

443086, Russian Federation; Associated Professor of Information Systems and Technologies Department. Tel. +7 927 654-29-33. E-mail: op-soldatova@yandex.ru

References

1. Wang K., Liu M. YOLO-Anti: YOLO-Based counterattack model for unseen congested object detection. *Pattern recognition*, 2022, vol. 131, pp. 108814.
2. ZHornartkyzy G., Tleudin E.A. Fast R-CNN object recognition algorithm. *Internauka*, 2022, no.18-1(241), pp. 56–58. (In Russ.)
3. Abdulghafoor N.H., Abdullah H.N. Real-time moving objects detection and tracking using deep-stream technology. *Journal of Engineering Science and Technology*, 2021, vol. 16, no. 1, pp. 194–208.
4. Murthy Ch.B., Hashmi M.F., Keskar A.G. Optimized MobileNET + SSD: a real-time pedestrian detection on a low-end edge device. *International Journal of Multimedia Information Retrieval*, 2021, vol. 10, no. 3, pp. 171–184.
5. Deng P., Wang K., Han X. Real-time object detection based on YOLO-V2 for tiny vehicle object. *SN Computer Science*, 2022, vol. 3, no. 4, pp. 1–10.
6. Utkin L.V. *Decision Making under Uncertainty*. Saint Petersburg: SPbPU, 2014, 199 p. (In Russ.)
7. Boosting, AdaBoost. URL: https://neerc.ifmo.ru/wiki/index.php?title=%D0%91%D1%83%D1%81%D1%82%D0%B8%D0%BD%D0%B3,_AdaBoost (accessed: 01.11.2023). (In Russ.)
8. Belyh E.A. Training Haar cascades. *Vestnik Syktyvskarskogo universiteta. Seriya: Matematika. Mekhanika. Informatika*. URL: <https://cyberleninka.ru/article/v/obuchenie-kaskadov-haara> (accessed: 01.11.2023). (In Russ.)
9. AdaBoost – Wikipedia. URL: <https://ru.wikipedia.org/wiki/AdaBoost> (accessed: 01.11.2023) (In Russ.)
10. Kazantseva I.S., Soldatova O.P. Solving the problem of image detection using cascade classifiers. *Perspektivnye informacionnye tekhnologii (PIT–2019): materialy Mezhdunarodnoj nauchno-tekhnicheskoy konferencii*. Samara: Izd-vo SNTs RAN, 2019, pp.256–260. (In Russ.)
11. Bolotova U.A., Fedotova L.S., Spicyn V.G. Algorithm for detecting areas of faces and hands in an image based on the Viola-Jones method and color segmentation algorithm. *Fundamental'nye issledovaniya*, 2014, no. 11-10, pp. 2130–2134. URL: <https://fundamental-research.ru/ru/article/view?id=35905> (accessed: 01.11.2023) (In Russ.)

Received 08.11.2023

УДК 004.89

ПРИМЕНЕНИЕ МОДЕЛЕЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В ПРИЕМО-СДАТОЧНЫХ ИСПЫТАНИЯХ

Тарасов А.А., Лезина И.В.

Самарский национальный исследовательский университет имени академика С.П. Королева, Самара, РФ
E-mail: tarasov.aa.1@ssau.ru, lezina.iv@ssau.ru

Данная статья рассматривает применение нейросетевых методов, а именно нечеткого персептрона, в задачах, требующих проведение приемо-сдаточных испытаний. Было проведено исследование по использованию различных нечетких функций при решении задачи аппроксимации плотностей вероятностей. Эксперименты проведены на временных рядах с известными законами распределения, с оценкой качества аппроксимации через среднеквадратичное отклонение в серии из 29 испытаний. В результате исследований при использовании Гауссовой функции принадлежности было получено среднее значение среднеквадратического отклонения равное 00145, что подтверждает хорошие аппроксимативные способности нечеткого персептрона. Система была протестирована на данных приемо-сдаточных испытаний двигателя газоперекачивающих агрегатов. В этом случае оценка качества аппроксимации проводилась с использованием критерия согласия Колмогорова-Смирнова. Результаты анализа подтверждают высокую аппроксимативную способность нечеткого персептрона, подчеркивая его применимость в реальных приемо-сдаточных испытаниях.

Ключевые слова: нейронные сети, нечеткие функции, аппроксимация, приемо-сдаточные испытания, C-Means, нечеткий персептрон, плотность распределения вероятности

Введение

В современном мире статистические методы анализа данных являются важным шагом в научных исследованиях. Не умаляя достоинств теоретических методов исследования, значение экспериментальных методов трудно переоценить. Только с помощью эксперимента возможно получение достоверной информации об исследуемом объекте в реальном масштабе времени, после обработки которой возможно построение ее модели [1].

В различных научных исследованиях возникает необходимость определения параметров случайного процесса, дающих его исчерпывающее описание. На практике для их получения требуется решить задачу аппроксимации, позволяющую на основе имеющихся данных получить функцию, описывающую случайный процесс [2]. Задача аппроксимации плотности распределения вероятностей является важной, так как во многих прикладных задачах выдвигается гипотеза о распределении статистического ряда, которую необходимо проверить.

В данной работе рассматривается применение методов аппроксимации в задачах приемо-сдаточных испытаний.

Использование аппроксимации в данных задачах позволяет:

- анализировать данные для более точных оценок измерений, особенно в случае ограниченного набора данных или наличия шума;
- производить моделирование данных с целью прогнозирования поведения системы;
- уменьшить количество необходимых испытаний и измерений, что позволит сократить время и затраты на проведение приемо-сдаточных испытаний.

Обзор методов аппроксимации

Как показано в [3], методы аппроксимации можно разделить на два класса:

1. Параметрические методы аппроксимации.
2. Методы непараметрической статистики.

Применение методов из первой группы основано на гипотезе о конкретном виде функции плотности распределения. Для оценки параметров функции применяется, например, метод максимального правдоподобия [2]. Стоит отметить, что на практике бывает затруднительно проверить гипотезу о принадлежности выборки конкретному распределению, что делает невоз-

можным применение методов параметрической аппроксимации.

Этого недостатка лишены методы второй группы. К ним можно отнести следующие алгоритмы [2]:

- аппроксимация сплайнами;
- аппроксимация ортогональными полиномами;
- ядерная оценка.

Общим недостатком этих оценок является то, что при построении модели не учитываются условия нормировки и неотрицательности полученной оценки. Это приводит к тому, что аппроксимирующее выражение может не являться плотностью распределения [4]. Также к недостаткам стоит отнести невозможность оценить параметры аппроксимируемой плотности.

Нейросетевая аппроксимация

Еще одним методом непараметрической статистики является использование нейронной сети в качестве универсального аппроксиматора. Корректность данной оценки следует из теоремы Хета-Нильсена о представимости любой многомерной функции нескольких переменных с помощью нейронной сети фиксированной размерности [5]. Таким образом, любую сложную функцию можно заменить более простой нейросетевой аппроксимацией, причем требуется только нелинейность функции активации нейрона.

Аппроксимирующие нейронные сети обладают целым рядом преимуществ по сравнению с другими способами аппроксимации:

- нейронные алгоритмы имеют потенциал для распараллеливания процесса обработки информации одновременно между всеми нейронами, что приводит к многократному ускорению работы нейронной сети;
- благодаря большому количеству нейросетевых соединений, сеть становится нечувствительной к ошибкам, возникающим в отдельных нейронах в процессе аппроксимации;
- нейросетевые модели позволяют добиться меньшей ошибки аппроксимации по сравнению с другими методами непараметрической статистики [4];
- оценка плотности вероятности является более гладкой, чем при использовании сплайнов и ортогональных полиномов.

Однако нейронные сети также не лишены ряда недостатков. Во-первых, для них также не выполняются условия нормировки и неотрица-

тельности. Во-вторых, аппроксимирующее выражение является в разы более сложным, чем при использовании полиномов.

Также для получения качественной модели необходимо подобрать параметры нейронной сети, что является сугубо эвристическим действием, не зависящим от определенной математической формулы.

Подготовка данных

Для построения оценки плотности распределения вероятности необходимо произвести первичное оценивание, построив гистограмму наблюдаемого статистического ряда, и выделить на ней точки $\{x_i, y_i\}, i = \overline{1, M}$, где M – число дифференциальных коридоров гистограммы, которые и будут входить в выборку данных. Для построения гистограммы в данной работе используется алгоритм, предложенный в [2].

В процессе обучения и работы на вход нейронной сети подается значение, равное координате середины интервала гистограммы плотности вероятности, а на выходе сети должно получиться значение, соответствующее ординате гистограммы в данной точке.

Нечеткий персептрон

В данной работе для решения задачи аппроксимации предлагается использовать модель нечеткого персептрона. Для данного типа сети сформулирована теорема об универсальной аппроксимации, которая утверждает, что любая непрерывная функция на замкнутом интервале может быть представлена сходящимся рядом полиномов [5].

В случае нечеткого персептрона достаточно одного скрытого слоя для построения равномерной аппроксимации с заданной точностью для любого обучающего множества, представленного набором обучающих пар. Однако теорема не утверждает, что использование одного скрытого слоя дает оптимальные результаты в плане сходимости и скорости работы алгоритма.

Структура нечеткого персептрона, представленная на рисунке 1, является гибридной и объединяет в себе сеть с нечеткой организацией и многослойный персептрон.

Использование гибридной архитектуры оправдано тем фактом, что при использовании гибридной сети задача разделяется на два независимых этапа, реализуемых отдельно друг от друга: этап фуззификации и этап работы многослойного персептрона (постпроцессора), приписывающего

каждой группе кластеров соответствующий ей результат.




Рисунок 1. Структура нечеткого персептрона

Использование препроцессора, размерность которого больше размерности входного вектора, обосновывается теоремой Ковера о разделимости образов. В ней утверждается, что преобразование задачи классификации в пространство более высокой размерности повышает вероятность линейной разделимости образов. Это позволяет подавать на вход многослойного персептрона уже откластеризованные данные [6].

Постпроцессор в виде многослойного персептрона осуществляет перевод коэффициентов принадлежности точки множествам кластеризации в оценку плотности вероятности в данной точке.

Аппроксимирующее выражение для нечеткого персептрона можно представить в виде:

$$y(x) = f\left(\sum_{i=1}^K w_{iout} f\left(\sum_{j=1}^n w_{ji} \varphi(x, c_j, \sigma_j)\right)\right), \quad (1)$$

где K – количество нейронов в персептронном слое;

x – координата середины интервала гистограммы;

w_{iout}, w_{ji} – значения весов;

n – количество нечетких нейронов;

φ – нечеткая функция;

f – функция активации персептронного слоя;

c_j, σ_j – значения параметров нечеткой функции.

Нечеткие функции

Ниже представлены нечеткие функции, используемые в данной работе.

Гауссова функция:

$$\varphi(x, c, \sigma) = \exp\left(-\frac{(x-c)^2}{2\sigma^2}\right). \quad (2)$$

Функция Епанечникова [9]:

$$\varphi(x, c, \sigma) = \frac{3}{4} \left(1 - \frac{(x-c)^2}{\sigma^2}\right). \quad (3)$$

Сигмоидальная функция:

$$\varphi(x, c, \sigma) = \frac{2}{\pi} \frac{1}{\exp\left(\frac{(x-c)^2}{2\sigma^2}\right) + \exp\left(-\frac{(x-c)^2}{2\sigma^2}\right)}. \quad (4)$$

Алгоритмы обучения нечеткого персептрона

Алгоритм обучения нечеткого персептрона носит двухэтапный характер. Первым этапом является определение параметров нечетких нейронов. После выполнения данного шага значения параметров замораживаются и начинается обучение многослойного персептрона.

Обучение нечеткого персептрона требует определения центров нечеткой функции. В данной работе используется алгоритм C-Means [7]. Для некоторых функций также требуется параметр ширины. В разработанной системе для этого используется метод Р-ближайших соседей [8].

Для обучения многослойного персептрона применялся алгоритм обратного распространения ошибки. Минимизировалась метрика MSE.

Исследование по аппроксимации плотностей распределения вероятностей

После обучения нейронной сети необходимо оценить качество полученного нейросетевого решения задачи аппроксимации.

С этой целью были сгенерированы временные ряды, подчиняющиеся заранее известным законам распределения вероятностей. Было проведено исследование по аппроксимации плотностей веро-

ятностей при помощи различных нечетких функций [10]. Качество аппроксимации оценивалось при помощи среднеквадратичного отклонения (СКО). Проводилась серия из 29 испытаний. В таблице 1 представлены максимальные значения СКО.

Тестирование проводилось на следующих параметрах нейронной сети:

- обучающие выборки построены по 10000 отсчетам;
- тестовая выборка с аналогичными характеристиками;
- коэффициент обучения – 0.03;
- функция активации многослойного персептрона – логистическая с параметром 5;
- число дифференциальных коридоров гистограммы – 15;
- число нейронов в нечетком слое – 12;
- число нейронов в многослойном персептроне – 15.

На основании данных из таблицы 1 мы можем сделать вывод, что нечеткий персептрон обладает хорошими аппроксимативными способностями. В среднем наилучшие результаты были получены при помощи нечеткой Гауссовой функции.

Исследование по аппроксимации плотностей распределения вероятностей данных прямо-сдаточных испытаний

Система была апробирована на данных прямо-сдаточных испытаний двигателя газоперекачивающих агрегатов. Так как распределение вероятности данных в данном случае нам неизвестно, для оценки качества аппроксимации использовался критерий согласия Колмогорова-Смирнова. Данный критерий используется для проверки гипотезы об однородности двух рассматриваемых выборок. В нашем случае сравниваются распределение вероятности реальных данных и выхода нейронной сети [11].

Для данной задачи использовалась конфигурация нейронной сети аналогичная той, что была

Таблица 1. Зависимость СКО аппроксимации нечетким персептроном от вида нечеткой функции

Закон распределения вероятностей	Нечеткая функция		
	Гауссова функция	Функция Епанечникова	Сигмоидальная функция
Нормальный	0,0005	0,0268	0,0016
Экспоненциальный	0,0026	0,0098	0,0045
Лапласа	0,003	0,0163	0,0014
Вейбулла	0,0009	0,0082	0,0025
Релэя	0,0012	0,0084	0,0016
Арсинусоидальный	0,0005	0,0011	0,0055

в прошлом эксперименте с нечеткой Гауссовой функцией.

Результаты анализа представлены на рисунках 2–4 и в таблице 2.

На основании полученных данных мы можем сделать вывод, что нечеткий персептрон обладает хорошими аппроксимативными способностями.




Рисунок 2. Сравнение эталона и выхода сети. Данные «Обороты компрессора высокого давления»




Рисунок 3. Сравнение эталона и выхода сети. Данные «Обороты компрессора низкого давления»




Рисунок 4. Сравнение эталона и выхода сети. Данные «Обороты свободной турбины»

Таблица 2. Критерий Колмогорова-Смирнова для данных прямо-сдаточных испытаний

Данные	Критерий Колмогорова-Смирнова
Обороты компрессора высокого давления	0.0003
Обороты компрессора низкого давления	0.0007
Обороты свободной турбины	0.0005

Заключение

В данной работе было описано использование нейросетевых методов в задачах аппроксимации плотностей распределения вероятностей. Были проведены эксперименты по подтверждению корректности результатов, а также исследование по выбору оптимальной нечеткой функции. Проведенные исследования показали корректность применения нечеткого персептрона в задачах аппроксимации.

Литература

1. Прохоров С.А., Куликовских И.М. Численные методы, алгоритмы и комплексы программ для проведения вычислительного и натурного экспериментов. Самара: Инсома-пресс, 2019. 208 с.
2. Прохоров С.А. Аппроксимативный анализ случайных процессов. Самара: СНЦ РАН, 2001. 380 с.
3. Терехов С.А. Нейросетевые аппроксимации плотности распределения вероятности в задачах информационного моделирования // Нейроинформатика–2002: материалы Всероссийской научно-технической конференции. М.: МИФИ, 2002. С. 94–120.
4. Лезина И.В. Аппроксимативный анализ законов распределения ортогональными полиномами и нейросетевыми моделями: дис. ... канд. техн. наук. Самара, 2012. 108 с.
5. Хайкин С. Нейронные сети: 2-е изд., исправленное; пер. с англ. М.: ООО «И.Д. Вильямс», 2006. 1104 с.
6. Осовский С. Нейронные сети для обработки информации / пер. с польск. И.Д. Рудинского. М.: Финансы и статистика, 2002. 344 с.
7. Bezdek J.C., Ehrlich R., Full W. FCM: The fuzzy c-means clustering algorithm // Computers and geosciences. 1984. Vol.10, no. 2–3. P. 191–203.
8. Tarasenko L. Supervised and unsupervised learning in radial basis function classifiers // IEEE Proceedings – Vision, Image and Signal Processing. 1994. no. 4. P. 210–216.

9. Дьерфи Л., Деврой Л. Непараметрическое оценивание плотности. L1-Подход / пер с англ. А.Б. Цыбакова. М.: Мир, 1988, 408 с. материалы международной научно-технической конференции. Самара: Изд-во СНЦ РАН, 2020. С. 61–63.
 10. Тарасов А.А., Лезина И.В. Исследование аппроксимативных возможностей нечеткого персептрона при использовании различных ядерных функций // Перспективные информационные технологии (ПИТ–2020): 11. Колмогоров А.Н. Теория вероятностей и математическая статистика. М.: Наука, 1986. 535 с.
- Получено 07.11.2023*

Тарасов Артем Алексеевич, аспирант кафедры информационных систем и технологий (ИСТ) Самарского национального исследовательского университета имени С.П. Королева (Самарский университет). 443086, Российская Федерация, г. Самара, ул. Московское шоссе, 34. Тел. +7 927 745-18-36. E-mail: tarasov.aa.1@ssau.ru

Лезина Ирина Викторовна, доцент кафедры ИСТ Самарского университета. 443086, Российская Федерация, г. Самара, ул. Московское шоссе, 34. Тел. +7 927 209-96-02. E-mail: lezina.iv@ssau.ru

USE OF ARTIFICIAL INTELLIGENCE MODELS IN ACCEPTANCE TESTS

Tarasov A.A., Lyozina I.V.

Samara National Research University, Samara, Russian Federation

E-mail: tarasov.aa.1@ssau.ru, lezina.iv@ssau.ru

This paper describes the application of fuzzy perceptron in acceptance testing problems. A study on the use of various fuzzy functions in solving the problem of approximation of probability densities was carried out. Experiments were conducted on time series with preset distribution laws, evaluating approximation quality using standard deviation in the series of 29 tests. As a result of the research, using Gaussian fuzzy function, the mean value of standard deviation equal to 0.00145 determined which confirms good approximative ability of the fuzzy perceptron. The system was tested on the acceptance test data of the gas compressor engine. In this case, approximation quality was assessed using the Kolmogorov-Smirnov agreement criterion. Analysis results confirm the high approximative ability of the fuzzy perceptron, emphasizing its applicability in real acceptance tests.

Keywords: *neural networks, fuzzy function, approximation, acceptance tests, C-Means, fuzzy perceptron, probability density*

DOI: 10.18469/ikt.2023.21.2.09

Tarasov Artyom Alekseevich, Samara National Research University, 34, Moskovskoe shosse, Samara, 443086, Russian Federation; PhD Student of Information Systems and Technologies Department. Tel. +7 927 745-18-36. E-mail: tarasov.aa.1@ssau.ru

Lyozina Irina Viktorovna, Samara National Research University, 34, Moskovskoe shosse, Samara, 443086, Russian Federation; Associate Professor of Information Systems and Technologies Department. Tel. +7 927 209-96-02. E-mail: lezina.iv@ssau.ru

References

1. Prokhorov S.A., Kulikovskih I.M. *Numerical Methods, Algorithms, and Software Complexes for Conducting Computational and Experimental Studies*. Samara: Insoma-press, 2019, 208 p. (In Russ.)
2. Prokhorov S.A. *Approximative Analysis of Stochastic Processes*. Samara: SNTs RAN, 2001, 380 p. (In Russ.)
3. Terekhov S.A. Neural Network Approximations of Probability Density in Information Modeling Tasks. *Nejroinformatika–2002: materialy IV Vserossiyskoy nauchno-tekhnicheskoy konferencii*. Moscow: MIFI, 2002, pp. 94–120. (In Russ.)

4. Lyozina I.V. Approximative Analysis of Distribution Laws with Orthogonal Polynomials and Neural Network Models: diss. ... cand. tech. sciences. Samara, 2012, 108 p. (In Russ.)
5. Hajkin S. *Neural Networks*: 2nd Ed., recycled. Transl. From English. Moscow: ООО «I.D. Vil'yams», 2006, 1104 p. (In Russ.)
6. Osovskij S. *Neural Networks for Information Processing*. Transl. From Poland. Moscow: Finansy i statistika, 2002, 344 p. (In Russ.)
7. Bezdek J.C., Ehrlich R., Full W. FCM: The fuzzy c-means clustering algorithm. *Computers and geosciences*, 1984, vol.10, no. 2–3, pp. 191–203.
8. Tarasenko L. Supervised and unsupervised learning in radial basis function classifiers. *IEEE Proceedings – Vision, Image and Signal Processing*, 1994, no. 4, pp. 210–216.
9. Györfi L., Devroye L. *Nonparametric Density Estimation: The L1-View*. Transl. From English. Moscow: Mir, 1988, 408 p. (In Russ.)
10. Tarasov A.A., Lyozina I.V. A study of the approximative capabilities of a fuzzy perceptron using various kernel functions. *Perspektivnye informacionnye tekhnologii (PIT–2020): materialy mezhdunarodnoj nauchno-tekhnicheskoj konferencii*. Samara: Izd-vo SNTs RAN, 2020, pp. 61–63. (In Russ.)
11. Kolmogorov A.N. *Theory of Probability and Mathematical Statistics*. Moscow: Nauka, 1986, 535 p. (In Russ.)

Received 07.11.2023

УДК 519.876.5

ВЫБОР И ОБОСНОВАНИЕ РАСПОЛОЖЕНИЯ КАМЕР СИСТЕМЫ КРУГОВОГО ОБЗОРА НА БЕСПИЛОТНЫЙ КАРЬЕРНЫЙ САМОСВАЛ

Сыркин И.С., Дубинкин Д.М., Садовец В.Ю.

Кузбасский государственный технический университет имени Т.Ф. Горбачева, Кемерово, РФ.

E-mail: syrkin@kuzstu.ru

Выбор места установки оборудования на бортах беспилотного транспортного средства, а особенно такого как карьерный самосвал, является сложной задачей, которая решает, как правило интуитивно и методом натурного моделирования. Авторы статьи решили сформулированную задачу по обоснованию выбора мест расстановки сенсорики на карьерном самосвале, используя разработанное специализированное программное приложение. Инструментом для проведения исследований был выбран симулятор Carla simulator, как обладающий широкими возможностями по визуализации окружающего мира. На начальном этапе выбора расположения расстановки камер, были сформулированы требования к углам их обзора и качеству получаемого от них изображения. Это потребовало разработки программного приложения на языке Python с использованием библиотеки Open3D, выбор которого обоснован тем, что симулятор Carla simulator предоставляет доступ к своему API (Application Programming Interface) через библиотеку для этого языка, а также потому, что он позволяет быстро создавать прототипы приложений. Разработанное программное приложение помогает пользователю выбрать расположение видеокамер на карьерном самосвале для очувствления системы беспилотного управления. Дальнейшие исследования направлены на автоматизацию выбора точек установки видеокамер на борту беспилотного карьерного самосвала.

Ключевые слова: система кругового обзора, карьерный самосвал, сенсор, симулятор

Введение

Разработкой беспилотных транспортных средств в настоящее время занимаются ведущие производители, как в области автомобилестроения, так и в направлении информационных технологий. Беспилотные транспортные средства, предназначены для повышения безопасности перемещения по дорогам общего пользования, а также по пересеченной местности, в сложных климатических условиях и в условиях добычи полезных

ископаемых открытым способом [1–5]. Создание беспилотного транспорта требует установки на него большого количества дополнительного оборудования – датчиков и вычислительных блоков, которые способны принимать решения по управлению транспортным средством, в зависимости от дорожной обстановки. К первой группе оборудования относятся радары, лидары, камеры, ко второй – вычислительные блоки на базе персональных компьютеров, промышленных компьютеров и прочих [6–7].