. 5, pp. 537–548. <https://doi.org/10.1007/s11370-023-00481-7>
  15. Da Silva L. E. B., Rayapati N., Wunsch D. C. iCVI-ARTMAP: Using incremental cluster validity indices and adaptive resonance theory reset mechanism to accelerate validation and achieve multiprototype unsupervised representations. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, vol. 34, no. 12, pp. 9757–9770. doi:10.1109/TNNLS.2022.3160381
  16. Pourpanah F., Lim C. P., Etemad A., Wu Q. J. An ensemble semi-supervised adaptive resonance theory model with explanation capability for pattern classification. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, vol. 8, no. 1, pp. 814–827. doi:10.1109/TETCI.2023.3285932
  17. Czmlil S., Kluska J., Czmlil A. An empirical study of a simple incremental classifier based on vector quantization and adaptive resonance theory. *International Journal of Applied Mathematics and Computer Science*, 2024, vol. 34, no. 1, pp. 149–165. doi:10.61822/amcs-2024-0011
  18. Wu W., Hu Y., Xu K., Qin L., Yin Q. Self-organizing memory based on adaptive resonance theory for vision and language navigation. *Mathematics*, 2023, vol. 11, no. 19. <https://doi.org/10.3390/math11194192>. Available at: <https://www.mdpi.com/2227-7390/11/19/4192> (accessed 27 August 2025).
  19. Zangana H., Mustafa F. M., Omar M. Advances in adaptive resonance theory for object identification and recognition in image processing. *Jurnal Ilmiah Computer Science*, 2025, vol. 3, no. 2, pp. 86–100. <https://doi.org/10.58602/jics.v3i2.41>
  20. Zangana H., Mohammed A. K., Omar M., Mustafa F. M., Vitaningsih A. V. Adaptive resonance theory-based approach for robust and efficient face recognition. *Vokasi Unesa Bulletin of Engineering, Technology and Applied Science*, 2025, vol. 2, no. 3, pp. 602–618. <https://doi.org/10.26740/vubeta.v2i3.38709>. Available at: <https://journal.unesa.ac.id/index.php/vubeta/article/view/38709> (accessed 15 March 2025).
  21. Masuyama N., Nojima Y., Toda Y., Loo C. K., Ishibuchi H., Kubota N. Privacy-preserving continual federated clustering via adaptive resonance theory. *IEEE Access*, 2024, vol. 12, pp. 139692–139710. doi:10.1109/ACCESS.2024.3467114. Available at: <https://ieeexplore.ieee.org/abstract/document/10689590> (accessed 18 March 2025).
  22. Kuchmin A. Yu., et al. *Programma dlya modelirovaniya interval'noy neyronnoy seti s samoobucheniem po tekhnologii ART* [A program for simulating an interval neural network with self-learning based on ART technology]. Certificate RU, no. 2025617415, 2025.