

УДК 004.8

DOI:10.25729/ESI.2025.39.3.002

Нейро-нечеткая система классификации состояний объектов сложной структуры

Ломакина Любовь Сергеевна, Чернобаев Игорь Дмитриевич, Беляева Любовь Андреевна

Нижегородский государственный технический университет им. Р. Е. Алексеева,
Россия, Нижний Новгород, ichernobnn@gmail.com

Аннотация. В работе рассматривается задача машинного обучения по классификации состояний объектов со сложной структурой. Под состоянием объекта понимается некоторая категория, характеризующая свойства объекта в момент времени, и при этом описываемая набором признаков. Сложность структуры объекта выражается в присутствии в признаковом описании характеристик, которые требуют предварительной специализированной обработки и обладают отношениями иерархии или характеризуются наличием последовательностей неструктурированных элементов. Данные для классификации могут содержать неточности, погрешности и ошибки. Инструмент нейросетевого моделирования часто применяется при решении задач классификации. Для решения задачи классификации в условиях нечеткости применяются нечеткие логические системы. Оба инструмента обладают свойствами универсального аппроксиматора, однако результаты нейросетевых моделей трудно интерпретировать, а для построения нечеткой логической системы требуется участие эксперта при описании нечетких правил. В работе рассматривается подход к объединению инструментов нечетких логических систем и инструментов нейросетевого моделирования, выраженный в построении модели нечеткой функции активации нейрона. Модель нечеткой функции описывается с применением аппарата теории нечетких множеств и функций принадлежности, объединенных правилами активации в НЛС. Информационный сигнал на входе нечеткой функции проходит несколько этапов преобразований, включающих преобразование сигнала «домен» нечетких множеств, совокупную обработку нечетких множеств в соответствии с заданными в системе правилами, алгоритмами отображения обработанного информационного сигнала обратно в домен четких чисел. Рассматриваемый подход позволяет формировать нечеткую функцию активации набором параметров, изменяемых в процессе обучения нейросетевой модели. В работе показано, что рассматриваемая модель нечеткой функции имеет ограниченную область определения. Для обеспечения выполнимости требований к информационному сигналу в модели нечеткой функции предложена улучшенная нормализация входа нечеткой функции активации. Нейро-нечеткие системы классификации проанализированы в задачах классификации технических объектов, медико-биологических объектов, текстовых объектов. Сравнительная оценка точности решений нейро-нечетких систем классификации относительно аналогичных систем на основе ИНС показала повышение от 2 до 9 % в ряде экспериментов.

Ключевые слова: классификация состояний объектов, нечеткая логическая система, нейронная сеть, нейро-нечеткая классификация

Цитирование: Ломакина Л.С. Нейро-нечеткая система классификации состояний объектов сложной структуры / Л.С. Ломакина, И.Д. Чернобаев, Л.А. Беляева // Информационные и математические технологии в науке и управлении, 2025. – № 3 (39). – С.17-25. – DOI:10.25729/ESI.2025.39.3.002.

Введение. Машинное обучение – раздел искусственного интеллекта, в котором исследуются и разрабатываются модели и алгоритмы для автоматизированной и, прежде всего, интеллектуальной обработки данных, выявления скрытых закономерностей, и принятия решения в соответствии с поставленной задачей. В машинном обучении выделяют такие фундаментальные типы задач, как регрессия, кластеризация, классификация. Регрессия решает задачу прогнозирования значения целевой функции на основе уже известных значений. При решении задачи кластеризации из исходного множества объектов выделяются новые подмножества, при этом такие подмножества формируются на основании близости характеристик признакового описания объектов одного подмножества. В задаче классификации определяется принадлежность объекта к заданной категории в результате обработки его признакового описания. Приведенные базовые типы задач машинного обучения

являются основой, на которой формулируют такие задачи, как: распознавание образов, идентификация, генерация данных, отслеживание объектов в реальном времени, обработка потоковых данных и другие. Так, существует перечень задач, в которых анализируется состояние объектов сложной структуры. В подобных задачах состояние объекта рассматривается как категория, характеризующая его работоспособность, режим работы или степень износа. При этом, рассматриваемые объекты, как правило, являются системами – техническими, медико-биологическими, программными, и обладают сложной структурой. Сложность структуры объекта выражается через его признаковые описания: наличие последовательностей, отношения иерархии, присутствие полуструктурированных элементов. К таким объектам относят текстовые данные, компьютерные изображения, потоковые данные, данные технических систем и др., при этом такие объекты требуют предварительной обработки. Также, в машинном обучении выделяют категорию задач, решающих вопросы обработки данных с учетом погрешностей, неточностей ошибок. В этой связи в задачах классификации и кластеризации границы между категориями «размываются» и вместо однозначного ответа на вопрос о принадлежности объекта к категории рассматривается уже вопрос о степени принадлежности. На практике источниками таких данных могут быть измерительные приборы, у которых подходит к концу срок сертификации – значения измерений таких приборов могут быть с погрешностями. Другим источником может быть человеческий фактор или неполнота сведений. В качестве примеров можно выделить задачи технической и медицинской диагностики.

Проблемы применения ИНС. Инструмент нейросетевого моделирования часто применяется для решения задач машинного обучения благодаря универсальности искусственных нейронных сетей (ИНС) и способности обобщать новые данные, отсутствующие в обучающем наборе данных. ИНС обладают свойствами универсального аппроксиматора [1] и обеспечивают высокую точность решений в прикладных задачах, а структура любой нейросетевой модели позволяет ускорить процесс обучения и принятия решений за счет организации распределенной обработки данных. Однако, решения ИНС сложно интерпретировать [2]. Без понимания процесса принятия решения нейросетевой моделью по-прежнему остается невозможным их применение в прикладных областях, где критически важна точность и надежность используемых моделей. Ввиду того, что для работы нейросетевых моделей необходимо их предварительное обучение на обучающей выборке, точность решений и обобщающая способность напрямую зависят от качества обучающей выборки, следовательно, неточные и неполные данные и погрешности в данных снижают точность решения задачи методом нейросетевого моделирования.

Нечеткие множества второго типа. Для работы с подобными данными применяют теорию нечетких множеств (НМ), разработанную Л. Заде [3] и предлагающую методы описания и обработки неопределенности в данных с использованием специальных функций, определяющих меру принадлежности объекта к множествам с «размытыми» границами [4].

На рисунке 1 «размытость» классов «Горячо» и «Холодно» выражена в постепенном переходе между двумя нечеткими множествами «Горячо» и «Холодно».

Сегодня интерес представляют нечеткие множества второго типа (Т2-НМ) [5], которые расширяют НМ первого типа через замещение фиксированной функции принадлежности на нечеткую таким образом, что степень принадлежности каждого элемента Т2-НМ представляет собой НМ первого типа в диапазоне [0,1]. Характеристические функции Т2-НМ имеют трехмерную структуру, а ключевой особенностью этих множеств является «след неопределенности», формируемый двумя функциями принадлежности сверху и снизу, и представленный на рисунке 2. Т2-НМ можно рассматривать как совокупность Т1-НМ [6].




Рис. 1. Функции принадлежности нечетких множеств: «Горячо» и «Холодно»




Рис. 2. След неопределенности нечетких множеств 2-го типа: «Горячо» и «Холодно»

Применение НМ и НЛС. НМ применяются в составе нечеткой логической системы (НЛС). Известно, что НЛС способна аппроксимировать любую непрерывную функцию в заданной области [7]. Принцип работы НЛС построен на совокупной обработке НМ в соответствии с заданными правилами. Решения НЛС – интерпретируемые, но построение подобных систем требует применения экспертных знаний прикладной области при составлении базы правил.

В структуре НЛС (рис. 3) присутствуют следующие этапы преобразования ввода функции:

1. Сигнал, передаваемый на вход системы на этапе фаззификации, преобразуется в T2-НМ и передается на обработку в базу нечетких правил. База правил НЛС имеет структуру:

R_{ix} : ЕСЛИ ВВОД x ПРИНАДЛЕЖИТ A_{ix} , ТО СЛЕДСТВИЕ f ПРИНАДЛЕЖИТ B_{ix} , где – ix – индекс нечеткого правила, x – ввод НЛС, A_{ix} – нечеткие множества, B_{ix} – вывод НЛС

2. В базе определяются правила, соответствующие вводу. Следствия активированных правил образуют вывод НЛС – агрегированное нечеткое множество.

3. Полученное НМ преобразуется в «четкий» вывод на этапе дефаззификации, который включает алгоритм сокращения типа для перевода T2-НМ в T1-НМ и алгоритм отображения T1-НМ в вывод НЛС.




Рис. 3. Структура НЛС второго типа

В работе рассматривается НЛС, включающая Т2-НМ и базу нечетких правил, представленных на рисунках 4 и 5:




Рис. 4. Графическое представление Т2-НМ рассматриваемой базы правил




Рис. 5. Графическое представление следствий рассматриваемой базы правил

Известно, что симметричные НМ обеспечивают устойчивость НЛС [8], в связи с этим в рассматриваемой НЛС применяются симметричные треугольные функции принадлежности (ФП) – верхние $\bar{\mu}_{\tilde{A}_i}$ и нижние $\underline{\mu}_{\tilde{A}_i}$:

$$\bar{\mu}_{\tilde{A}_i} = \begin{cases} \frac{\sigma - c_{i+1}}{c_i - c_{i+1}}, \sigma \in [c_i, c_{i+1}) \\ \frac{c_{i-1} - \sigma}{c_{i-1} - c_i}, \sigma \in [c_{i-1}, c_i) \end{cases} \quad (1)$$

$$\underline{\mu}_{\tilde{A}_i} = h_i * \bar{\mu}_{\tilde{A}_i} \quad (2)$$

где $c_1 = -1$, $c_2 = 0$, $c_3 = 1$, $h_1 = h_3 = 1 - a$, $h_2 = a$, $a \in (0, 1)$. Из выражения нижней функции принадлежности следует, что параметры h_i рассматриваемой НЛС определяют форму следа неопределенности. Как показано на рисунке 4, ФП заданы в диапазоне $\sigma \in [-1, 1]$. Формирование нижних ФП выполняется путем изменения параметра h , выраженным через параметр a . Значения $a \in \{0, 1\}$, приводят к вырождению Т2-НМ в Т1-НМ. Данный метод прототипирования НЛС, представлен в [9], отличается простотой и наглядностью структуры системы нечеткой логики.

Модель нечеткой функции активации. В работе для построения системы классификации состояний объектов сложной структуры с учетом нечеткости в данных рассматривается объединение [10] НЛС и ИНС. Модель нечеткой функции активации (НФА) нейрона описывается через НЛС с применением Т2-НМ и ФП, объединенных правилами активации. Такой подход позволяет использовать различные типы НМ и алгоритмы дефаззификации [11]. В результате выполнения этапа сокращения типа НМ и дефаззификации, модель НФА можно формализовать в виде:

$$F(x) = \begin{cases} P x k(x), & x \in (0; 1] \\ N x k(-x), & x \in [-1; 0] \end{cases} \quad (3)$$

где $k(x) = 0.5(\frac{1}{a+x-ax} + \frac{1-a}{1-ax})$, параметры P, N, a обновляются в соответствии с правилом обучения ИНС.

Параметры НФА предоставляют возможность гибкой настройки функции нелинейного отображения входных данных и позволяют получать функции, близкие к базовым функциям активации ИНС, таким, как $ReLU(x) = \max(0, x)$, $\text{sigmoid}(x) = \frac{1}{e^{-x} + 1}$ и др.

Полученная функция представлена на рисунке 6, и может применяться при построении ИНС в качестве НФА, при этом вместо весовых коэффициентов модели нейрона применяются только параметры НФА.

На рисунке 6 показано, что величина и направление изгиба кривой в положительной и отрицательной областях зависят от знака и значения параметра a . При значениях параметра a ,

близких к 0.5, рассматриваемая функция вырождается в кусочно-заданную линейную функцию.




Рис. 6. График нечеткой функции активации с параметрами $N = 1.0$, $P = 1.0$ и различными вариантами параметра α

В процессе обучения ИНС с НФА значения параметра $\alpha \in (0; 1)$ могут выйти за границы допустимого диапазона, обусловленного выражением (2). При значениях $\alpha = 0$ или $\alpha = 1$ Т2-НМ вырождаются в Т1-НМ, это приводит к сокращению типа НЛС, и НФА становится недифференцируемой [10]. В результате теряется одно из ключевых преимуществ модели, а именно, сокращается количество Т1-НМ, входящих в состав Т2-НМ, улучшенная обработка неопределенности в данных.

Для предотвращения этой проблемы предлагается расширение НФА дополнительным этапом нормализации [11], который ограничит значения параметра α в пределах $(0,1)$ и обеспечит стабильность обучения и сохранение преимуществ нечетких множеств второго типа в архитектуре нейронной сети. В работе рассматривается нормализация с применением функции гиперболического тангенса: $\tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}$, однако допустимо любое преобразование ввода, при условии, что будут соблюдаться ограничения области определения НФА. Структура НФА с добавленным шагом нормализации входа приведена на рисунке 7:




Рис. 7. НФА с нормализацией входа

Нейро-нечеткая система классификации. Системы классификации, построенные на объединении ИНС и НФА, являются альтернативой системам классификации на базе обыкновенных нейросетевых моделей. При построении нейро-нечетких систем классификации в структуре ИНС применяются слои нейронов с НФА [12]. Например, для построения многослойной нейро-нечеткой сети (МННС) прямого распространения на базе

многослойной ИНС прямого распространения (МЛС) требуется применить слой нейронов с НФА. На рисунке 8 приведена структура сверточной нейро-нечеткой сети (СННС), на рисунке 9 изображена структура рекуррентной нейро-нечеткой сети (РННС) с НФА внутри блока «ННРС», иллюстрирующего слой рекуррентных нейронов.




Рис. 8. Структура сверточной нейро-нечеткой сети




Рис. 9. Структура рекуррентной нейро-нечеткой сети

В слоях с НФА в процессе обучения оптимизируются параметры НФА, следовательно, при обучении нейро-нечеткой сети изменяется нелинейное отображение, определяемое параметрами НФА. Основное отличие от обыкновенных ИНС в том, что у нейрона с НФА отсутствуют весовые коэффициенты [13], вместо них применяются параметры НФА.

Нейро-нечеткая классификация в прикладных задачах. Оценка нейро-нечетких систем классификации проведена в экспериментах с объектами сложной структуры и разной физической природы: медико-биологическими данными, текстовыми данными, компьютерными изображениями. В эксперименте с медико-биологическими объектами решалась задача классификации семейств белков набора данных «Protein Families annotations and multiple sequence alignments using Hidden Markov Models» (PFAM) [14]. Результаты приведены в таблице 1.

Таблица 1. Точность классификации медико-биологических объектов

Точность		
Классификатор	Обучение	Проверка
СНС	68.45	69.53
СННС	77.19	75.41
РНС	78.56	76.15
РННС	86.41	84.10

Оценивание качества работы с текстовыми данными проведено в контексте задачи классификации пользовательских рецензий на фильмы онлайн-базы «Internet Movie Database» (IMDB) [15]. Результаты приведены в таблице 2.

Таблица 2. Точность классификации текстовых объектов

Точность		
Классификатор	Обучение	Проверка
СНС	74.56	70.29
СННС	83.57	76.48
РНС	78.32	74.53
РННС	83.31	79.40

При работе с компьютерными изображениями использовались данные набора Fashion-MNIST [16]. Результаты приведены в таблице 3.

Таблица 3. Точность классификации компьютерных изображений

Точность		
Классификатор	Обучение	Проверка
СНС	81.66	79.98
СННС	90.27	88.68
МЛС	84.03	82.40
МННС	85.77	83.96

В проведенных экспериментах построенные нейро-нечеткие системы классификации, в сравнении с аналогичными системами на основе ИНС, показывают лучшие показатели точности.

Заключение. В работе рассмотрена задача классификации состояний объектов сложной структуры инструментом нейросетевого моделирования, и обработка нечеткости в данных инструментом нечетких множеств. Отмечены проблемы применения ИНС и НЛС в задачах классификации.

В работе предложен новый подход к объединению инструментов нечетких множеств и нейросетевого моделирования через расширение функций активации нечеткими логическими системами. На примере НЛС с Т2-НМ рассмотрена модель нечеткой функции активации. Параметры P , N , a определяют свойства нелинейного отображения НФА, при этом ограничения области значений параметров обусловлены применяемыми функциями принадлежности и методом формирования следа неопределенности. При выходе значений параметров за допустимые пределы используемые Т2-НМ вырождаются в Т1-НМ, а нечеткая функция перестает быть дифференцируемой.

Нечеткая функция может применяться в математической модели искусственного нейрона в качестве нечеткой функции активации. Весовые коэффициенты в модели нейрона с НФА заменены параметрами НФА. Для обеспечения корректной работы нейро-нечеткой сети предлагается дополнительный этап нормализации ввода НФА в диапазон допустимых значений.

Рассмотрены особенности построения и нейро-нечетких систем классификации и их применение для работы с объектами сложной структуры разной природы: медико-биологическими, текстовыми объектами и объектами компьютерных изображений.

Экспериментальная оценка точности, полученная в прикладных задачах классификации, приведенных выше, при применении нейро-нечетких систем классификации: на тестовом наборе данных для медико-биологических объектов – улучшение 5.9-8%, для текстовых объектов – 4-6%, в задаче классификации изображений – улучшение 1.6-9%.

Рассмотренный подход расширяет область применения нейросетевого моделирования и допускает применение к задачам в условиях неполных, неточных, нечетких данных.

Список источников

1. Lu Y, Lu J. A universal approximation theorem of deep neural networks for expressing probability distributions. *Advances in neural information processing systems*, 2020, DOI:10.48550/arXiv.2004.08867.
2. Zhang Y, Tiño P, Leonardi A., et al. A survey on neural network interpretability. *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2021, vol. 5, iss. 5, pp. 726-742, DOI:10.1109/TETCI.2021.3100641.
3. Zadeh L.A. Fuzzy sets. *Information and control*, 1965, vol. 8 (3), pp. 338-353, DOI:10.1016/S0019-9958(65)90241-X.
4. Заде Л.А. Размытые множества и их применение в распознавании образов и кластер-анализе / Л.А. Заде // Классификация и кластер. – М.: Мир, 1980. – с. 208-247.
5. Liang Q., Mendel J.M. Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on fuzzy systems*, 2000, vol. 8, no. 5, pp. 535-550, DOI:10.1109/91.873577.
6. Mendel J., Hagaras H., Tan W.W. et al. Introduction to type-2 fuzzy logic control: theory and applications. John Wiley & Sons, 2014, 357 p., DOI:10.1002/9781118886540.

7. Kosko B. Fuzzy systems as universal approximators. IEEE transactions on computers, 1994, vol. 43, iss. 11, pp. 1329-1333, DOI:10.1109/12.324566.
8. Kumbasar T. Robust stability analysis and systematic design of single input interval Type-2 fuzzy logic controllers, IEEE Transactions on fuzzy systems, 2015, vol. 24, iss. 3, pp. 675-694, DOI:10.1109/TFUZZ.2015.2471805.
9. Kumbasar T. A simple design method for interval type-2 fuzzy PID controllers. Soft Computing, 2014, vol. 18(7), pp. 1293-1304, DOI:10.1007/s00500-013-1144-1.
10. Ломакина Л.С. Нейро-нечеткие классификаторы / Л.С. Ломакина, С.А. Манцеров, И.Д. Чернобаев // Теория и практика: Монография. – Воронеж: Издательство «Научная книга», 2022. – 137 с.
11. Naaz S, Alam A, Biswas R. Effect of different defuzzification methods in a fuzzy based load balancing application. International journal of computer science issues (IJCSI), 2011, vol. 8(5).
12. Ломакина Л.С. Нейро-нечеткие классификаторы / Л.С. Ломакина, И.Д. Чернобаев // Моделирование, оптимизация и информационные технологии, 2021. – № 9(4). – DOI:10.26102/2310-6018/2021.35.4.027.
13. Ломакина Л.С. Algorithmic support of neuro-fuzzy classification of objects of complex structure / Л.С. Ломакина, И.Д. Чернобаев, И.Н. Киселев // Труды Международного научно-технического конгресса «Интеллектуальные системы и информационные технологии – 2021» («ИС & ИТ-2021», «IS&IT'21»). – Дивноморское, 2021. – № 6 – С. 475-481.
14. Sonnhammer E.L., Eddy S.R., Durbin R. Pfam: a comprehensive database of protein domain families based on seed alignments. Proteins. – New York, NY: Wiley-Lissn 1997, no. 28(3), pp. 405-420, DOI:10.1002/(sici)1097-0134(199707)28:3<405::aid-prot10>3.0.co;2-I.
15. Maas A.L., Daly R.E., Pham P.T., et al. Learning word vectors for sentiment analysis. In Proceedings of the 49th annual meeting of the association for computational linguistics: human language technologies, Portland, Oregon, USA, 2011, pp. 142-150,
16. Khafera E, Cina E, Toti L. Classification of standard FASHION MNIST dataset using deep learning based CNN algorithms. 2022 international symposium on multidisciplinary studies and innovative technologies (ISMSIT), 2022, pp. 494-498, DOI: 10.1109/ISMSIT56059.2022.9932737.

Ломакина Любовь Сергеевна. Доктор технических наук, профессор, профессор кафедры «Вычислительные системы и технологии» НГТУ им. П. Е. Алексеева. Elibrary AuthorID: 8366, ORCID: 0000-0002-5598-6079 lloமாகina@list.ru

Чернобаев Игорь Дмитриевич. Кандидат технических наук, доцент кафедры «Вычислительные системы и технологии» НГТУ им. П. Е. Алексеева. Elibrary AuthorID: 1305749 SPIN: 6772-2940 ORCID: 0000-0001-6809-6473, ichernobnn@gmail.com

Беляева Любовь Андреевна. Магистрант кафедры «Вычислительные системы и технологии» НГТУ им. П. Е. Алексеева. b3liaeva.lub@yandex.ru

UDC 004.8

DOI:10.25729/ESI.2025.39.3.002

Neuro-fuzzy classification system for states of objects of complex structure

Liubov S. Lomakina, Igor D. Chernobaev, Liubov A. Beliaeva

Nizhny Novgorod state technical university n.a. R. E. Alekseev,

Russia, Nizhny Novgorod, ichernobnn@gmail.com

Abstract. The paper considers the machine learning task of classifying the states of objects with a complex structure. The state of an object is understood as a certain category that characterizes the properties of an object at a given time, and at the same time is described by a set of features. The complexity of the object structure is expressed by the features that require preliminary processing and have hierarchical or sequential relationships, or unstructured elements. The data to process may contain inaccuracies, and errors. The neural networks as a tool are often applied to the classification tasks. Fuzzy logic systems are applicable to the classification tasks within the context of data fuzziness. Both tools have the properties of a universal approximator, however the neural network results are hard to interpret, at the same time the application of a fuzzy logical system requires the preliminary construction of a fuzzy rules. The paper considers an approach to combine fuzzy logic system and neural network with the fuzzy neuron activation function. The model of the fuzzy function is described by the fuzzy sets, membership functions and fuzzy activation rules. The input of a fuzzy function goes through the transformations stages, including fuzzification, fuzzy inference using the fuzzy logic system's rules and defuzzification. The approach makes it possible to form a fuzzy activation function with a set of changeable parameters during the neural network model training. An improved normalization of the input of the fuzzy activation function is proposed in order to ensure the feasibility of the information signal requirements in the fuzzy function. Neuro-fuzzy

classification systems are analyzed in the tasks classification of objects of various nature: technical objects, biomedical objects textual objects. A comparative assessment of the accuracy of solutions of neuro-fuzzy classification systems relative to similar ANN-based systems showed an increase from 2 to 9% in a number of experiments.

Keywords: classification of objects states, fuzzy logic system, neural networks, neuro-fuzzy classification

References

1. Lu Y, Lu J. A universal approximation theorem of deep neural networks for expressing probability distributions. *Advances in neural information processing systems*, 2020, DOI:10.48550/arXiv.2004.08867.
2. Zhang Y, Tiño P, Leonardis A., et al. A survey on neural network interpretability. *IEEE Transactions on Emerging Topics in Computational Intelligence*. 2021, vol. 5, iss. 5, pp. 726-742, DOI:10.1109/TETCI.2021.3100641.
3. Zadeh L.A. Fuzzy sets. *Information and control*, 1965, vol. 8 (3), pp. 338-353, DOI:10.1016/S0019-9958(65)90241-X
4. Zade L.A. Razmytyye mnozhestva i ikh primeneniye v raspoznavanii obrazov i klaster-analize [Fuzzy extensions and their application in pattern recognition and cluster analysis]. *Klassifikatsiya i klister*, M.: Mir [Classification and cluster, M.: Mir], 1980, pp. 208-247.
5. Liang Q., Mendel J.M. Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on fuzzy systems*, 2000, vol. 8, no. 5, pp. 535-550, DOI:10.1109/91.873577.
6. Mendel J., Hagsras H., Tan W.W. et al. Introduction to type-2 fuzzy logic control: theory and applications. John Wiley & Sons, 2014, 357 p., DOI:10.1002/9781118886540.
7. Kosko B. Fuzzy systems as universal approximators. *IEEE transactions on computers*, 1994, vol. 43, iss. 11, pp. 1329-1333, DOI:10.1109/12.324566.
8. Kumbasar T. Robust stability analysis and systematic design of single input interval Type-2 fuzzy logic controllers, *IEEE Transactions on fuzzy systems*, 2015, vol. 24, iss. 3, pp. 675-694, DOI:10.1109/TFUZZ.2015.2471805.
9. Kumbasar T. A simple design method for interval type-2 fuzzy PID controllers. *Soft Computing*, 2014, vol. 18(7), pp. 1293-1304, DOI:10.1007/s00500-013-1144-1.
10. Lomakina L.S., Mantserov S.A., Chernobaev I.D. Neiro-nechetkie klassifikatory [Neuro-fuzzy classifiers]. *Teoriya i praktika: Monografiya, Voronezh, Nauchnaya Kniga* [Theory and practice: Monograph. Voronezh: Publishing house "Scientific book"], 2022, 137 p.
11. Naaz S, Alam A, Biswas R. Effect of different defuzzification methods in a fuzzy based load balancing application. *International journal of computer science issues (IJCSI)*, 2011, vol. 8(5).
12. Lomakina L.S., Chernobaev I.D. Neyro-nechetkiye klassifikatory [Neuro-fuzzy classifiers]. *Modelirovaniye, optimizatsiya i informatsionnyye tekhnologii* [Modeling, optimization and information technology], 2021, no. 9(4), DOI:10.26102/2310-6018/2021.35.4.027.
13. Lomakina L.S., Chernobaev I.D., Kiselev Y.N. Algorithmic support of neuro-fuzzy classification of objects of complex structure. *Trudy Mezhdunarodnogo nauchnotekhnicheskogo kongressa "Intellectual'nyye sistemy i informatsionnyye tekhnologii – 2021" ("IS & IT-2021", "IS&IT'21")* [Proceedings of the international scientific and technical congress "Intelligent systems and information technology – 2021" ("IS&IT'21")], 2021, no. 6, pp. 475-481.
14. Sonnhammer E.L., Eddy S.R., Durbin R. Pfam: a comprehensive database of protein domain families based on seed alignments. *Proteins. – New York, NY: Wiley-Lissn* 1997, no. 28(3), pp. 405-420, DOI:10.1002/(sici)1097-0134(199707)28:3<405::aid-prot10>3.0.co;2-l.
15. Maas A.L., Daly R.E., Pham P.T., et al. Learning word vectors for sentiment analysis. In *Proceedings of the 49th annual meeting of the association for computational linguistics: human language technologies*, Portland, Oregon, USA, 2011, pp. 142-150,
16. Xhaferri E, Cina E, Toti L. Classification of standard FASHION MNIST dataset using deep learning based CNN algorithms. *2022 international symposium on multidisciplinary studies and innovative technologies (ISMSIT)*, 2022, pp. 494-498, DOI: 10.1109/ISMSIT56059.2022.9932737.

Lomakina Liubov Sergeevna. Doctor of Technical Science, Professor, Professor of the Department of Computing Systems and Technologies at the NNSTU n.a. R. E. Alekseev. Elibrary AuthorID: 8366, ORCID: 0000-0002-5598-6079, llomakina@list.ru.

Chernobaev Igor Dmitrievich. Candidate of Technical Science, Associate Professor of the Department of Computing Systems and Technologies at the NNSTU n.a. R. E. Alekseev. Elibrary AuthorID: 1305749, SPIN: 6772-2940 ORCID: 0000-0001-6809-6473, ichernobnn@gmail.com.

Beliaeva Liubov Andreevna. Master's degree in the Department of Computing Systems and Technologies at the NNSTU n.a. R. E. Alekseev. b3liaeva.lub@yandex.ru.

Статья поступила в редакцию 16.04.2025; одобрена после рецензирования 22.05.2025; принята к публикации 02.08.2025.

The article was submitted 04/16/2025; approved after reviewing 05/22/2025; accepted for publication 08/02/2025.