

# ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА УПРАВЛЕНИЯ ПРИ КЛАССИФИКАЦИИ СОСТОЯНИЙ ОБЪЕКТОВ СЛОЖНОЙ СТРУКТУРЫ

Ломакина Л.С., Манцеров С.А., Чернобаев И.Д.

*Нижегородский государственный технический университет им. Р. Е. Алексеева,*

*Нижний Новгород, Россия*

*ichernobnn@gmail.com*

*Аннотация. В работе рассматривается подход к построению системы классификации проблемных состояний объектов сложной структуры через расширение инструмента нейросетевого моделирования аппаратом нечетких логических систем, позволяющим работать в условиях неполных, неточных данных, и тем самым повысить точность классификации состояний объектов.*

*Ключевые слова: классификация состояний, нейро-нечеткая система классификации, объекты сложной структуры, нечеткие логические системы, нейросетевое моделирование.*

## **Введение**

Современный технологический прогресс создал условия, в которых интеллектуальные системы диагностики становятся ключевыми инструментами для обеспечения надежной, и при этом эффективной эксплуатации технических объектов сложной структуры. Отличительной характеристикой подобных систем является способность анализировать показатели признакового описания объекта и своевременно выявлять проблемные состояния, предшествующие отклонению от нормального функционирования и отказам.

Состояние объекта как категория формируется элементами признакового описания, которые определяют его работоспособность в момент времени. Измерение и анализ показателей этих признаков позволяет оценивать текущее состояние объекта и прогнозировать его состояния в следующие моменты времени. В задачах по анализу состояния объекта зачастую требуется учитывать совокупности взаимосвязанных признаков, образующие отдельные подмножества признакового описания. Примерами подобных объектов со сложной структурой, выражаемой совокупностями взаимосвязанных признаков, могут выступать, технические и промышленные объекты, медицинские и биологические объекты. Анализ совокупностей признаков позволяет осуществлять диагностирование для своевременного выявления отклонений от состояния нормального функционирования, для определения причин возникновения проблемных состояний, и принятия решений по устранению проблемных состояний для контролируемого возврата к состоянию нормального функционирования.

Выявление проблемных состояний технических объектов актуально в широком спектре задач, связанных с ранним обнаружением отклонений состояния объекта от нормального, с предотвращением отказов функционирования, с оптимизацией технического обслуживания, с увеличением срока службы, снижением риска преждевременного износа. Применение методов искусственного интеллекта при решении задач технической диагностики позволяет добиться снижения затрат на поддержание технических объектов в работоспособном состоянии.

Техническое диагностирование с применением методов, методов машинного обучения, позволяет принимать обоснованные решения, направленные на обеспечение его надежного и эффективного функционирования.

Нейросетевые модели обладают свойством универсального аппроксиматора [1], и решают задачу приближения к неизвестной зависимости, следовательно, корректность и точность решений искусственных нейронных сетей (ИНС) определяется качеством и полнотой обучающих данных, и при этом может снижаться из-за наличия погрешностей и неточностей в данных. Для работы в подобных условиях применяют инструмент нечетких логических систем (НЛС), оперирующий нечеткими множествами (НМ). НЛС способны к аппроксимации любой непрерывной функции в заданной области [2]. Принцип работы НЛС базируется на обработке нечетких данных, описываемых НМ, в соответствии с заданными правилами. Интерпретируемость решений НЛС, в отличие от ИНС, позволяет применять их в системах управления, однако построение подобных систем требует применения экспертных знаний прикладной области при составлении базы правил. При построении систем классификации состояний объектов сложной структуры рассматривается подход к расширению инструмента нейросетевого моделирования через НЛС, позволяющих работать в условиях неполных, неточных данных.

## 1. Нечеткая функция активации

Модель нечеткой функции активации (НФА) нейрона [3] строится на НЛС, в которых информация обрабатывается совокупностью правил активации, оперирующих нечеткими множествами (НМ). Подобный подход допускает применение любых типов НМ, и алгоритмов дефаззификации [4].

В рамках рассматриваемого подхода, используется совокупность утверждений вида:

$$i: \text{ЕСЛИ } \sigma \text{ ЕСТЬ } A_i \text{ ТО } \varphi_i = B_i, \quad (1)$$

где  $\sigma$  – ввод системы,  $A_i$  – НМ [5],  $\varphi_i$  – вывод системы, где  $B_1 = N, B_2 = 0, B_3 = P$ , где  $P$  и  $N$  – числовые коэффициенты. В системе используются интервальные НМ 2-го типа и следствия базы правил, как показано на рисунках 1 и 2.




Рис. 1. Интервальные НМ 2-го типа в рассматриваемой НЛС




Рис. 2. Следствия базы правил в рассматриваемой НЛС

Антеcedенты правил в рассматриваемой НЛС, интервальные НМ 2-го типа (Т2-ИНМ), определены треугольными верхними  $\bar{\mu}_{A_i}$  и нижними  $\underline{\mu}_{A_i}$  функциями принадлежности (ФП):

$$\bar{\mu}_{A_i} = \begin{cases} \frac{\sigma - c_{i+1}}{c_i - c_{i+1}}, & \sigma \in [c_i, c_{i+1}) \\ \frac{c_{i-1} - \sigma}{c_{i-1} - c_i}, & \sigma \in [c_{i-1}, c_i) \end{cases} \quad (2)$$

$$\underline{\mu}_{A_i} = h_i \cdot \bar{\mu}_{A_i}, \quad (3)$$

где коэффициенты  $c_1 = -1, c_2 = 0, c_3 = 1, h_1 = h_3 = 1 - \alpha, h_2 = \alpha, \alpha \in (0, 1)$ .

Таким образом, коэффициенты высоты  $h_i$  – единственные параметры, задающие след неопределенности Т2-ИНМ. Данный подход к прототипированию НЛС через правила, описываемые с применением симметричных ФП в составе Т2-ИНМ, предложен в [6], позволяет формировать вывод НЛС через настройку параметров нижних ФП.

Для описания нечеткой функции активации необходимо формализовать вывод НЛС через этапы определения совокупности активированных правил, приведения [7] Т2-ИНМ к НМ 1-го типа и перехода в домен «четких» чисел – дефаззификации [8]:

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

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

где параметры  $P, N, \alpha$ , определяют форму функции.

## 2. Нейро-нечеткая система классификации состояний

Структура нечеткого нейрона приведена на рисунке 3, из которого следует, что у такого нейрона отсутствуют весовые коэффициенты, и, следовательно, операция линейной комбинации ввода нейрона и его параметров. Для нормализации ввода нечеткого нейрона применяется функция гиперболического тангенса:

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

Нормализация применяется для учета области определения входного сигнала  $\sigma$  в выражении (4).

Структура ИНС с добавлением слоя нечетких нейронов приведена на рисунке 4, где продемонстрирована организация связей между слоем ИНС и следующим слоем нечетких нейронов по типу «один к одному», что является следствием отсутствием весовых коэффициентов и операции линейной комбинации.




Рис. 3. Структурная схема нечеткого нейрона




Рис. 4. Структурная схема слоя нечетких нейронов в составе ИНС

Таким образом, с добавлением слоя НФА в структуру ИНС, нейросетевые классификаторы преобразуются в нейро-нечёткие классификаторы (ННК), которые можно применять, в том числе, при диагностировании состояний технических объектов сложной структуры. На рисунке 5 приведена структура свёрточного нейро-нечёткого классификатора (СННК), который содержит свёрточную ИНС (СНС) и слой НФА.

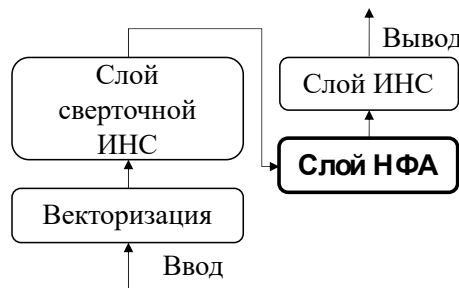


Рис. 5. Структурная схема СННК

Частные производные параметров для каждого параметра НФА определяются в соответствии с выражениями 7,8,9:

$$\frac{\partial f_c(\sigma_c)}{\partial \alpha_c} = \begin{cases} \frac{P_c \sigma_c}{2} \left( \frac{1}{\alpha_c \sigma_c - 1} + \frac{\sigma_c - 1}{(\alpha_c + \sigma_c - \alpha_c \sigma_c)^2} + \frac{\sigma_c (1 - \alpha_c)}{(\alpha_c \sigma_c - 1)^2} \right), & \text{if } \sigma_c > 0 \\ -\frac{N_c \sigma_c}{2} \left( \frac{1}{\alpha_c \sigma_c - 1} + \frac{\sigma_c + 1}{(\alpha_c - \sigma_c + \alpha_c \sigma_c)^2} + \frac{\sigma_c (1 - \alpha_c)}{(\alpha_c \sigma_c + 1)^2} \right), & \text{if } \sigma_c \leq 0 \end{cases} \quad (7)$$

$$\frac{\partial f_c(\sigma_c)}{\partial P_c} = \begin{cases} \sigma_c k_c(\sigma_c), & \text{if } \sigma_c > 0 \\ 0, & \text{if } \sigma_c \leq 0 \end{cases} \quad (8)$$

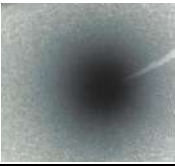






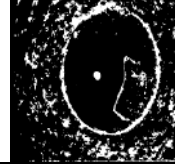
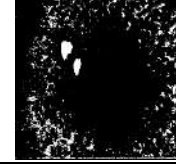
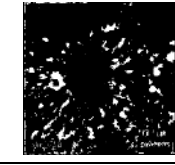
$$\frac{\partial f_c(\sigma_c)}{\partial N_c} = \begin{cases} 0, & \text{if } \sigma_c > 0 \\ \sigma_c k_c(-\sigma_c), & \text{if } \sigma_c \leq 0 \end{cases} \quad (9)$$

где  $c$  – индекс нечеткого нейрона в слое НФА.

### 3. ННК в задачах технической диагностики

В качестве примера рассматривается задача классификации дефектов внутренней поверхности труб. Диагностирование технических изделий неразрушающими методами позволяет обеспечивать требуемый уровень качества в технологическом процессе производства, в том числе для объектов атомной отрасли [9]. При обучении нейро-нечёткой системы классификации использован набор данных, включающий 3456 изображений внутренней поверхности труб. Перечень категорий дефектов приведен в таблице 1.

Таблица 1. Категории дефектов внутренней поверхности труб

Продольная риска	Нитка	Кольцевая риска	Вмятина	Пыль
				
				

Графики обучения ННК для решения задачи бинарной классификации дефектов труб представлены на рисунке 6, итоговая точность ННК составила 0.833, точность ИНС – 0.82, при этом на графиках видно, что ННК быстрее достиг удовлетворительной точности. Графики обучения ННК для решения задачи многоклассовой классификации приведены на рисунке 7.




Рис. 6. Изменение ошибки и точности ННК и ИНС при обучении в задаче бинарной классификации дефектов

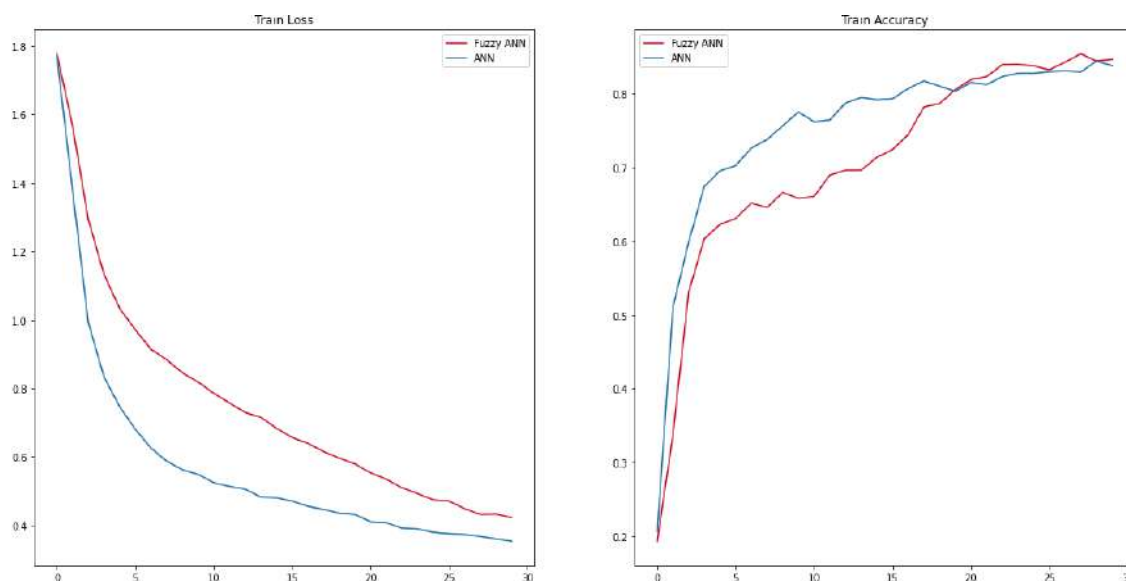


Рис. 7. Изменение ошибки и точности ННК и ИНС при обучении в задаче многоклассовой классификации дефектов

При тестировании ННК показатели корректного выявления категорий «Вмятина», «Капля», «Риска» составили 91%, показатели ложного срабатывания классификатора – менее 1%. Применение ННК позволило добиться повышения процента выявления дефектов 11,2%, и при этом ННК позволяет быстрее достичь высокой точности решений, как показано на рисунке 6.

#### 4. Заключение

Проведенные эксперименты показали, что применение слоя НФА в составе нейросетевой архитектуры позволяет повысить точность нейросетевых моделей в задачах технического диагностирования. Параметры НФА позволяют гибко определять преобразование входного сигнала, и при этом проводить анализ состояния каждого нечеткого нейрона в составе слоя НФА.

Применение НФА в прикладных задачах технической диагностики повысило процент корректного выявления дефектных состояний технических объектов на 11,2%.

#### Литература

1. *Lu Y., Lu J.* A universal approximation theorem of deep neural networks for expressing probability distributions // *Advances in neural information processing systems*. – 2020;33:3094-105.
2. *Kosko B.* Fuzzy systems as universal approximators // *IEEE Trans. Computers*. – 1994 Nov;43(11):1329–33.
3. *Ломакина Л.С., Чернобаев И.Д.* Нейро-нечеткие классификаторы // *Моделирование, оптимизация и информационные технологии*. – 2021;9(4). Доступно по: <https://moitvvt.ru/ru/journal/pdf?id=1092>.
4. *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 Sep 1;8(5):261.
5. *Ремезова Е.М.* Нечеткие множества второго порядка: понятие, анализ и особенности применения // *Современные проблемы науки и образования*. – 2013. – № 5.
6. *Kumbasar T.* A simple design method for interval type-2 fuzzy pid controllers // *Soft Computing*, 18(7), 1293–1304. DOI:10.1007/s00500-013-1144-1.
7. *Karnik N.N., Mendel J.M.* Centroid of a type-2 fuzzy set // *Information Sciences*, 2001. – Vol. 132. – P. 199–220.
8. *Mendel J.M.* Uncertain Rule-based Fuzzy Logic Systems: Introduction and New Directions / Mendel J. M. – Prentice Hall PTR, 2001. – 684 p.
9. *Ломакина Л.С., Манцеров С.А., Чернобаев И.Д.* Нейро-нечеткие классификаторы. Теория и практика: Монография. – Воронеж: Издательство «Научная книга», 2022. – 137 с.