

ТЕХНИЧЕСКАЯ ДИАГНОСТИКА НА ОСНОВЕ НЕЙРОСЕТЕВОГО МОДЕЛИРОВАНИЯ ПРИ НЕПОЛНЫХ ДАННЫХ

И.Д. Чернобаев

ORCID: 0000-0001-6809-6473 e-mail: ichernobnn@gmail.com

Нижегородский государственный технический университет им. Р.Е. Алексеева
Нижний Новгород, Россия

Рассмотрено применение инструментов нейросетевого моделирования и теории нечетких множеств в задачах диагностирования проблемных состояний технических объектов в условиях неполных данных. Выполнены построение и настройка нейро-нечетких моделей в условиях неполных данных с применением нечетких логических систем второго типа. Рассматриваемый подход к построению нейро-нечетких классификаторов основан на расширении инструмента нейросетевого моделирования аппаратом нечетких логических систем. Экспериментальное применение нейро-нечеткого классификатора в задаче технической диагностики позволило повысить точность классификации проблемных состояний до 11.2 % в сравнении с обычной нейросетевой моделью. Практическая значимость исследования определяется тем, что нейро-нечеткие системы классификации могут быть применены в условиях неполных данных в задачах диагностики технических объектов, в том числе, объектов атомной отрасли.

Ключевые слова: техническая диагностика; неполные данные; нейросетевое моделирование; нечеткая логическая система; нейро-нечеткая классификация.

ДЛЯ ЦИТИРОВАНИЯ: Чернобаев, И.Д. Техническая диагностика на основе нейросетевого моделирования при неполных данных // Труды НГТУ им. Р.Е. Алексеева. 2025. № 4. С. 31-41.
DOI:10.46960/1816-210X_2025_4_31 EDN: JARTUC

TECHNICAL DIAGNOSTICS BASED ON NEURAL NETWORK MODELING WITH INCOMPLETE DATA

I.D. Chernobaev

ORCID: 0000-0001-6809-6473 e-mail: ichernobnn@gmail.com
Nizhny Novgorod State Technical University n.a. R.E. Alekseev
Nizhny Novgorod, Russia

Abstract. The article discusses the application of neural network modeling tools and fuzzy set theory in diagnosing problematic states of technical objects in conditions of incomplete data. Neuro-fuzzy models were built and tuned under conditions of incomplete data using type-2 fuzzy logic systems. The considered approach to the construction of neuro-fuzzy classifiers is based on the expansion of the neural network modeling tool with the apparatus of fuzzy logical systems. The experimental application of the neuro-fuzzy classifier in a technical diagnostics task allowed to increase the accuracy of classifying problematic conditions to 11.2 % compared to a conventional neural network model. Neuro-fuzzy classification systems can be applied in conditions of incomplete data in diagnostic tasks of technical objects, including nuclear industry objects.

Key words: technical diagnostics; incomplete data; neural networks; fuzzy logic system; neuro-fuzzy classification.

FOR CITATION: I.D. Chernobaev. Technical diagnostics based on neural network modeling with incomplete data. Transactions of NNSTU n.a. R.E. Alekseev. 2025. № 4. Pp. 31-41. DOI: 10.46960/1816-210X_2025_4_31 EDN: JARTUC

В работе рассматривается задача технического диагностирования 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.

В теории машинного обучения под решением задачи классификации понимается получение ответа на вопрос о принадлежности рассматриваемого объекта к некоторой категории из множества допустимых в рамках задачи. Для определения объекта к той или иной категории требуется построить модель объекта в виде набора признаков и выполнить анализ его признакового описания. В контексте технического диагностирования значения элементов признакового описания рассматриваемого объекта могут содержать неточности, погрешности и ошибки, обусловленные датчиками измерительных приборов. Подобные неточности приводят к «нечеткости» границ между категориями, что затрудняет получение однозначного ответа о принадлежности объекта к одной из них. В таких условиях необходимо рассматривать степень принадлежности объекта к категории, что требует более детального и комплексного подхода к анализу данных.

Задача классификации может быть решена применением как точных аналитических методов, так и приближенных численных подходов. Аналитические методы предполагают формализацию проблемы и последующее нахождение точного решения за конечное число операций, что позволяет проводить оценку вычислительной и временной сложности получения решения. В основу аналитического подхода заложены строгие математические принципы, что позволяет достичь высокой степени уверенности в корректности и точности результата, и делает эти методы предпочтительными в областях с повышенными требованиями к надежности и интерпретируемости полученных решений.

Точные методы требуют строгого определения анализируемого процесса. Тем не менее, даже при его наличии точное решение может оказаться недостижимым. У аналитических методов отсутствует стадия обучения на данных ввода, поэтому они особенно требовательны к качеству входных данных. Эти методы обеспечивают интерпретируемость решений и востребованы в областях, где отсутствуют необходимые объемы обучающих данных, а сами данные содержат хорошо известные закономерности. При этом вычислительная сложность получения точного решения, при условии его существования, определяется размером пространства признаков анализируемых объектов, следовательно, точные методы могут оказаться неприменимы в условиях ограниченных вычислительных ресурсов.

Поиск оптимального решения численными методами является ключевым инструментом в ситуациях, когда существует множество допустимых решений задачи, а поиск точного решения аналитическим методом затруднен ввиду необходимости выполнения чрезмерно ресурсоемких вычислений. Эти методы позволяют эффективно справляться с задачами оптимизации в условиях неполноты данных, наличия ошибок и погрешностей измерений, а также при ограниченных вычислительных ресурсах. Численные методы оптимизации играют важную роль в ситуациях, когда точное решение задачи либо не может быть получено в разумные сроки, либо не существует в принципе. В связи с этим, алгоритмы численных методов позволяют находить приближенные решения, удовлетворяющие заданным критериям оптимальности и востребованы в условиях ограниченных вычислительных ресурсов.

Инструмент нейросетевого моделирования, как один из методов приближенного поиска решения, позволяет обрабатывать большие объемы данных, выявлять и аппроксимировать скрытые в них закономерности, которые не всегда поддаются аналитическому решению. Возможность применения искусственных нейронных сетей (ИНС) для обработки данных любой физической природы [1], способность инструмента нейросетевого моделирования обобщать новые данные, отсутствующие в обучающей выборке, подходы к повышению про-

изводительности нейросетевых моделей через организацию параллельных и распределенных вычислений, построения ансамблей базовых нейросетевых моделей, квантизацию весовых коэффициентов, позволяют применять инструмент нейросетевого моделирования в задачах технического диагностирования для классификации проблемных состояний технических объектов, прогнозирования отказов оборудования.

В инструменте нейросетевого моделирования рассматривается совместное применение множеств простейших компонентов в качестве основы ИНС: искусственный нейрон (рис. 1) и функция активации (ФА), преобразующая сигнал на выходе нейрона.

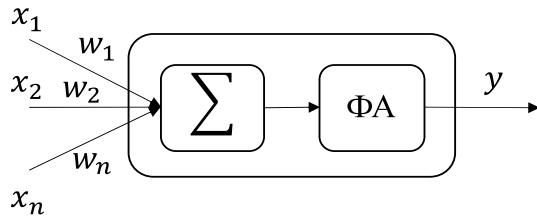


Рис. 1. Модель искусственного нейрона включает операцию линейной комбинации входа и весовых коэффициентов, а также функцию активации

Fig. 1. The artificial neuron model includes a linear combination operation of the input and weight coefficients, as well as an activation function

Функции активации обеспечивают нелинейность, необходимую для аппроксимации произвольных функций и позволяют формировать способность нейросетевой модели к извлечению и представлению сложных зависимостей в данных. Кроме того, ФА оказывают значительное влияние на сходимость и стабильность процесса обучения. Например, функция ReLU (рис. 2), способствует ускорению обучения благодаря устранению проблемы исчезающего градиента, что особенно важно для глубоких нейронных сетей. Функция сигмоиды (рис. 2) обеспечивает отображение входного сигнала в диапазон $[0, 1]$, но в то же время применение этой функции может способствовать замедлению обучения из-за проблемы исчезающего градиента.



Рис. 2. Функции активации ReLU (а) и Sigmoid (б)

Fig. 2. ReLU (a) and Sigmoid (b) activation functions

Простейшие нейросетевые модели включают полносвязные ИС прямого распространения, рекуррентные сети, характеризуемые наличием петли в структуре вычислительного графа ИНС, а также сверточные ИНС, в которых применяется операция свертки изображения. Различия между этими архитектурами заключаются в применяемых операциях и способе распространения сигнала по вычислительному графу сети. Сети прямого распространения представляют собой многослойные нейросетевые модели, где входные данные последовательно преобразуются и передаются в направлении от входного слоя к выходному. Эта конфигурация позволяет сети осуществлять последовательное извлечение и обработку информации, что делает ее эффективным инструментом для решения задач классификации, регрессии и других задач машинного обучения. В сети прямого распространения реализована операция линейной комбинации вектора входного сигнала и матрицы весовых коэффициентов

нейронов в слое (рис. 3). Это обеспечивает возможность моделирования сложных нелинейных зависимостей между входными и выходными данными.

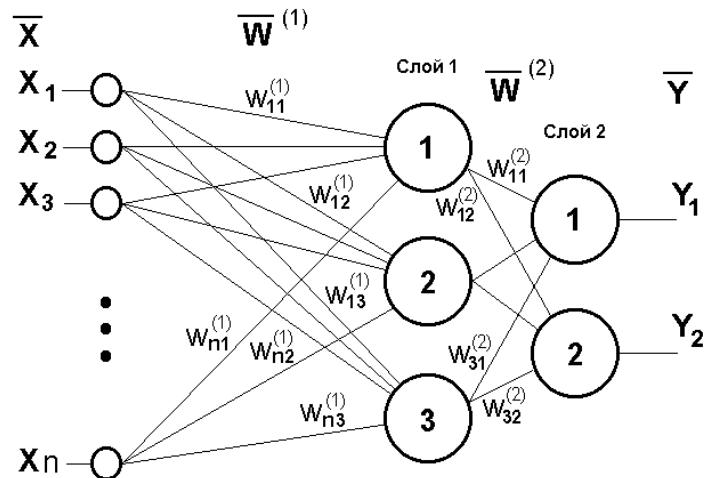


Рис. 3. Модель ИНС прямого распространения

Fig. 3. Feedforward artificial neural network model

В архитектуре рекуррентных нейросетевых моделей присутствуют элементы обратной связи, формирующие ориентированный граф с циклическими связями (рис. 4). Наличие обратной связи позволяет учитывать временную зависимость данных и обеспечивает возможность сохранения информации о предыдущих состояниях сети. Такие сети применяются в задачах обработки последовательностей данных.

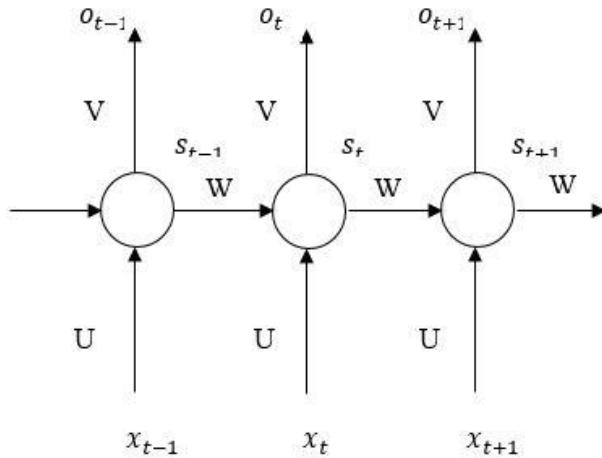


Рис. 4. Структура РНС

Fig. 4. Structure of a recurrent neural network

Ключевым элементом архитектуры сверточных нейронных сетей (СНС) является операция свертки изображения – специализированный настраиваемый фильтр, направленный на выявление существенных признаков в изображении. Операция свертки позволяет нейросетевой модели эффективно анализировать визуальные данные, при этом абстрагируясь от незначительных деталей и фокусируясь на более значимых признаках, что является ключевым аспектом в задачах компьютерного зрения и распознавания образов. В результате применения нескольких операций свертки изображения в последовательности (рис. 5), из исходного изображения на каждом шаге извлекаются все более абстрактные и значимые признаки.

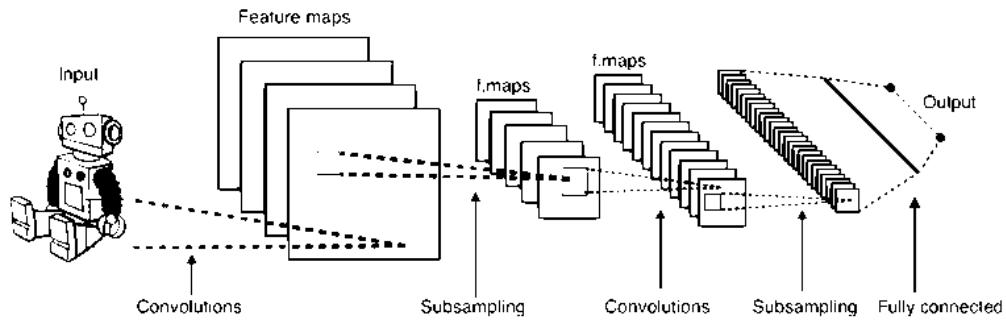


Рис. 5. Модель сверточной ИНС

Fig. 5. Convolutional artificial neural network model

Свойство универсального аппроксиматора [2] обеспечивает высокую точность нейросетевых моделей при решении любых прикладных задач. Структура графа в основе нейросетевых моделей допускает параллельную обработку данных, что способствует ускорению процесса обучения и принятия решений. Существенный недостаток ИНС заключается в низкой интерпретируемости [3] решений, принятых нейросетевыми моделями и ограничивает их применение в областях, требующих прозрачности и надежности используемых моделей. Эффективность нейронных сетей в обобщении данных напрямую связана с количеством и качеством информации, поступающей на вход. Качество решений нейросетевой модели может значительно снизиться при обработке неполных или неточных данных.

При работе с нечеткими или неполными данными для моделирования нечеткости применяется инструмент теории нечетких множеств (НМ), который предоставляет методологическую основу для формализации неопределенности [4] с помощью функций принадлежности (ФП), которые количественно оценивают степень принадлежности объектов к классам с нечеткими границами. Интеграция НМ в архитектуру нейросетевых моделей позволит повысить интерпретируемость и точность ИНС при работе с нечеткими или неполными данными. Нечеткое множество первого типа (T1-НМ) представляет собой набор упорядоченных пар, каждая из которых включает элемент «х» универсального множества «Х» и соответствующее ему значение степени принадлежности.

Характеристическая функция НМ определяется на диапазоне допустимых значений принадлежностей. На рис. 6 приведен график треугольной ФП, определенной для значений $\{2, 4, 6, 8\}$ диапазона принадлежностей. Если пространство принадлежностей содержит только два элемента $\{0, 1\}$, то НМ вырождается в детерминированное четкое множество.

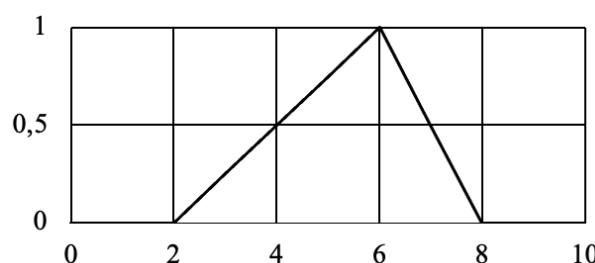


Рис. 6. График треугольной ФП

Fig. 6. Graph of triangular membership functions

Из определения функции НМ первого типа следует его важное ограничение и недостаток. Такое множество не позволяет моделировать неопределенность в значениях характеристической функции. Нечеткое множество 2-го типа (T2-НМ) расширяет возможности стандартных ФП и приведено на рис. 7. T2-НМ описывается множеством ФП, также являющихся T1-НМ [5].

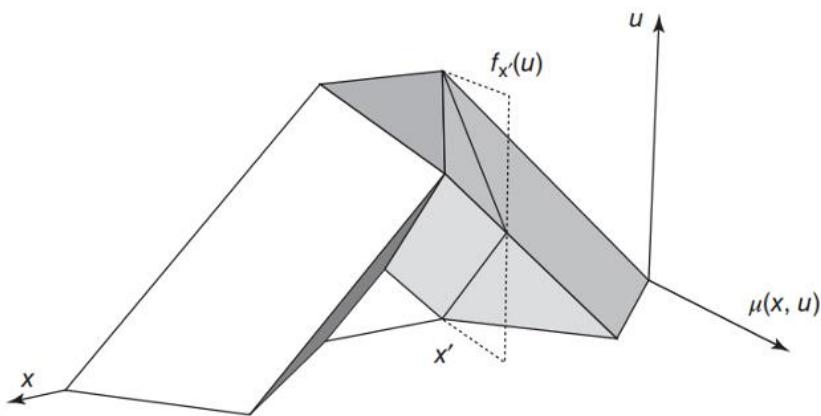


Рис. 7. Трехмерная модель обобщенного Т2-НМ с треугольными ФП

Fig. 7. Three-dimensional model of a generalized type-2 fuzzy set with triangular membership functions

Нечеткое множество второго типа можно рассматривать как область, образуемую проекцией множества ФП первого типа на плоскость "u-x", образуемую двумя ФП (рис. 8). Эту проекцию называют «отпечатком неопределенности» нечеткого множества второго типа. Третье измерение у Т2-НМ и его след неопределенности образуют вторичную ФП, которая позволяет моделировать нечеткость в ФП. Вторичная ФП – это проекция Т2-НМ на плоскость "u-Mu" в точке "x'" (рис. 8, справа).

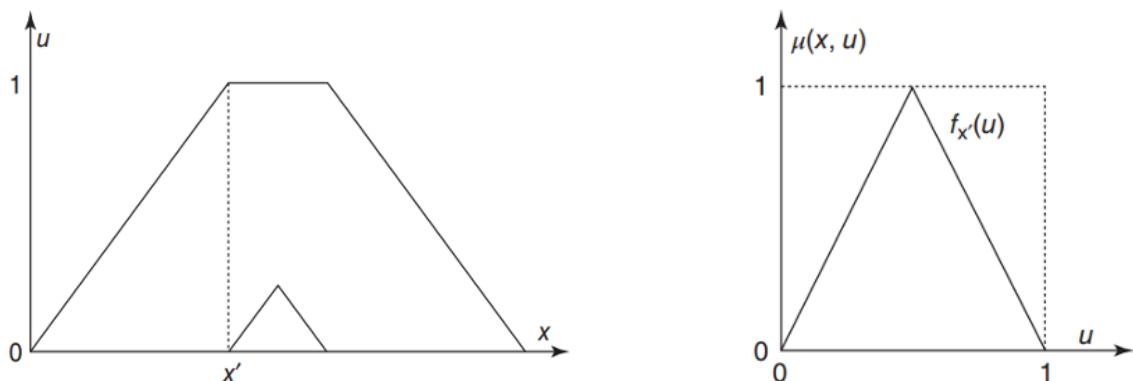


Рис. 8. Отпечаток неопределенности ФП Т2-НМ (слева) и вторичная треугольная ФП в точке x' (справа)

Fig. 8. The fingerprint of the uncertainty of the membership function of type-2 fuzzy set (left) and the secondary triangular membership function at point x' (right)

Если значения вторичной функции принадлежности для всех элементов первичной принадлежности принимают значение, равное 1, функция принадлежности классифицируется как интервальная (пунктирная линия на рис. 8 справа). Соответствующее нечеткое множество также обозначается как интервальное нечеткое множество второго типа (Т2-ИНМ). Обобщая вышеизложенное, Т2-НМ можно рассматривать как совокупность встроенных Т1-НМ. Принцип работы НЛС построен на совокупной обработке НМ в соответствии с заданными правилами. Поэтому решения НЛС – интерпретируемые, но построение подобных систем требует применения экспертных знаний прикладной области при составлении базы правил.

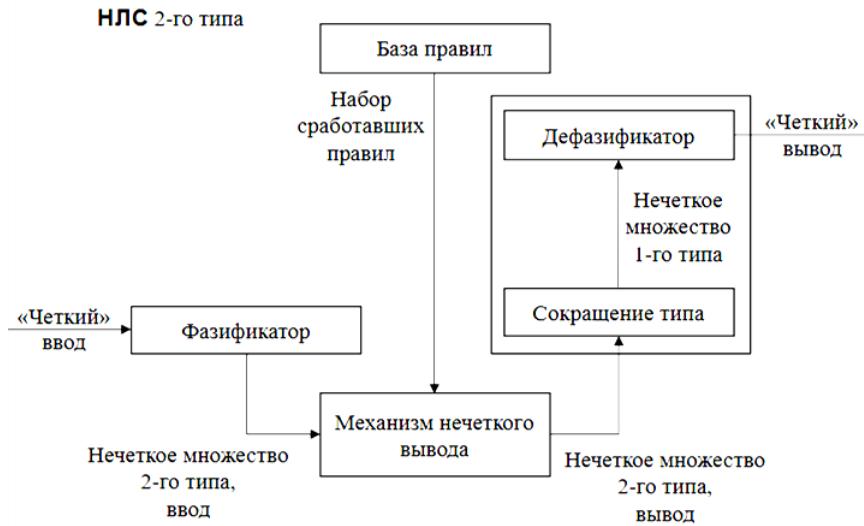


Рис. 9. Структура НЛС 2-го типа

Fig. 9. Structure of type-2 fuzzy logic system

В работе рассматривается структура Т2-НЛС, содержащая три правила для оперирования Т2-ИИМ, определяемыми треугольными ФП сверху и снизу (рис. 10).

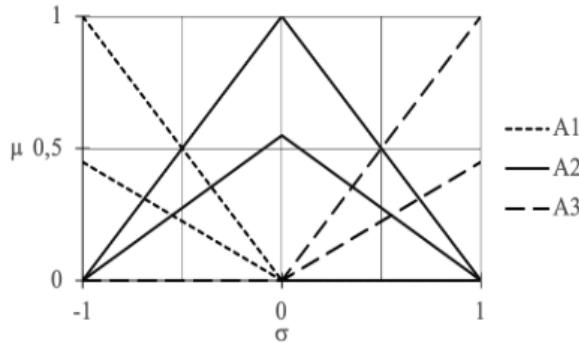


Рис. 10. Графическое представление рассматриваемой базы правил

Fig. 10. Graphical representation of the rule base under consideration

В рассматриваемых НМ след неопределенности формируется следующими ФП:

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

$$\underline{\mu}_{A_i} = h_i \cdot \bar{\mu}_{A_i}, \quad (2)$$

где $c_1 = -1, c_2 = 0, c_3 = 1$, отпечаток неопределенности Т2-ИИМ определяется только коэффициентами $h_1 = h_3 = 1 - a, h_2 = a$, $a \in (0,1)$. Рассматриваемый подход [6] к прототипированию Т2-НЛС позволяет формировать вывод через изменение параметра a .

В рассматриваемой Т2-НЛС выполняются следующие пять этапов преобразования информационного сигнала.

1. Фазификация – сигнал, передаваемый на вход системы на этапе фазификации отображается в Т2-НМ.

2. В соответствии с базой определяются правила, соответствующие вводу:

$$\text{ЕСЛИ } \sigma \text{ ЯВЛЯЕТСЯ } A_i \text{ ТОГДА } F \text{ ЯВЛЯЕТСЯ } F_i = B_i \quad (3)$$

где σ – сигнал на входе Т2-НЛС, A_i – Т2-ИНМ, а B – вывод Т2-НЛС, при этом $B_1 = N, B_2 = 0, B_3 = P, P$ и N – числовые коэффициенты.

3. Следствия активированных правил объединяются с применением операций над Т2-НМ и образуют вывод Т2-НЛС – агрегированное нечеткое множество.

4. Сокращение типа – для Т2-НМ определяется центроид, который является Т1-НМ.

5. Дефазификация – полученное Т1-НМ преобразуется в числовой вывод, который включает алгоритм отображения Т1-НМ в вывод НЛС.

Из выражения (2) следует, что параметры рассматриваемой НЛС определяют форму следа неопределенности. При этом следует отметить, что значения параметра " $a=\{0,1\}$ ", приводят к вырождению Т2-НМ в Т1-НМ, что приводит к сокращению типа НЛС, в результате чего сокращается количество Т1-НМ, входящих в состав Т2-НМ

В результате выполнения этапов 4-5 работы НЛС, модель НФА можно формализовать в виде [7]:

$$F(\sigma, P, N, a) = \begin{cases} P\sigma k(\sigma, a), & \sigma \in (0; 1] \\ N\sigma k(-\sigma, a), & \sigma \in [-1; 0] \end{cases} \quad (4)$$

$$k(\sigma) = 0.5 \left(\frac{1}{a + \sigma - a\sigma} + \frac{1 - a}{1 - a\sigma} \right) \quad (5)$$

где параметры P, N, a – конфигурируемые параметры, определяющие форму нечеткой функции активации, график которой приведен на рис. 11.

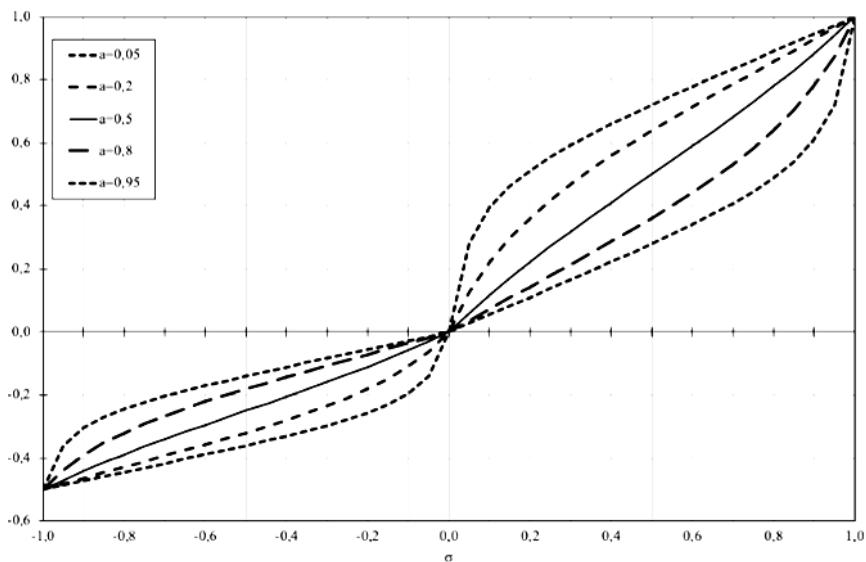


Рис. 11. График нечеткой функции активации с параметрами $N=1.0, P=1.0$ и переменными значениями параметра a

Fig. 11. Graph of fuzzy activation function with parameters $N=1.0, P=1.0$ and variable values of parameter a

На рис. 11 продемонстрирован потенциал гибкой настройки нелинейного отображения в НФА путем изменения параметров функции, которое позволяет получать отображения, близкие к базовым функциям активации. При построении моделей ИНС выражение (4) допустимо использовать как НФА, при этом весовые коэффициенты модели нейрона замещены параметрами НФА. Продемонстрировано, как меняется нелинейное отображение НФА в зависимости от знака и абсолютного значения параметра " a ".

В работе для моделирования НФА (рис. 12), применяются Т2-НЛС и, соответственно, Т2-ИНМ, при этом параметры НФА обновляются согласно правилу обучения ИНС. Такой подход позволяет использовать различные типы НМ и алгоритмы перехода в диапазон «четких» чисел [8].

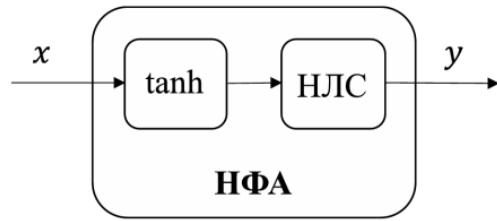


Рис. 12. Модель нечеткой функции активации

Fig. 12. Fuzzy activation function model

При обучении нейро-нечеткого классификатора значения параметра "a" могут принимать значения за пределом области определения в выражении (1), что сделает НФА недифференцируемой и негативно отразится на точности ННК. Для того чтобы исключить возможность выхода значений за пределы допустимого интервала, в [7] предложен этап нормализации ввода, который, ограничивающий значения параметра α в пределах (0,1). В исследовании рассматривается метод нормализации с использованием функции гиперболического тангенса:

$$\sigma = \tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}, \quad (6)$$

Слой нейронов с НФА применяется для получения нейро-нечетких систем классификации [9]. Ввиду того, что у нейрона с НФА весовые коэффициенты замещены параметрами НФА, связь между слоем ИНС предшествующим слою НФА, и слоем НФА организована по принципу «один к одному» (рис. 13).

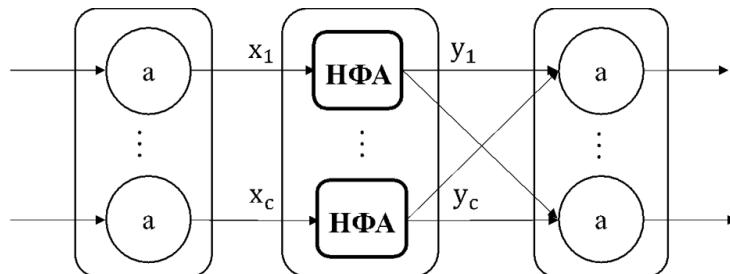


Рис. 13. Схема организации связей со слоем НФА в ИНС прямого распространения

Fig. 13. Diagram of the organization of connections with a fuzzy activation function layer in a feedforward artificial neural network

Системы классификации, объединяющие ИНС и НФА, предлагают альтернативный подход к построению нейросетевых моделей. При построении нейро-нечетких моделей требуется добавить слой НФА в структуру любой нейросетевой модели. Например, при построении сверточной нейро-нечеткой сети (СННС) достаточно применить слой нейронов с НФА в составе сверточной ИНС. В работе нейро-нечеткие классификаторы применены к прикладной задаче диагностирования дефектов внутренней поверхности труб [1], являющихся, в том числе, объектами атомной отрасли. СННС обучен на выборке из 3156 изображений с категориями дефектов: «царапина», «вмятина», «ржавчина», «продольная риска», «кольцевая риска», каждая категория представлена набором из 526 изображений. Объем тестовой выборки составляет 300 изображений.

Результаты обучения и тестирования ННК приведены на рис. 14. В проведенных экспериментах построенные нейро-нечеткие системы классификации, в сравнении с аналогичными системами на основе ИНС, позволили добиться повышения точности классификации до 11.2 %.

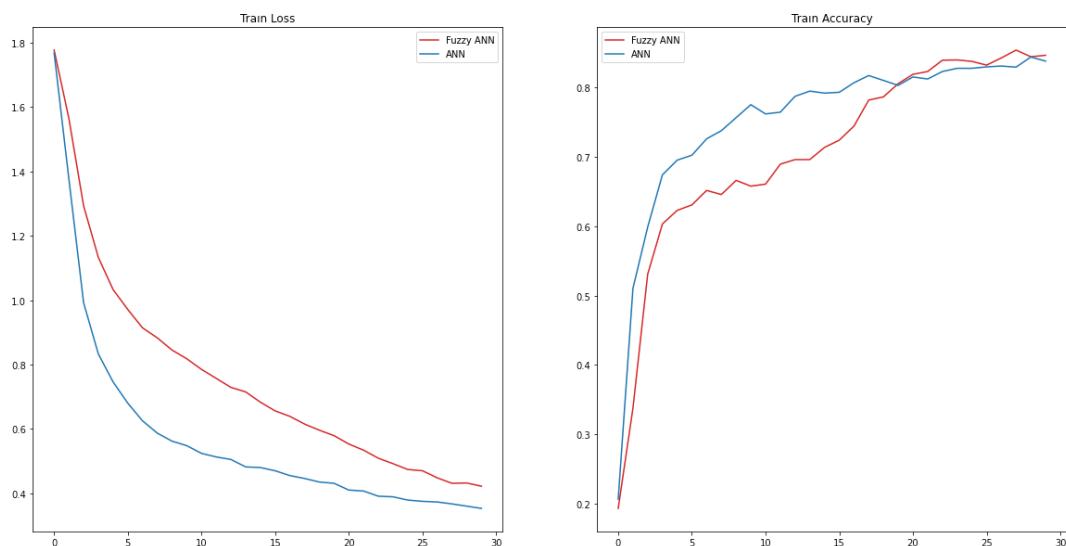


Рис. 14. Изменение точности и ошибки СННК и СНС при обучении в задаче классификации дефектов внутренней поверхности труб

Fig. 14. Change in the accuracy and error of convolutional neuro-fuzzy classifier and convolutional neural network during training in the problem of classifying defects on the inner surface of pipes

Библиографический список

1. **Ломакина, Л.С.** Нейро-нечеткие классификаторы. Теория и практика: монография / Л.С. Ломакина, С.А. Манцеров, И.Д. Чернобаев. – Воронеж: Научная книга, 2022. – 137 с.
2. **Lu, Y.** A universal approximation theorem of deep neural networks for expressing probability distributions / Y. Lu, J. Lu // Advances in neural information processing systems. – 2020. – Vol. 33. – Pp. 3094-3105.
3. **Ломакина, Л.С.** Проблема ускорения вычислений в прикладных задачах диагностирования объектов различной физической природы / Л.С. Ломакина, И.Д. Чернобаев, А.Н. Двиговская [и др.] // Научно-технический вестник Поволжья. – 2025. – № 7. – С. 123-130.
4. **Заде, Л.А.** Размытые множества и их применение в распознавании образов и кластер-анализе // Классификация и кластер / Л.А. Заде. – М.: Мир, 1980. – С. 208-247.
5. **Mendel, J.** Introduction to type-2 fuzzy logic control: theory and applications / J. Mendel, H. Hagras, W. Tan [et al.]. – Hoboken: John Wiley & Sons, 2014. – 357 p.
6. **Kumbasar, T.** A simple design method for interval type-2 fuzzy PID controllers / T. Kumbasar // Soft Computing. – 2014. – Vol. 18, № 7. – Pp. 1293-1304.
7. **Ломакина, Л.С.** Нейро-нечеткие классификаторы / Л.С. Ломакина, И.Д. Чернобаев // Моделирование, оптимизация и информационные технологии. – 2021. – Т. 9, № 4. – URL: <https://moitvivt.ru/ru/journal/pdf?id=1092> (дата обращения: 11.09.2025). – DOI: 10.26102/2310-6018/2021.35.4.027.
8. **Naa, S.** Effect of different defuzzification methods in a fuzzy based load balancing application / S. Naaz, A. Alam, R. Biswas // International Journal of Computer Science Issues (IJCSI). – 2011. – Vol. 8, № 5. – Pp. 261-267.
9. **Ломакина, Л.С.** Алгоритмическое обеспечение нейро-нечеткой классификации объектов сложной структуры / Л.С. Ломакина, И.Д. Чернобаев, Ю.Н. Киселев // Труды Международного научно-технического конгресса «Интеллектуальные системы и информационные технологии – 2021» («IS&IT'21»). – Дивноморское, 2021. – № 6. – С. 475-481.

References

1. Lomakina L.S., Mantserov S.A. and Chernobaev I.D. *Neuro-nechetkie klassifikatory. Teoriia i praktika* [Neuro-Fuzzy Classifiers. Theory and Practice]. Voronezh: Nauchnaia kniga, 2022.
2. Lu Y. and Lu J.. 2020. “A Universal Approximation Theorem of Deep Neural Networks for Expressing Probability Distributions” *Advances in Neural Information Processing Systems* 33: 3094-3105.

3. Lomakina L.S., Chernobaev I.D., Dvitovskaya A.N. [et al.]. 2025. “Problema uskoreniiia vychislenii v prikladnykh zadachakh diagnostirovaniia ob'ektov razlichnoi fizicheskoi prirody” [The Problem of Accelerating Computations in Applied Problems of Diagnosing Objects of Various Physical Nature]. *Nauchno-tehnicheskii vestnik Povolzh'ya* [Scientific and Technical Journal of the Volga Region], no. 7: 123-130.
4. Zadeh L.A. 1980. Razmytye mnozhestva i ikh primenenie v raspoznavanii obrazov i klasternom analize [Fuzzy Sets and Their Application in Pattern Recognition and Cluster Analysis]. In *Klassifikatsiia i klaster* [Classification and Cluster], 208-247. Moscow: Mir.
5. Mendel Jerry, Hani Hagras and Woei-Wan Tan. 2014. Introduction to Type-2 Fuzzy Logic Control: Theory and Applications. Hoboken, NJ: John Wiley & Sons.
6. umbasar, T. 2014. “A Simple Design Method for Interval Type-2 Fuzzy PID Controllers”. *Soft Computing* 18 (7): 1293-1304. <https://doi.org/10.1007/s00500-013-1>
7. Lomakina L.S. and Chernobaev I.D. 2021. “Neuro-nechetkie klassifikatory” [Neuro-Fuzzy Classifiers]. *Modelirovanie, optimizatsiia i informatsionnye tekhnologii* [Modeling, Optimization and Information Technology] 9, no. 4. <https://doi.org/10.26102/2310-6018/2021.35.4.027>.
8. Naaz S., Alam A. and Biswas R. 2011. “Effect of Different Defuzzification Methods in a Fuzzy Based Load Balancing Application”. *International Journal of Computer Science Issues (IJCSI)* 8 (5): 261-267.
9. Lomakina L.S., Chernobaev I.D. and Kiselev Y.N. 2021. “Algoritmicheskoe obespechenie neyro-nechetkoi klassifikatsii ob'ektov slozhnoi struktury” [Algorithmic Support for Neuro-Fuzzy Classification of Complex Structure Objects]. In *Trudy Mezhdunarodnogo nauchno-tehnicheskogo kongressa “Intellektual'nye sistemy i informatsionnye tekhnologii – 2021” (“IS&IT'21”)* [Proceedings of the International Scientific and Technical Congress “Intelligent Systems and Information Technologies – 2021” (“IS&IT'21”)], 6:475-481. Divnomorskoe.

*Дата поступления
в редакцию: 17.07.2025*

*Дата принятия
к публикации: 10.11.2025*