

УДК 004.852

DOI: [10.26102/2310-6018/2021.35.4.027](https://doi.org/10.26102/2310-6018/2021.35.4.027)

Нейро-нечеткие классификаторы

Л.С. Ломакина, И.Д. Чернобаев✉

*Нижегородский государственный технический университет им. Р. Е. Алексева,
Нижний Новгород, Российская Федерация
ichernobnn@gmail.com*

Резюме. В статье рассматривается проблема повышения точности искусственных нейронных сетей при решении задач классификации состояний объектов различной физической природы. Эту проблему предлагается сформулировать как проблему выбора типа функции активации в искусственных нейронных сетях и рассматривать ее с позиции теории нечетких множеств. В этой связи разработана математическая модель адаптивной функции активации искусственного нейрона, использующая нечеткую логическую систему с интервальными нечеткими множествами второго типа. Эта функция отличается от обыкновенных функций активации, применяемых в нейросетевых моделях тем, что область ее входных значений ограничена, и при этом позволяет оптимизировать параметры, определяющие форму кривой в процессе обучения искусственной нейронной сети. С целью снижения вычислительной сложности нейро-нечеткой модели с нечеткой функцией активации предложена ее модификация, заключающаяся в применении математической функции гиперболического тангенса для нормализации значений вектора, подаваемого на вход нечеткой функции. Разработано алгоритмическое обеспечение для двух архитектур нейро-нечетких классификаторов – рекуррентного нейро-нечеткого классификатора и сверточного нейро-нечеткого классификатора. Проведено два эксперимента по классификации медико-биологических и текстовых объектов, в которых сравнивались показатели точности моделей нейро-нечетких классификаторов и аналогичных по структуре классификаторов без нечеткой функции активации, и при этом подтверждено повышение точности искусственных нейронных сетей, в составе которых используются нечеткие функции активации.

Ключевые слова: нейро-нечеткий классификатор, нечеткая логическая система, адаптивная функция активации, нейро-нечеткий рекуррентный классификатор, нейро-нечеткий сверточный классификатор

Для цитирования: 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> DOI: 10.26102/2310-6018/2021.35.4.027

Neuro-fuzzy classifiers

L.S. Lomakina, I.D. Chernobaev✉

*Nizhny Novgorod State Technical University n.a. R.E. Alekseev
Nizhny Novgorod, Russian Federation
ichernobnn@gmail.com*

Abstract: This paper considers the problem of increasing the accuracy of artificial neural networks in the tasks of states classification of objects with different physical nature. It is proposed to define this problem as a problem of choosing the activation function type in artificial neural networks and to consider it from the perspective of the fuzzy sets theory. In this regard, a mathematical model of the artificial neuron adaptive activation function has been developed, using a fuzzy logic system with interval fuzzy sets of the second type. This function differs from ordinary activation functions used in neural network models in that the range of its input values is limited, and, at the same time, such a

function allows to optimize the parameters that determine the shape of the curve in the process of training an artificial neural network. To reduce the computational complexity of a neuro-fuzzy model with a fuzzy activation function, its modification is proposed, which involves the use of mathematical function of the hyperbolic tangent to normalize the values of the vector supplied to the input of the fuzzy function. Algorithmic support has been developed for two architectures of neuro-fuzzy classifiers - a recurrent neuro-fuzzy classifier and a convolutional neuro-fuzzy classifier. Two experiments on the classification of biomedical and text objects were carried out, in which the accuracy indicators of models of neuro-fuzzy classifiers and classifiers similar in structure without a fuzzy activation function were compared; additionally, an increase in the accuracy of artificial neural networks, which used fuzzy activation functions, was confirmed.

Keywords: neuro-fuzzy classifier, fuzzy logic system, adaptive activation function, neuro-fuzzy recurrent classifier, neuro-fuzzy convolution classifier

For citation: Lomakina L.S., Chernobaev I.D. Neuro-fuzzy classifiers. *Modeling, Optimization and Information Technology*. 2021;9(4). Available from: <https://moitvvt.ru/ru/journal/pdf?id=1092> DOI: 10.26102/2310-6018/2021.35.4.027 (In Russ).

Введение (Introduction)

Развитие цифровых технологий является одной из причин роста объемов доступных данных, при этом возникает необходимость в их интеллектуальной обработке, например, классификации. Решение подобных задач сопровождается трудностями, связанными с формализацией знаний о предметной области, неполнотой и зашумленностью данных, размытостью классов объектов, нечеткостью, обусловленной человеческим фактором.

Задача классификации заключается в определении класса [1], к которому принадлежит объект. Существуют различные подходы к решению этой задачи, известно [2], что искусственная нейронная сеть (ИНС) является универсальным инструментом для решения задачи классификации, и при этом преимуществом обученной на необходимом объеме тренировочных данных ИНС является скорость работы. Эффективность работы сети напрямую зависит от ее структуры и используемых функций активации (ФА), которые задаются на этапе проектирования. Конкретный тип ФА выбирается исходя из структуры ИНС, ее сложности и вычислительных возможностей ЭВМ, при этом, некорректный выбор ФА может привести к снижению эффективности всей сети.

Проблему повышения точности ИНС можно сформулировать как проблему выбора типа ФА и рассматривать с позиции теории нечетких множеств, которая является разделом математики, приспособленным для описания неопределенности через понятие нечеткости [3]. Нечеткое множество определяется функцией принадлежности (ФП), которая характеризует меру принадлежности конкретного объекта множеству.

Материалы и методы (Materials and Methods)

На сегодняшний день аппарат теории нечетких множеств содержит интервальные нечеткие множества 2-го типа (Т2-ИНМ), которые являются развитием концепции нечетких множеств и характеризуются неопределенностью конкретного типа функций принадлежности. Такие множества описываются двумя ФП – верхней и нижней, при этом под нечеткостью ФП понимается множество всех возможных ФП между верхней и нижней ФП.

Нечеткие множества применяются для моделирования неопределенности, и в составе нечеткой логической системы (НЛС), которая кроме нечетких множеств

содержит фазификатор, базу правил и дефазификатор. В работе нечеткая функция моделируется с применением НЛС, база правил которой состоит из трех правил:

$$R_i: \text{ЕСЛИ } \sigma \text{ ЯВЛЯЕТСЯ } A_i \text{ ТОГДА } \varphi \text{ ЯВЛЯЕТСЯ } \varphi_i = B_i$$

где $i = 1, 2, 3$ – индекс правила R, σ – ввод НЛС, A_i – интервальные нечеткие множества 2-го типа, а $\varphi_i = B_i$ – вывод системы, известный в теории нечетких множеств как «следствие», при этом $B_1 = N$, $B_2 = 0$, $B_3 = P$, где P и N – числовые коэффициенты. Интервальные нечеткие множества 2-го типа приведены на Рисунке 1.

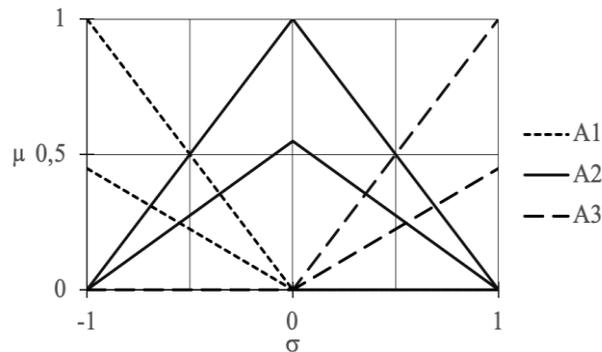


Рисунок 1 – Интервальные нечеткие множества 2-го типа, используемые в НЛС
Figure 1 – Interval type-2 fuzzy sets used in the fuzzy logic system

Известно [4], что стабильность НЛС гарантируется, когда применяемые нечеткие множества обладают свойством симметрии. Поэтому в предложенной системе множества определены треугольными верхними $\bar{\mu}_{A_i}$ и нижними $\underline{\mu}_{A_i}$ ФП:

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

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

Верхние ФП определены через параметры ($c_1 = -1, c_2 = 0, c_3 = 1$), а нижние – через параметры h_i , при этом $h_1 = h_3 = 1 - \alpha, h_2 = \alpha, \alpha \in (0, 1]$. Данный подход позволяет формировать вывод НЛС через настройку параметров верхних и нижних ФП.

В НЛС для получения вывода необходимо выполнить дефазификацию нечеткого сигнала, при этом вывод системы определяется выражением:

$$\varphi = \frac{(\varphi_l + \varphi_r)}{2} \quad (3)$$

$$\varphi_r = \frac{\sum_{i=1}^R \underline{\mu}_{A_i} \varphi_i + \sum_{i=R+1}^{I=3} \bar{\mu}_{A_i} \varphi_i}{\sum_{i=1}^R \underline{\mu}_{A_i} + \sum_{i=R+1}^{I=3} \bar{\mu}_{A_i}} \quad (4)$$

$$\varphi_l = \frac{\sum_{i=1}^L \bar{\mu}_{A_i} \varphi_i + \sum_{i=L+1}^{I=3} \underline{\mu}_{A_i} \varphi_i}{\sum_{i=1}^L \bar{\mu}_{A_i} + \sum_{i=L+1}^{I=3} \underline{\mu}_{A_i}} \quad (5)$$

где φ_l и φ_r являются конечными точками нечетких множеств 1-го типа, которые определяются по T2-ИНМ по методу определения центра множеств, R, L – точки переключения, определяемые по алгоритмам Карника-Менделя [5], а I=3 – количество правил в базе НЛС.

В рассматриваемой НЛС используются полностью перекрывающиеся T2-ИНМ, как показано на Рисунке 1, поэтому всегда срабатывают только два правила (I=2), содержащие два соседних множества A_i и A_{i+1} , поэтому точки переключения всегда

принимают значение, равное единице. В результате подстановки (4) и (5) в (3) вывод НЛС примет вид:

$$\varphi(\sigma) = \frac{1}{2} \left(\frac{\bar{\mu}_{\bar{A}_i} \varphi_i + \bar{\mu}_{\bar{A}_{i+1}} \varphi_{i+1}}{\bar{\mu}_{\bar{A}_i} + \bar{\mu}_{\bar{A}_{i+1}}} + \frac{\underline{\mu}_{\bar{A}_i} \varphi_i + \underline{\mu}_{\bar{A}_{i+1}} \varphi_{i+1}}{\underline{\mu}_{\bar{A}_i} + \underline{\mu}_{\bar{A}_{i+1}}} \right) \quad (6)$$

После подстановки (1) и (2) в (6), вывод системы φ можно определить как нечеткую функцию от σ , при этом $\sigma \in [-1, 1]$:

$$\varphi(\sigma, \gamma) = \begin{cases} P\sigma k(\sigma), & \sigma \in (0; 1] \\ N\sigma k(-\sigma), & \sigma \in [-1; 0) \end{cases} \quad (7)$$

где $k(\sigma) = 0.5 \left(\frac{1}{\alpha + \sigma - \alpha\sigma} + \frac{1-\alpha}{1-\alpha\sigma} \right)$, а $\gamma = [P, N, \alpha]$ – набор параметров, определяющих конкретную форму функции, как показано на Рисунке 2:

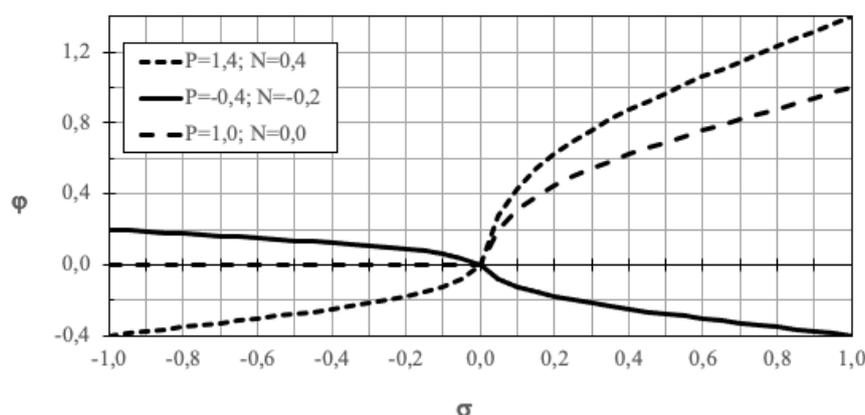


Рисунок 2 – Три графика нечеткой функции при различных значениях параметров P и N и при $\alpha = 0,5$

Figure 2 – Three graphs of the fuzzy function with various values of the parameters P and N and with $\alpha = 0,5$

На Рисунке 2 показано, что параметры P и N определяют направление функции φ в положительных и отрицательных квадрантах, а параметр α – величину изгиба кривой функции в положительных и отрицательных квадрантах.

Полученная нечеткая функция, определяемая выражением (7), может быть использована в математической модели искусственного нейрона в качестве нечеткой ФА (НФА), и при этом оптимизируемыми параметрами модели ИНС вместо весовых коэффициентов связей искусственного нейрона становятся параметры P, N и α .

Ограничение области допустимых значений параметра σ в выражении (7) обусловлено определением функций принадлежности интервальных нечетких множеств 2-го типа в (2). Очевидно, что в модели ИНС вектор значений признаков, поступающий на вход нейрона с НФА, может не удовлетворять заданному ограничению, поэтому необходимо выполнить его нормализацию. В [6] предложено нормализовать вектор с использованием его максимального элемента и затем выполнить обратную процедуру. Подобный подход предполагает выполнение множества дополнительных операций, которые оказывают негативное влияние на производительность ИНС. В настоящей работе предложена нормализация вектора при помощи функции гиперболического тангенса

$$\sigma = \tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}, \quad (8)$$

которая гарантирует, что нормализованный вектор σ удовлетворит обозначенным ограничениям.

Используя НФА, также возможно построить нейро-нечеткую рекуррентную сеть (ННРС) [7] путем добавления НФА в модель ячейки РНС, как показано на Рисунке 3:

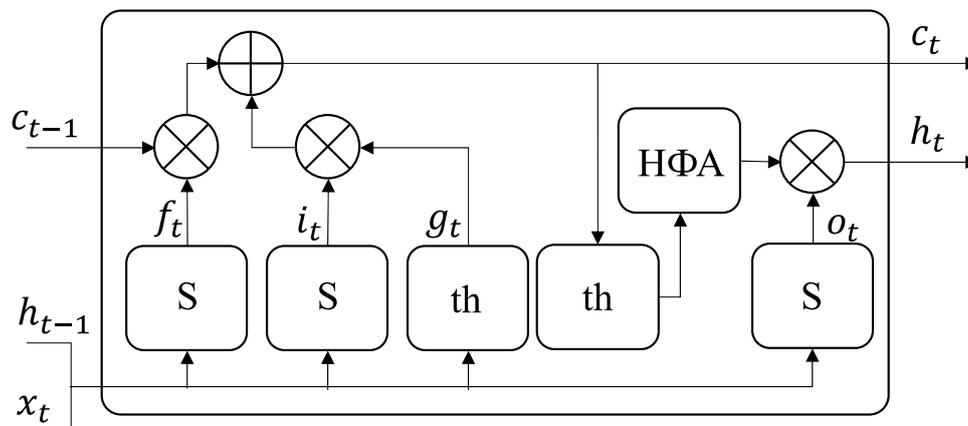


Рисунок 3 – Модель ячейки ННРС с нечеткой ФА

Figure 3 – The model of the neuro-fuzzy recurrent network cell with the fuzzy activation function

На Рисунке 3 представлены модуль НФА, обозначающий нечеткую ФА из (8), модуль S, обозначающий математическую функцию сигмоиды:

$$S(x) = \frac{1}{1 + e^{-x}}$$

и модуль th, обозначающий математическую функцию гиперболического тангенса, представленную выражением (8), при этом вывод ячейки ННРС определяется следующим выражением:

$$h_t(o_t, c_t) = \varphi(\tanh(c_t), P, N, \alpha) * o_t.$$

Применяя НФА в нейронах ИНС прямого распространения можно построить слой нечетких нейронов. С точки зрения топологии соединений, нейроны в слое с НФА связаны поэлементно с нейронами предшествующего слоя, как показано на Рисунке 4.

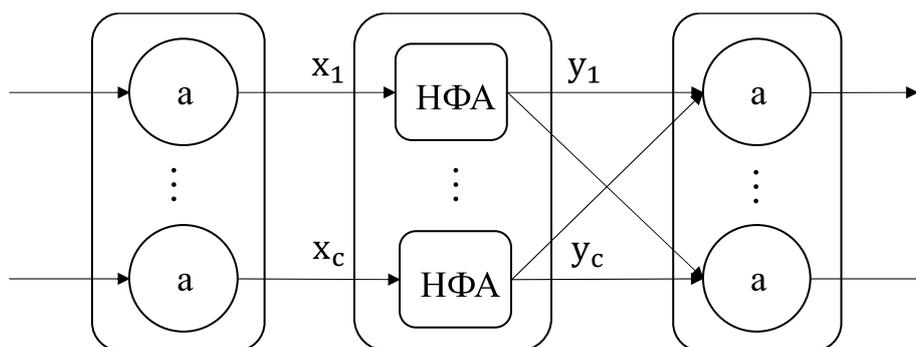


Рисунок 4 – Схема связей между слоем нейронов с НФА и смежными слоями нейронов ИНС прямого распространения

Figure 4 – Scheme of connections between the layer of neurons with NFA and adjacent layers of neurons of forward propagation ANN

Элементы «а» на Рисунке 4 представляют обыкновенные ФА в слоях нейронов ИНС прямого распространения, а в центре рисунка изображен слой нейронов с НФА. Такая организация связей для слоя нейронов с НФА на Рисунке 4 принципиально отличается от топологии соединений в моделях обыкновенных ИНС прямого распространения, где каждый нейрон одного слоя связан с каждым нейроном смежного слоя.

Представленные выше структурные элементы обеспечивают возможность для построения моделей нейро-нечетких классификаторов (ННК) для работы с данными различной физической природы, при этом необходимо в любую модель ИНС [8] добавить слой нейронов с НФА, либо слой ННРС. Например, применив слой ННРС вместо обыкновенной РНС можно получить модель рекуррентного нейро-нечеткого классификатора (РННК), как показано на Рисунке 5:

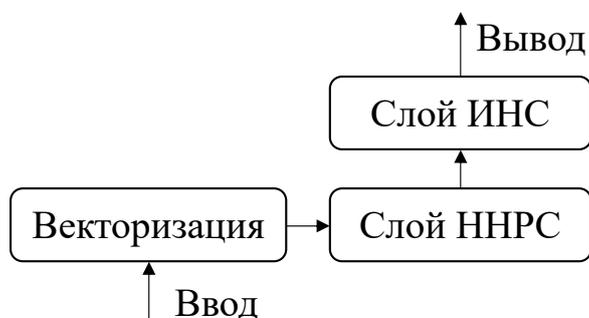


Рисунок 5 – Алгоритм рекуррентного нейро-нечеткого классификатора
 Figure 5 – The algorithm of the recurrent neuro-fuzzy classifier

Алгоритм классификатора на Рисунке 5, выделяется наличием обратной (рекуррентной) связи в слое ННРС, которая позволяет таким классификаторам эффективно обрабатывать последовательности данных [9].

На Рисунке 6 изображен алгоритм сверточного нейро-нечеткого классификатора (СННК) с применением слоя сверточной ИНС и слоя НФА. Слой сверточной ИНС выполняет функцию выделения наиболее значимых для классификации признаков.

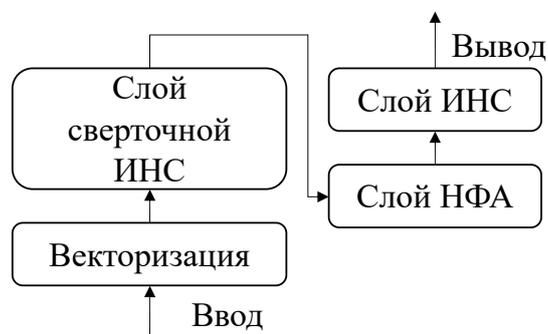


Рисунок 6 –Алгоритм сверточного нейро-нечеткого классификатора
 Figure 6 – The algorithm of the convolutional neuro-fuzzy classifier

В обоих алгоритмах ННК, представленных на Рисунке 5 и Рисунке 6, этап векторизации, выполняет функцию отображения входящих данных в векторное пространство модели ИНС. Обычно такой подход используется при работе с текстовыми данными [10]. Слой ИНС является полносвязной ИНС.

Результаты (Results)

Для оценки эффективности ННК проведен ряд экспериментов по классификации объектов различной физической природы, в частности, медико-биологических и текстовых объектов. В экспериментах использовались два типа ННК: РННК и СННК, точность классификации которых сравнивалась с аналогичными классификаторами без НФА в ИСН: сверточной нейронной сетью (СНС) и РНС. Эксперименты проводились

на серверной ЭВМ с 256 Мб ОЗУ и двумя ЦПУ Intel(R) Xeon(R) с тактовой частотой 2.20 ГГц.

Эксперимент 1. Классификация медико-биологических объектов.

В качестве таких объектов взяты последовательности аминокислот, и необходимо для каждой последовательности определить ее принадлежность к некоторому семейству белков. В данном эксперименте использован набор данных «Protein Families annotations and multiple sequence alignments using Hidden Markov Models» (PFAM) [11], содержащий известные на данный момент последовательности аминокислот. Для эксперимента выбраны два признака: последовательность аминокислот и метка класса последовательности в наборе данных PFAM. Исходный набор данных содержит более 13 000 различных семейств аминокислот, поэтому для упрощения задачи и ввиду ограниченной производительности используемой ЭВМ, исходный набор данных разделен на наборы, содержащие 10 и 100 наиболее распространенных классов семейств белков.

Набор параметров каждой НФА изначально задан как $\alpha=0.9$, $P=1.0$, $N=0.0$. Обучение классификаторов проводилось в течение 25 обучающих эпох. Среднее время одной тренировочной эпохи для классификации на ста классах – 8 минут 24 секунды для РНС, 10 минут 50 секунд для РННК, 1 минута 34 секунды для СННК, 1 минута 33 секунды для СНС; среднее время одной тренировочной эпохи для классификации на десяти классах – 17 секунд для РНС, 30 секунд для РННК, 3 секунды для СННК, 3 секунды для СНС. В Таблице 1 и Таблице 2 приведены результаты обучения и проверки моделей классификаторов.

Таблица 1 – Точность классификации для десяти семейств белков

Table 1 – Classification accuracy for ten protein families

Точность, %			
Классификатор	Обучение	Промежуточная проверка	Проверка
РНС	78.56	78.14	76.15
РННК	86.41	84.76	84.10
СНС	68.45	68.55	69.53
СННК	77.19	77.65	75.41

Таблица 2 – Точность классификации для ста семейств белков

Table 2 – Classification accuracy for one hundred protein families

Точность, %			
Классификатор	Обучение	Промежуточная проверка	Проверка
РНС	45.44	40.70	43.27
РННК	51.98	49.24	50.53
СНС	66.97	64.30	67.55
СННК	70.70	65.36	69.07

Эксперимент 2. Классификация текстовых объектов.

В качестве таких объектов взяты отзывы пользователей на фильмы сети Интернет. Требуется произвести бинарную классификацию тональности текстов из набора текстов базы данных «Internet Movie Database» (IMDB) [12]. Набор параметров

каждой НФА изначально задан как $\alpha=0.9$, $P=1.0$, $N=0.0$. Обучение проводилось в течение 25 обучающих эпох, среднее время одной тренировочной эпохи – 10 СННК, 13 секунд для СНС. В Таблице 3 приведены результаты обучения и проверки моделей классификаторов.

Таблица 3 – Точность бинарной классификации пользовательских рецензий на фильмы из онлайн базы данных

Table 3 – Binary classification accuracy of the user reviews to the films from the online database

Точность, %			
Классификатор	Обучение	Промежуточная проверка	Проверка
PHC	78.32	73.24	74.53
PHNK	83.31	79.51	79.40
CHC	74.56	69.48	70.29
CHNK	83.57	75.24	76.48

Обсуждение (Discussion)

В Таблице 1, Таблице 2, Таблице 3 приведены показатели точности классификаторов при обучении, промежуточной проверке и тестировании. На основании полученных результатов отчетливо видно, что применение НФА позволяет добиться повышения точности классификации, при этом, за ограниченное число обучающих эпох.

В процессе обучения ННК параметры НФА изменяются и, соответственно, меняют форму кривой НФА. На Рисунке 7 и Рисунке 8 изображены графики НФА до начала обучения (пунктирная линия) и после завершения обучения (сплошная линия).

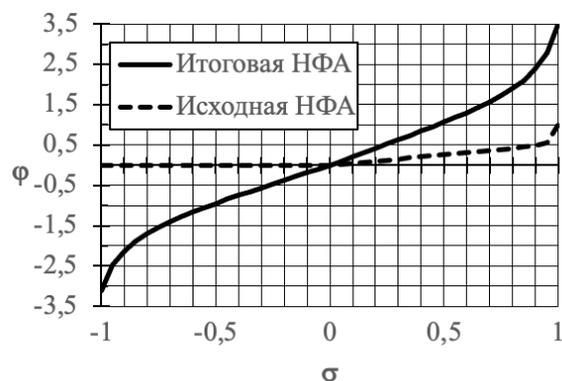


Рисунок 7 – График НФА второго нейрона в слое для итоговых значений параметров: $\alpha = 0,97$; $P = 3,55$; $N = 3,37$

Figure 7 – Graph of the NFA of the second neuron in the layer for the final values of the parameters $\alpha = 0,97$; $P = 3,55$; $N = 3,37$

На Рисунке 7 и Рисунке 8 видно, что параметры N и P имеют тенденцию к росту, при этом, на Рисунке 8 приведена ситуация, при которой величина параметра α вышла за обозначенные пределы $(-1;1)$ и область значений σ , в которой НФА остается дифференцируемой, уменьшается. Это негативно сказывается на эффективности ННК, но данная проблема может быть исправлена в ходе дальнейшей оптимизации параметров классификатора при большем числе обучающих эпох.

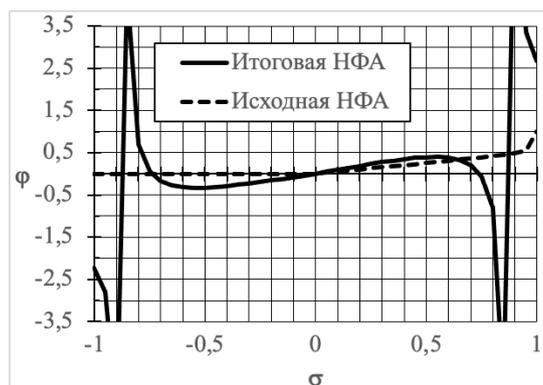


Рисунок 8 – График НФА восьмого нейрона в слое для итоговых значений параметров: $\alpha = 1,15$; $P = 2,66$; $N = 2,24$

Figure 8 – Graph of the NFA of the eighth neuron in the layer for the final values of the parameters $\alpha = 1,15$; $P = 2,66$; $N = 2,24$

Заключение (Conclusion)

В работе поставлена задача повышения эффективности нейросетевых моделей. Предложено применять аппарат теории нечетких множеств для разработки адаптивной функции активации искусственного нейрона. Предложена модификация нечеткой функции активации, использующая функцию гиперболического тангенса для нормализации ввода, и позволяющая повысить показатели точности классификаторов. Описана методика построения нейро-нечетких классификаторов с использованием интервальных нечетких множеств 2-го типа. Построены модели двух нейро-нечетких классификаторов – нейро-нечеткий рекуррентный классификатор и нейро-нечеткий сверточный классификатор. Проведены два эксперимента – классификация медико-биологических и текстовых объектов. По результатам экспериментов сделан вывод о том, что у нейро-нечетких классификаторов показатели точности выше, а значит нечеткие функции активации можно применять для повышения точности нейросетевых классификаторов.

СПИСОК ИСТОЧНИКОВ

1. Ломакина Л.С., Субботин А.Н. Классификация потоковых данных на основе байесовского критерия. *Моделирование, оптимизация и информационные технологии*. 2020;8(1). Доступно по: https://moit.vivt.ru/wp-content/uploads/2020/02/LomakinaSubbotin_1_20_1.pdf DOI: 10.26102/2310-6018/2020.28.1.034.
2. Sonoda S., Murata N. Neural network with unbounded activation functions is universal approximator. *Applied and Computational Harmonic Analysis*. 2017;43(2):233–268. DOI: 10.1016/j.acha.2015.12.005.
3. Кофман А. *Введение в теорию нечетких множеств*. М.: Радио и связь; 1982. 432 с.
4. Kumbasar T. Robust stability analysis and systematic design of single-input interval type-2 fuzzy logic controllers. *IEEE Transactions on Fuzzy Systems*. 2015;24(3):675–694. DOI: 10.1109/TFUZZ.2015.2471805.
5. Liang Q., Mendel J.M. Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on Fuzzy systems*. 2000;8(5):535–550. DOI: 10.1109/91.873577.

6. Beke A., Kumbasar T. Learning with type-2 fuzzy activation functions to improve the performance of deep neural networks. *Engineering Applications of Artificial Intelligence*. 2019;85:372–384. DOI: 10.1016/j.engappai.2019.06.016.
7. Greff K., Srivastava R.K., Koutník J., Steunebrink B.R., Schmidhuber J. LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*. 2016;28(10):2222–2232. DOI: 10.1109/TNNLS.2016.2582924.
8. Lomakina L.S., Surkova A.S., Zhevnerchuk D.V., Chernobaev I.D., et al. Conceptual modeling of heterogeneous data for geoinformation systems. *Proc. of the Thirteenth International MEDCOAST Congress on Coastal and Marine Sciences, Engineering, Management and Conservation (MEDCOAST 2019)*. 2019;1:77–89.
9. Ломакина Л.С., Чернобаев И.Д., Киселев Ю.Н. Алгоритмическое обеспечение нейронечеткой классификации состояний объектов сложной структуры. *Труды Международного научно-технического конгресса «Интеллектуальные системы и информационные технологии - 2021» («ИС & ИТ-2021», «IS&IT'21»)*. 2021;475–481.
10. Surkova A., Skorynin S., Chernobaev I. Word embedding and cognitive linguistic models in text classification tasks. *Proc. of the XI International Scientific Conference Communicative Strategies of the Information Society*. 2019;1–6. DOI: 10.1145/3373722.3373778
11. Mistry J., Chuguransky S., Williams L., Qureshi M., Salazar G.A., Sonnhammer E.L., Tosatto S.C., Paladin L., Raj S. Richardson L.J., Finn R.D. Pfam: The protein families database in 2021. *Nucleic Acids Research*. 2021;49(D1):D412–419. DOI: 10.1093/nar/gkaa913
12. Maas A., Daly R.E., Pham P.T., Huang D., Ng A.Y., Potts C. Learning word vectors for sentiment analysis. *Proc. of the 49th annual meeting of the association for computational linguistics: Human language technologies*. 2011;142–150.

REFERENCES

1. Lomakina L.S., Subbotin A.N. Stream data classification based on Bayesian criteria. *Modelirovaniye, optimizatsiya i informatsionnyye tekhnologii = Modeling, Optimization and Information Technology*. 2020;8(1). Available by: https://moit.vivt.ru/wp-content/uploads/2020/02/LomakinaSubbotin_1_20_1.pdf DOI: 10.26102/2310-6018/2020.28.1.034. (In Russ.)
2. Sonoda S., Murata N. Neural network with unbounded activation functions is universal approximator. *Applied and Computational Harmonic Analysis*. 2017;43(2):233–268. DOI: 10.1016/j.acha.2015.12.005.
3. Coffman A. *Introduction to Fuzzy Sets Theory*. Moscow: Radio and Communication; 1982. 432 p. (In Russ.)
4. Kumbasar T. Robust stability analysis and systematic design of single-input interval type-2 fuzzy logic controllers. *IEEE Transactions on Fuzzy Systems*. 2015;24(3):675–694. DOI: 10.1109/TFUZZ.2015.2471805.
5. Liang Q., Mendel J.M. Interval type-2 fuzzy logic systems: theory and design. *IEEE Transactions on Fuzzy systems*. 2000;8(5):535–550. DOI: 10.1109/91.873577.
6. Beke A., Kumbasar T. Learning with type-2 fuzzy activation functions to improve the performance of deep neural networks. *Engineering Applications of Artificial Intelligence*. 2019;85:372–384. DOI: 10.1016/j.engappai.2019.06.016.
7. Greff K., Srivastava R.K., Koutník J., Steunebrink B.R., Schmidhuber J. LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*. 2016;28(10):2222–2232. DOI: 10.1109/TNNLS.2016.2582924.

8. Lomakina L.S., Surkova A.S., Zhevnerchuk D.V., Chernobaev I.D., et al. Conceptual modeling of heterogeneous data for geoinformation systems. *Proc. of the Thirteenth International MEDCOAST Congress on Coastal and Marine Sciences, Engineering, Management and Conservation*. 2019;1:77–89.
9. Lomakina L.S., Chernobaev I.D., Kiselev Y.N. Algorithmic support of neuro-fuzzy classification of objects of complex structure. *Trudy Mezhdunarodnogo nauchno-tehnicheskogo 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;475–481. (In Russ.)
10. Surkova A., Skorynin S., Chernobaev I. Word embedding and cognitive linguistic models in text classification tasks. *Proc. of the XI International Scientific Conference Communicative Strategies of the Information Society*. 2019;1–6. DOI: 10.1145/3373722.3373778.
11. Mistry J., Chuguransky S., Williams L., Qureshi M., Salazar G.A., Sonnhammer E.L., Tosatto S.C., Paladin L., Raj S., Richardson L.J., Finn R.D. Pfam: The protein families database in 2021. *Nucleic Acids Research*. 2021;49(D1):D412–419. DOI: 10.1093/nar/gkaa913.
12. Maas A., Daly R.E., Pham P.T., Huang D., Ng A.Y., Potts C. Learning word vectors for sentiment analysis. *Proc. of the 49th annual meeting of the association for computational linguistics: Human language technologies*. 2011;142–150.

ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

Ломакина Любовь Сергеевна, доктор технических наук, профессор Нижегородского Государственного Технического Университета им. Р.Е. Алексеева, Нижний Новгород, Российская Федерация.

e-mail: llomakina@list.ru

Чернобаев Игорь Дмитриевич, аспирант Нижегородского Государственного Технического Университета им. Р.Е. Алексеева, Нижний Новгород, Российская Федерация

e-mail: ichernobnn@gmail.com

Liubov S. Lomakina, Doctor Of Technical Science, Professor of Nizhny Novgorod State Technical University n.a. R.E. Alekseev, Nizhny Novgorod, Russian Federation

Igor D. Chernobaev, graduate student of Nizhny Novgorod State Technical University n.a. R.E. Alekseev, Nizhny Novgorod, Russian Federation

Статья поступила в редакцию 26.11.2021; одобрена после рецензирования 22.12.2021; принята к публикации 27.12.2021.

The article was submitted 26.11.2021; approved after reviewing 22.12.2021; accepted for publication 27.12.2021.