

УДК 519.4

DOI 10.24412/2413-7383-2025-2-37-4-12

М. А. Наумов, А. Ю. Карповский

Научно-исследовательский и проектно-конструкторский институт по автоматизации горных машин «ГБУ Автоматгормаш им. В. А. Антипова»  
Российская Федерация, ДНР, 283003 г. Донецк, пр. Ильича, 93

## МЕТОДЫ ПОВЫШЕНИЯ ТОЧНОСТИ КЛАССИФИКАЦИИ ОБЪЕКТОВ ПРИ ПОСТРОЕНИИ СИСТЕМЫ ЗРЕНИЯ ДЛЯ ИССЛЕДОВАНИЯ ОГРАНИЧЕННЫХ ПРОСТРАНСТВ

M. A. Naumov, A. Y. Karpovsky

Scientific Research and Design Institute for Automation of Mining Machines "GBU Automatgormash named after V. A. Antipov"  
Russian Federation, DNR, 283003 93 Ilyich ave., Donetsk

## METHODS FOR IMPROVING THE ACCURACY OF OBJECT CLASSIFICATION WHEN BUILDING A VISION SYSTEM FOR EXPLORING CONFINED SPACES

В статье рассматриваются методы повышения точности классификации объектов в системах технического зрения, работающих в ограниченных пространствах. Предложены подходы к синтезу нейросетевых моделей на основе логических нейронов и сигмоидальных функций активации, обеспечивающие адаптивность к неполным и зашумлённым данным. Развита концепция фрактальной структуры (ФФС) и кооперативной нейросетевой архитектуры, объединяющей частные модели для улучшения точности решений. Представленные методы повышают интерпретируемость и устойчивость нейросетей, что особенно актуально для интеллектуальных систем навигации и анализа в технически сложных условиях.

**Ключевые слова:** Искусственные нейронные сети, классификация объектов, фрактальная структура нейросети, системы технического зрения, логические нейроны.

The article discusses methods for improving the accuracy of object classification in vision systems operating in confined spaces. Approaches to the synthesis of neural network models based on logical neurons and sigmoidal activation functions are proposed, providing adaptivity to incomplete and noisy data. The concept of fractal structure (FFS) and cooperative neural network architecture, combining private models to improve the accuracy of solutions, has been developed. The presented methods increase the interpretability and stability of neural networks, which is especially important for intelligent navigation and analysis systems in technically difficult conditions.

**Key words:** Artificial neural networks, classification of objects, fractal structure of neural networks, vision systems, logical neurons.

**Целью исследования** является разработка и обоснование методов повышения точности классификации объектов в системах технического зрения, функционирующих в условиях ограниченного пространства и при наличии зашумлённых или неполных исходных данных. Особое внимание уделяется синтезу интерпретируемых и устойчивых нейросетевых моделей, обеспечивающих адаптивность к внешним воздействиям и неопределённости, с использованием логических нейронов, фрактальной структуры и кооперативных архитектур.

Для достижения поставленной цели решаются следующие **задачи**:

1. Проанализировать существующие подходы к синтезу искусственных нейронных сетей (ИНС) и выявить их ограничения в условиях ограниченного и зашумлённого пространства данных.

2. Исследовать возможности использования логических нейронов и пороговых функций активации для повышения интерпретируемости и формализации логических операций в рамках нейросетевой архитектуры.

3. Разработать метод построения нейросетей с фрактальной структурой (ФФС), обеспечивающей минимизацию ошибки при обучении и устойчивость к недостоверным входным данным.

4. Предложить и обосновать кооперативную нейросетевую архитектуру, объединяющую несколько частных моделей, для повышения точности классификации и устойчивости решений.

5. Оценить эффективность применения сигмоидальных функций активации в логических нейронах для сглаживания жёстких переходов и повышения способности моделей к обобщению.

6. Провести теоретическое и экспериментальное обоснование предложенных решений, продемонстрировав их применимость в системах технического зрения, работающих в сложных технических условиях.

С математической точки зрения синтез нейронной сети рассматривается как решение некоторой оптимизационной задачи – поиска такого состояния сети, в котором минимизируется некая функция ошибки  $\varepsilon$ , вычисляемая на основании имеющегося в распоряжении исследователя множества данных (обучающей выборки), которую можно представить в виде [3], [4]:

$$\varepsilon = \sum_{j=1}^k (\Omega_j(W^t, z^j) - y^j)^2$$

где  $W$  – состояние сети (все весовые коэффициенты всех нейронов, входящих в сеть);  $W_t$  – текущее состояние сети;  $\Omega: z \Rightarrow y$  – отображение, реализуемое нейронной сетью;  $k$  – количество примеров в обучающей выборке;  $y_j$  – требуемое значение выхода для  $j$ -го примера;  $z_j$  – входной вектор для  $j$ -го примера.

Обучение искусственной нейронной сети (ИНС) — это процесс минимизации ошибки  $\varepsilon$  между прогнозируемыми и реальными значениями на обучающей выборке. Обычно используется метод градиентного спуска (например, обратное распространение ошибки), который стремится к минимуму функции ошибки, но часто находит лишь локальные минимумы. Основные проблемы обучения связаны с ограниченностью и нерепрезентативностью данных, особенно при малом объеме выборки, а также с ограничениями самих алгоритмов оптимизации. Кроме того, на качество модели влияет выбор архитектуры сети — числа слоёв, нейронов и их связей. Несмотря на теоретические доказательства аппроксимационных возможностей нейросетей, эти результаты не дают практических методов построения оптимальной архитектуры. На практике разработчику приходится самостоятельно определять:

1. оптимальную топологию сети — как именно будут соединены нейроны;
2. необходимое количество нейронов и их распределение по слоям;
3. выбор функций активации для каждого слоя;
4. подтвердить эффективность и работоспособность полученной архитектуры экспериментально.

Хотя выбор функции активации и оценка качества обучения решаются стандартными методами, проектирование структуры ИНС требует опыта и интуиции, что усложняет процесс. Метод фрактальной структуры (ФФС) предлагает формализованный и быстрый способ синтеза нейросетей с логической интерпретацией и минимальной ошибкой обучения. Однако такие сети могут быть недостаточно гибкими при классификации объектов, находящихся на границах классов, поскольку грубо аппроксимируют сложные границы в пространстве признаков.

Для устранения данного недостатка автором была предложена концепция кооперативной нейросетевой структуры [9]. Согласно этой концепции, несколько ИНС, построенных по методу ФФС, объединяются в единую систему. Каждая отдельная сеть вносит свой вклад в общее решение о принадлежности объекта к заданному классу. Итоговое решение формируется на основе агрегации частных решений с использованием специального нейрона, реализующего функцию объединения. Подобный подход позволяет значительно повысить точность и устойчивость классификации, особенно в условиях недостатка обучающих данных. Он также открывает возможности для параллельной обработки информации и повышения надёжности системы в целом. Однако, несмотря на достигнутые успехи, остаются ситуации, в которых и кооперативная структура оказывается недостаточно точной, особенно при наличии сложных, изрезанных границ между классами. Это подчёркивает необходимость в дальнейшем совершенствовании предложенных методов и их практической верификации. В связи с этим главной задачей настоящего исследования является развитие существующих методов синтеза ИНС с целью повышения их обобщающей способности и устойчивости к различным видам неопределённости.

$$L(x_i) = \gamma(x_i) * \varphi(x_i) + \overline{\gamma(x_i)} * \psi(x_i)$$

где  $x_i$  – входной вектор,  $\gamma$  – результат нейрона первого типа,  $\varphi$  и  $\psi$  – функции ошибок.

При разработке нейронных сетей для задач классификации и логического вывода ключевую роль играют архитектура сети и тип нейронов. Один из подходов предусматривает использование в первом слое нейронов с пороговой функцией активации, реагирующих только при превышении взвешенной суммы входов заданного порога, что позволяет реализовывать простейшие логические условия. В последующих слоях применяются логические нейроны, моделирующие базовые операции "И", "ИЛИ" и "НЕ" через взвешенное суммирование входов и последующее применение пороговой функции, что обеспечивает формализацию логических процессов внутри нейросетевой структуры.

Для лучшего понимания логической природы нейронов можно представить структуру нейросети, реализующей элементарные логические функции, в виде схемы, где:

- два нейрона реализуют функцию логического "И": они активируются только в случае, когда оба входа принимают значение 1;
- один нейрон реализует логическую операцию "ИЛИ": он активируется, если хотя бы один из входов равен 1;
- и ещё один нейрон моделирует логическую операцию "НЕ", инвертируя значение поступающего сигнала.

Такая модульная структура позволяет представить более сложные логические выражения, комбинируя вышеуказанные нейроны в различных конфигурациях. При этом каждая логическая операция легко формализуется через выбор соответствующих весов и порога активации. Например, чтобы реализовать операцию "И" с использованием пороговой функции активации, можно задать веса входов равными 0.5, а порог — 1. В этом случае, только когда оба входа равны 1, сумма весов достигнет порога и нейрон активируется. Подобный подход позволяет не только моделировать логические структуры в рамках нейронных сетей, но и обеспечивает высокий уровень интерпретируемости решений сети. Это особенно ценно в условиях, когда требуется объяснимость результатов, таких как в системах поддержки принятия решений или в экспертных интеллектуальных системах. Таким образом, использование логических нейронов и пороговых функций активации в архитектуре нейросети открывает широкие возможности для построения гибких, интерпретируемых и эффективно обучаемых моделей, особенно в задачах, связанных с логическим выводом, бинарной классификацией и анализом дискретных признаков.

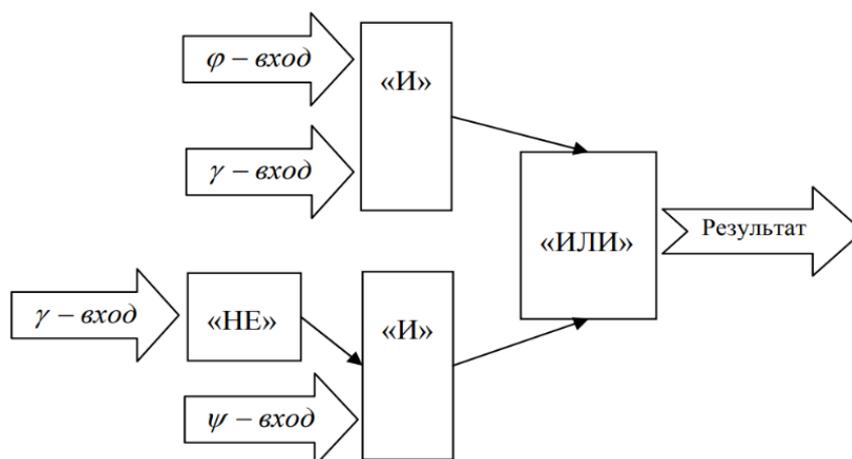


Рисунок 1 - Представление логического нейрона в виде сети с нейронами, реализующими элементарные логические операции

Рассмотрим способы реализации элементарных логических операций, используя в качестве активационной функции нейрона пороговую функцию  $\Phi(x)$  - функцию Хевисайда:

$$\Phi(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

Представимость логической операции «И» для двух входов в нейросетевом базисе сводится к существованию коэффициентов  $w_i$  таких, что выполняется неравенство:

$$w_1 \gamma + w_2 \varphi + w_0 \geq 0$$

При проектировании логических нейронов, реализующих элементарные булевы операции, особое внимание уделяется подбору весовых коэффициентов и порогового значения функции активации. Для операций "И" и "ИЛИ" существует бесконечное множество возможных комбинаций весов и порогов, которые позволяют воспроизвести их логическое поведение в рамках нейросетевой модели. Однако, для простоты и наглядности анализа можно использовать конкретные, типовые значения.

Рассмотрим логическую операцию "И" (конъюнкцию). Для реализации этой функции можно задать следующие значения весов:  $w_0 = -1$  (свободный член или смещение),  $w_1 = 0.5$ ,  $w_2 = 0.5$ . Здесь переменные  $\gamma$  и  $\phi$  обозначают входные сигналы, принимающие значения 0 или 1. Суммируя взвешенные входы и прибавляя смещение, получаем выражение:

$$\Phi(x) = \Phi(w_0 + w_1 * \gamma + w_2 * \phi) = \Phi(-1 + 0.5 * \gamma + 0.5 * \phi)$$

Пороговая функция активации  $\Phi(x)$ , например функция Хевисайда, принимает значение 1, если аргумент  $\geq 0$ , и 0 в противном случае. Проверим значения на истинность логической функции "И":

$$\text{Если } \gamma = 0 \text{ и } \phi = 0 \rightarrow \Phi(-1) = 0$$

$$\text{Если } \gamma = 1 \text{ и } \phi = 0 \rightarrow \Phi(-0.5) = 0$$

$$\text{Если } \gamma = 0 \text{ и } \phi = 1 \rightarrow \Phi(-0.5) = 0$$

$$\text{Если } \gamma = 1 \text{ и } \phi = 1 \rightarrow \Phi(0) = 1$$

Таким образом, выход нейрона соответствует таблице истинности операции "И". Аналогично можно сконструировать нейрон, реализующий операцию "ИЛИ" (дизъюнкцию). Для этого зададим веса:  $w_0 = -1$ ,  $w_1 = 1$ ,  $w_2 = 1$ . Подставляя их в выражение функции активации, получим:

$$\Phi(x) = \Phi(-1 + 1 * \gamma + 1 * \phi)$$

Проверим значения:

$$\gamma = 0, \phi = 0 \rightarrow \Phi(-1) = 0$$

$$\gamma = 1, \phi = 0 \rightarrow \Phi(0) = 1$$

$$\gamma = 0, \phi = 1 \rightarrow \Phi(0) = 1$$

$$\gamma = 1, \phi = 1 \rightarrow \Phi(1) = 1$$

Результаты совпадают с истинностной таблицей логической дизъюнкции, что подтверждает корректность выбранных коэффициентов. Следует отметить, что выбор конкретных значений весов не является единственно возможным. Например, при увеличении всех коэффициентов и порога в одинаковое число раз логическая функция сохранится. Это свойство связано с тем, что пороговая функция активации чувствительна лишь к знаку суммарного аргумента, а не к его абсолютной величине.

Такая реализация логических функций с использованием простейших нейронов и пороговой активации даёт возможность интеграции булевой логики в состав нейросетевых моделей. Это особенно полезно при решении задач, требующих формализованной логической обработки информации, а также при построении объяснимых ИНС, где прозрачность внутренних процессов играет ключевую роль.

Для логической операции «НЕ» выражение записывается в виде:

$$w_1 \gamma \geq 0.$$

Реализация логической операции "НЕ" (инверсия) в рамках нейронной сети с использованием пороговой функции активации также представляется достаточно простой и наглядной. Для этого используется однослойный нейрон с одним входом. Основной задачей в данном случае является подбор такого весового коэффициента и значения смещения (порога), которые позволят инвертировать входной сигнал, принимающий значения из множества  $\{0, 1\}$ . Обобщая вышеизложенное, можно записать функцию логического нейрона в нейросетевом базисе:

$$y = \Phi \left[ \Phi \left( \frac{\gamma}{2} + \frac{\phi}{2} - 1 \right) + \Phi \left( \frac{\Phi(-y)}{2} + \frac{\psi}{2} - 1 \right) - 1 \right].$$

Концепция логического нейрона может быть реализована с помощью нейросетей через взвешенное суммирование входов и пороговую функцию активации, например, функцию Хевисайда. Однако такие жёсткие функции плохо работают при наличии шумов и неопределённостей во входных данных, что приводит к ошибкам классификации. Более гибкой альтернативой является сигмоидальная функция активации, обеспечивающая плавное разделение классов и интерпретацию выхода как вероятности. Она лучше справляется с зашумлёнными данными, способствует устойчивому обучению благодаря непрерывной производной и повышает обобщающую способность модели — особенно важную в задачах классификации. В качестве такой функции целесообразно использовать сигмоид, т.е. функцию вида:

$$f(x) = \frac{1}{1 + e^{-bx}},$$

принимающую значения в диапазоне от 0 до 1, график которой показан на рис. 2 для различных значений коэффициента  $b$ . Коэффициент  $b$  определяет, насколько быстро и на каком интервале функция изменяет значение от 0 до 1, и в случае  $b \rightarrow \infty$  функцию (можно рассматривать как пороговую функцию). Таким образом, используя коэффициент  $b$ , можно управлять свойствами синтезируемой нейросетевой структуры.

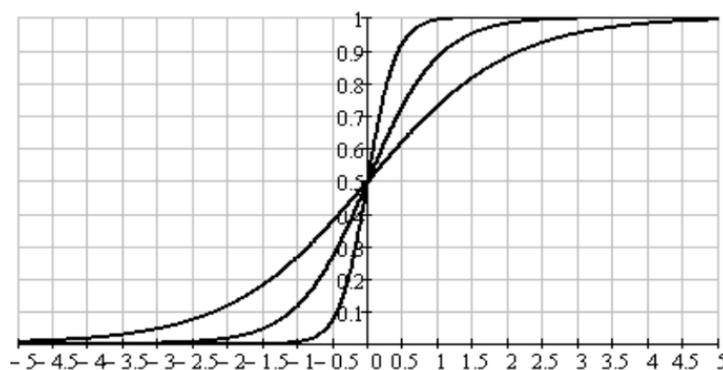


Рисунок 2 - График функции сигмоида для различных значений коэффициента  $b$

## Заключение

На основании изложенного в работе материала, можно утверждать, что для описанного класса задач:

1. Замена пороговой активационной функции каждого входящего в сеть нейрона на сигмоидальную функцию позволяет улучшить качество классификации образов, особенно для случаев, когда они находятся близко к границе областей, занимаемых различными классами.

2. Показана возможность представления используемых в структуре сети специальных логических нейронов в нейросетевом базисе – операцией взвешенного суммирования и нелинейного преобразования результата, что доказывает эквивалентность синтезируемых структур классическим нейронным сетям.

3. Предложенный метод дополняет ранее изложенные в работах [7-9] методы синтеза нейронных сетей и позволяет на данной основе формализовать получение нейросетевых структур для решения задач классификации.

Проведённое исследование продемонстрировало высокую актуальность и важность разработки методов повышения точности классификации в системах технического зрения, ориентированных на работу в ограниченных и структурно сложных

пространствах. В частности, показана практическая ценность применения искусственных нейронных сетей (ИНС) в задачах, где классические методы синтеза моделей сталкиваются с фундаментальными ограничениями — как теоретическими, так и практическими.

## Список литературы

1. *Справочник по теории автоматического управления* [Текст] / А. Г. Александров, В. М. Артемьев, В. Н. Афанасьев и др.; под ред. А. А. Красовского. М.: Наука, 1987. 712 с. 2. Методы классической и современной теории автоматического управления [Текст].
2. *Статистическая динамика и идентификация систем автоматического управления: учеб.* / К. А. Пупков, Н. Д. Егупов, Е. М. Воронов и др.; под ред. К. А. Пупкова, Н. Д. Егупова. 2-е изд., перераб. и доп. М.: Издательство МГТУ им. Н. Э. Баумана, 2004. 640 с.
3. *Методы классической и современной теории автоматического управления* [Текст]. Т. 5. Методы современной теории автоматического управления: учеб. / К. А. Пупков, Н. Д. Егупов, А. И. Баркин и др.; под ред. К. А. Пупкова, Н. Д. Егупова. 2-е изд., перераб. и доп. М.: Издательство МГТУ им. Н. Э. Баумана, 2004. 784 с.
4. *Методы робастного, нейро-нечеткого и адаптивного управления* [Текст]: учеб. / К. А. Пупков, Н. Д. Егупов, А. И. Гаврилов и др.; под ред. Н. Д. Егупова; изд. 2-ое, стереотипное. М.: Издательство МГТУ им. Н.Э. Баумана, 2002. 744 с.
5. Колмогоров, А. Н. *О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного и сложения Докл. АН СССР.* 1957. Т. 114, №5. С. 953—956.
6. Hecht-Nielsen R. Kolmogorov's Mapping Neural Network Existence Theorem. *IEEE First Annual Int. Conf. on Neural Networks.* 1987. Vol.3.P. 11—13.
7. Юрков, Д. А. Метод синтеза нейросетевых модельных структур. *Вісн. Східноукр. нац. ун-ту.* 2009. № 5 (135). С. 115—122.
8. Юрков, Д. А. Синтез нейронных сетей с фрактальной структурой. *Восточно-Европейский журнал передовых технологий.* 2009. № 4-3 (40). С. 39—44.
9. Юрков, Д. А. Классификация на основе кооперативных нейросетевых структур. *Восточно-Европейский журнал передовых технологий.* 2009. №5-3 (41). С. 51—56.
10. Сивак, М. А. Исследование применимости робастных функций потерь в нейронных сетях. *Сборник научных трудов НГТУ.* 2020. № 4. С. 50—58.
11. Сивак, М. А. Оптимизация работы робастной нейронной сети для задачи классификации [Текст] / М. А. Сивак, В. С. Тимофеев. *Наука. Технологии. Инновации: сб. науч. тр.:* в 9 ч., Новосибирск, 30 нояб. 4 дек. 2020 г. Ч. 2. Изд-во НГТУ, 2020. С. 298—300.
12. Fujimoto, S. *An Equivalence between Loss Functions and Non-Uniform Sampling in Experience Replay* / S. Fujimoto, D. Meger, D. Precup. 2020. URL: <https://inlnk.ru/poZ0mB>.
13. Сивак, М. А. Классификация зашумленных данных при различных объемах выборки [Текст] / М. А. Сивак. *Наука. Технологии. Инновации: сб. науч. тр.:* в 9 ч., Новосибирск, 6–10 дек. 2021 г. Ч. 2. Изд-во НГТУ, 2021. С. 277—279.
14. Сивак, М. А. Настройка робастных нейронных сетей для решения задачи классификации [Текст] / М. А. Сивак, В. С. Тимофеев. *Доклады Томского государственного университета систем управления и радиоэлектроники.* 2021. Т. 24, № 3. С. 26—32.
15. Сивак, М. А. Построение робастных нейронных сетей с различными функциями потерь [Текст] / М. А. Сивак, В. С. Тимофеев. *Системы анализа и обработки данных.* 2021. Т. 82, № 2. С. 67—83.
16. Тимофеев, В. С. Робастная нейронная сеть с простой архитектурой [Текст] / В. С. Тимофеев, М. А. Сивак // *Сибирский журнал индустриальной математики.* 2021. Т. 24, № 4. С. 126—138.
17. Yukang Chen, Yanwei Li, Tao Kong, Lu Qi, Ruihang Chu, Lei Li, Jiaya Jia. Scale-aware Automatic Augmentation for Object Detection // *CVPR.* 2021. P. 9563-9572.
18. Rowel Atienza. Data Augmentation for Scene Text Recognition // *ICCVW.* 2021. P. 1561-1570.
19. Zhun Zhong, Liang Zheng, Guoliang Kang, Shaozi Li, Yi Yang. Random Erasing Data Augmentation // *AAAI.* 2020. P. 13001-13008.
20. Иванов Д. А., Турута Д. В. Применение методов аугментации данных для повышения точности классификации изображений. *Искусственный интеллект и принятие решений.* 2022. № 3. С. 45—56.
21. Talukdar S, Mahato S, Shahfahad Pal S, Liou YA, Rahman A. *Land-use land-cover classification by machine learning classifiers for satellite observations—A review.* *Remote Sens* 2020; 12(7): 1135. DOI: 10.3390/rs12071135.

## References

1. Handbook of the theory of automatic control [Text] / A. G. Alexandrov, V. M. Artemyev, V. N. Afanasyev and others; edited by A. A. Krasovsky. — M.: Nauka, 1987. — 712 p. 2. Methods of classical and modern theory of automatic control [Text]. Vol
2. Statistical dynamics and identification of automatic control systems: textbook / K. A. Pupkov, N. D. Egupov, E. M. Voronov et al.; edited by K. A. Pupkov, N. D. Egupov. — 2nd ed., revised and additional — M.: Publishing House of the Bauman Moscow State Technical University, 2004. — 640 p.
3. Methods of classical and modern theory of automatic control [Text]. Vol. 5. Methods of modern theory of automatic control: textbook / K. A. Pupkov, N. D. Egupov, A. I. Barkin et al.; edited by K. A. Pupkov, N. D. Egupov. — 2nd ed., revised and additional — M.: Publishing House of the Bauman Moscow State Technical University, 2004. 784 p.
4. Methods of robust, neuro-fuzzy and adaptive control [Text]: textbook / K. A. Pupkov, N. D. Egupov, A. I. Gavrilov et al.; edited by N. D. Egupov; ed. 2nd, stereotypical. Moscow: Publishing House of the Bauman Moscow State Technical University, 2002. 744 p.
5. Kolmogorov, A. N. On the representation of continuous functions of several variables in the form of a superposition of continuous functions of one variable and addition [Text] / A. N. Kolmogorov // Dokl. USSR Academy of Sciences. 1957. Vol. 114, No. 5. pp. 953-956.
6. Hecht-Nielsen R. Kolmogorov's mapping neural network theorem [Text] // IEEE standards first Annual Int. Conference on Neural Networks. — 1987. — Volume 3. — pp. 11-13.
7. Yurkov, D. A. Method of synthesis of neural network model structures [Text] / D. A. Yurkov // Visn. Skydnoukr. national un-tu. — 2009. — № 5 (135). — Pp. 115-122.
8. Yurkov, D. A. Synthesis of neural networks with fractal structure [Text] / D. A. Yurkov // East European Journal of Advanced Technologies. — 2009. — № 4-3 (40). — Pp. 39-44.
9. Yurkov, D. A. Classification based on cooperative neural network structures [Text] / D. A. Yurkov // East European Journal of Advanced Technologies. — 2009. — №5-3 (41). — Pp. 51-56.
10. Sivak, M. A. A study of the applicability of robust loss functions in neural networks [Text] / M. A. Sivak // Collection of scientific papers of NSTU. - 2020. — No. 4. — pp. 50-58.
11. Sivak, M. A. Optimization of the operation of a robust neural network for the classification problem [Text] / M. A. Sivak, V. S. Timofeev // Science. Technologies. Innovations: collection of scientific papers: at 9 a.m., Novosibirsk, November 30 - December 4, 2020, Part 2. NSTU Publishing House, 2020. pp. 298-300.
12. Gudzimo, S. Dynamically developing search process [Text] / S. Gudzimo, D. Meger, J. Purchase. — 2020. — URL: <https://inlnk.ru/poZ0mB>.
13. Sivak, M. A. Classification of noisy data with different sample sizes [Text] / M. A. Sivak // Science. Technologies. Innovations: collection of scientific papers: at 9 a.m., Novosibirsk, December 6-10, 2021, Part 2. — NSTU Publishing House, 2021. — pp. 277-279.
14. Sivak, M. A. Setting up robust neural networks to solve the classification problem [Text] / M. A. Sivak, V. S. Timofeev // Reports of Tomsk State University of Control Systems and Radio Electronics. — 2021. — Vol. 24, No. 3. — pp. 26-32.
15. Sivak, M. A. Construction of robust neural networks with various loss functions [Text] / M. A. Sivak, V. S. Timofeev // Data analysis and processing systems. — 2021. — Vol. 82, No. 2. — pp. 67-83.
16. Timofeev, V. S. Robust neural network with simple architecture [Text] / V. S. Timofeev, M. A. Sivak // Siberian Journal of Industrial Mathematics. — 2021. — Vol. 24, No. 4. — pp. 126-138.
17. Yukang Chen, Yanwei Li, Tao Kong, Lu Qi, Ruihang Chu, Lei Li, Jiayaya Jia. Mathematical exhortation based on user needs // CVPR. 2021. pp. 9563-9572.
18. Rowel Atienza. Fascination with the volume of data for understanding the text of a book // ICCVW. 2021. pp. 1561-1570.
19. Zhong Zhong, Liang Zheng, Guoliang Kang, Shaozi Li, Yi Yang. Fascination with the volume of data under random circumstances // AAAI. 2020. pp. 13001-13008.
20. Ivanov D. A., Turuta D. V. Application of data augmentation methods to improve the accuracy of image classification // Artificial intelligence and decision—making. - 2022. — No. 3. — pp. 45-56.
21. Talukdar S., Mahato S., Shahfahad Pal S., Liu Ya., Rahman A. Classification of vegetation cover in the field of land use using machine learning classifiers for satellite observations - an overview. Updated Sens 2020; 12(7):1135. DOI: 10.3390/rs12071135.

## RESUME

*M. A. Naumov, A. Y. Karpovsky*

*Methods for improving the accuracy of object classification when building a vision system for exploring confined spaces*

In this paper, methods for improving the accuracy of object classification in vision systems operating in conditions of limited space and incomplete source data are proposed and substantiated. Special attention is paid to the synthesis of neural network models based on logical neurons and flexible activation functions, in particular, sigmoids, which made it possible to ensure adaptability and stability of classification in noisy conditions. The development of the concept of fractal and cooperative neural network architecture made it possible to combine private solutions into a single system, which improved the interpretability and accuracy of the model. The practical significance of the proposed approaches is to expand the applicability of neural network structures to the tasks of intelligent analysis and management in complex technical systems. The obtained results create prerequisites for further research in the field of developing explicable and reliable ANNs for use in real-time systems.

## РЕЗЮМЕ

*М.А. Наумов, А.Ю. Карповский*

*Методы повышения точности классификации объектов при построении системы зрения для исследования ограниченных пространств*

В данной работе предложены и обоснованы методы повышения точности классификации объектов в системах технического зрения, функционирующих в условиях ограниченного пространства и неполноты исходных данных. Особое внимание уделено синтезу нейросетевых моделей на основе логических нейронов и гибких активационных функций, в частности, сигмоиды, что позволило обеспечить адаптивность и устойчивость классификации в зашумлённых условиях. Развитие концепции фрактальной и кооперативной нейросетевой архитектуры позволило объединить частные решения в единую систему, что улучшило интерпретируемость и точность модели. Практическая значимость предложенных подходов заключается в расширении применимости нейросетевых структур к задачам интеллектуального анализа и управления в сложных технических системах. Полученные результаты создают предпосылки для дальнейших исследований в области разработки объяснимых и надёжных ИНС для применения в системах реального времени.

**Наумов Максим Александрович** – младший научный сотрудник отдела автоматизации горных машин, Государственное бюджетное учреждение «Научно-исследовательский и проектно-конструкторский институт по автоматизации горных машин «Автоматгормаш им. В.А. Антипова», г. Донецк. *Область научных интересов:* системы автоматического управления и машинное зрение, эл. почта [maksim-naumov-99@bk.ru](mailto:maksim-naumov-99@bk.ru), адрес 283003, г. Донецк, пр. Ильича, дом 93, телефон +7949 318-32-79.

**Карповский Артур Юрьевич** – заведующий отделом автоматизации горных машин, Государственное бюджетное учреждение «Научно-исследовательский и проектно-конструкторский институт по автоматизации горных машин «Автоматгормаш им. В.А. Антипова», г. Донецк. *Область научных интересов:* приборостроение и радиоэлектроника, эл. почта [oagm308@mail.ru](mailto:oagm308@mail.ru), адрес 283003, г. Донецк, пр. Ильича, дом 93, телефон +7949 336-05-66.

Статья поступила в редакцию 20.03.2025.