

Раздел I. Алгоритмы обработки информации

УДК 004.942, 654.924.56

DOI 10.18522/2311-3103-2024-6-6-15

С. Сингх, А.В. Прибыльский

КЛАССИФИКАЦИИ ПОЖАРООПАСНЫХ СИТУАЦИЙ НА ОСНОВЕ СЕТИ КОЛМОГОВОРА-АРНОЛЬДА

Проблема своевременного и точного обнаружения пожароопасных ситуаций является критически важной для обеспечения безопасности людей и сохранения имущества. Традиционные методы мониторинга, основанные на простых пороговых значениях для датчиков дыма и температуры, часто недостаточно эффективны, так как могут приводить к ложным срабатываниям или пропуску реальных пожароопасных ситуаций. Современные методы, использующие нейронные сети, позволяют значительно повысить точность классификации нештатной ситуации за счет анализа комплексных паттернов в данных с датчиков, представляющих из себя сложные нелинейные функции с динамически изменяющимися параметрами. Разработка таких моделей требует внимания к сбору, разметке и обработке данных, к выбору архитектуры нейронной сети для конкретной задачи, потому как качественная разметка данных и выбор желаемой архитектуры нейронной сети, напрямую влияет на выделение искомым паттернов, а также нахождение скрытых паттернов, которые невозможно или затруднительно определить традиционными методами. В статье исследуется алгоритм классификации пожароопасных ситуаций, основанный на сети Колмогорова-Арнольда (KAN). Данный алгоритм применяется для обработки данных с комплекса взаимосвязанных пожарных датчиков и предназначен для обнаружения и классификации различных типов пожароопасных ситуаций. Ключевым элементом разработки является использование сети Колмогорова-Арнольда, которая благодаря своей архитектуре способна моделировать сложные функциональные зависимости между входными данными. В качестве входных данных используются показания с комплекса взаимосвязанных пожарных датчиков, таких как датчики температуры, дыма. Для повышения точности классификации проводится разметка данных с использованием экспертных знаний. Для реализации алгоритма использовался язык программирования Python, совместно с библиотеками Pytorch, pykan, scikit-learn. В статье приводятся результаты тестирования модели на реальных данных и обсуждаются возможные направления для дальнейшего улучшения алгоритма. В ходе экспериментов было показано, что предложенная модель демонстрирует высокую точность классификации пожароопасных ситуаций, которая не уступает традиционным методам классификации данных.

Пожарный датчик; Python; нейронные сети; классификация; моделирование; разметка данных; сеть Колмогорова-Арнольда; KAN; парсинг.

S. Singh, A.V. Pribylskiy

ALGORITHM FOR CLASSIFICATION OF FIRE HAZARDOUS SITUATIONS BASED ON KOLMOGOROV-ARNOLD NETWORK

The problem of timely and accurate detection of fire hazardous situations is critical to ensure the safety of people and property. Traditional monitoring methods based on simple threshold values for smoke and temperature sensors are often insufficiently effective, as they can lead to false alarms or miss real fire hazardous situations. Modern methods using neural networks can significantly improve the accuracy of classifying an emergency situation by analyzing complex patterns in sensor data, which are complex non-linear functions with dynamically changing parameters. The development of such models requires attention to the collection, labeling and processing of data, to the choice of neural network architecture for a specific task, because high-quality data labeling and the choice of the desired neural network architecture directly affect the selection of the desired patterns, as well as the detection of hidden patterns that are impossible or difficult to determine by traditional methods. The article examines an algorithm for classify-

ing fire hazardous situations based on the Kolmogorov-Arnold network (KAN). This algorithm is used to process data from a complex of interconnected fire sensors and is designed to detect and classify various types of fire hazardous situations. The key element of the development is the use of the Kolmogorov-Arnold network, which, due to its architecture, is capable of modeling complex functional dependencies between input data. Readings from a complex of interconnected fire sensors, such as temperature and smoke sensors, are used as input data. To improve the accuracy of classification, data is labeled using expert knowledge. The Python programming language was used to implement the algorithm, together with the Pytorch, pykan, and scikit-learn libraries. The article presents the results of testing the model on real data and discusses possible directions for further improvement of the algorithm. During the experiments, it was shown that the proposed model demonstrates high accuracy in classifying fire hazardous situations, which is not inferior to traditional methods of data classification.

Fire sensor; Python; neural network; classification; modeling; data markup; Kolmogorov-Arnold Network; parsing.

Введение. Обеспечение своевременного и точного обнаружения пожароопасных ситуаций является важной задачей, обеспечивающей защиту жизни людей и сохранения имущества. В последние годы все больше внимания уделяется современным методам, использующим нейронные сети, которые способны значительно повысить точность классификации путем анализа сложных паттернов в данных с датчиков. Эти паттерны представляют собой нелинейные функции с динамически изменяющимися параметрами, которые трудно обнаружить с помощью традиционных методов.

Важным аспектом разработки и применения моделей классификации является процесс сбора, разметки и обработки данных, а также выбор оптимальной архитектуры нейронной сети для конкретной задачи. Качественная разметка данных и правильный выбор архитектуры сети играют важную роль в выявлении искомых паттернов и обнаружении скрытых закономерностей, которые не могут быть выявлены традиционными методами.

В работе рассматривается модель сети Колмогорова-Арнольда (KAN) [1, 2] для классификации пожароопасных ситуаций, данные для обучения которой получены с комплекса взаимосвязанных датчиков. Сеть Колмогорова-Арнольда благодаря своей уникальной, инновационной архитектуре способна моделировать сложные функциональные зависимости между параметрами объекта классификации, тем самым не только повышая точность обнаружения пожаров, но и предоставляя понятную и интерпретируемую модель классификации.

Цель исследования заключается в оценке пригодности сети Колмогорова-Арнольда (KAN) для задачи классификации пожароопасных ситуаций на основе полученных и заданных параметров точности.

Описание объекта исследования. Кратко описания пожарного датчика. Объектом исследования являются показания 36000 датчиков сверххранного обнаружения пожара (комплекс взаимосвязанных пожарных датчиков) [3–5], полученные в процессе их эксплуатации, а также информация об отказах с 2018- по 2023 гг., методы и средства их обработки, методы классификация [6] на основе KAN модели, RNN модели, модели Random forest, модели Optimization tree..

Конструктивно датчик состоит из 6 датчиков температуры средней инерционности, 1 датчика температуры большой инерционности, 1 быстродействующая температурного датчика, 3 датчика инфракрасного спектра обнаружения дыма и 3 датчиков ультрафиолетового канала, всего получается 8 информационных каналов по показанием температура и 6 каналов по показаниям дыма. Наличие температурных датчиков разной инерционности, позволяет подробно отслеживать динамику изменения температуры, даже при её кратковременных изменениях. Датчики обнаружения дыма расположены таким образом и в таком количестве для обнаружения дыма в угле 360 вокруг себя, что значительно увеличивает скорость обнаружения дыма, для сравнения классические датчики обладают чувствительность от 30 до 90 градусов [7–11], что значительно увеличивает время их срабатывания при возникновению пожароопасной ситуации по каналу задымленности.

Архитектура KAN модели. Архитектура KAN модели классификации пожароопасных ситуаций приведена на рис. 1 [1, 2].

Исходя из математической модели, приведенной в статье [5], а также выбранных входных и выходных параметров [6], архитектура KAN включает 5 входов, 11 выходов, а также выбранное в ходе экспериментов количество внутренних узлов равное 11. Количество входов соответствует количеству параметров комплекса пожарных датчиков используемых для анализа текущего временного отсчета для дальнейшей классификации. Количество выходов, соответствует количеству выделенных классов пожароопасных ситуаций, подробная расшифровка каждого класса представлена в работе [6].




Рис. 1. Архитектура KAN модели классификации пожароопасных ситуаций

На рис. 1 x_1 - x_5 – входные параметры сети, s_1 - s_{11} – внутренние сумматоры, s'_1 - s'_{11} – выходные сумматоры, y_1 - y_{11} – выходы

В отличие от классической основы MLP [12–15] архитектура KAN не имеет обучаемых весов на ребрах сети, вместо них KAN использует обучаемые функции активации, такой подход связан с используемой математикой, включая теорему аппроксимации Колмогорова-Арнольда, что позволяет также лучше интерпретировать получаемые результаты обучения. Количество обучаемых функций активации для каждого входного узла соответствует количеству выходов сети. Внутренний сумматор, суммирует все выходы с обучаемых функций активаций передавая их во внутренние узлы сети. После чего внутренние узлы снова разделяет узел на 11 обучаемых функций активации суммирует их, в результате чего получают выходы y_1 - y_{11} . Значения каждого выхода будут характеризовать принадлежность текущей комбинации входов к каждому из выделенных классов (выходов y_1 - y_{11}), в данном случае, чем больше значение выхода, тем более высокая вероятность принадлежности к данному классу пожароопасной ситуации.

Алгоритм парсинга данных. Парсинг данных является одним из важнейших этапов обработки данных для дальнейшего использования с целью решения определенной задачи, например классификации нештатных ситуаций [16, 17]. Стоит отметить, что в зависимости от формата и структуры получаемых данных из базы данных мест установки пожарных датчиков, должны использоваться разные этапы парсинга, потому как конечная цель парсинга получения данных в едином формате для используемой модели нейронной сети. В случае с пожарным датчиком данных в зависимости от места установки могут быть переданы в формате матриц $m \times n$, представленных на рис. 2 и 3.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	
1	time	name	optic_1	optic_2	tpt	tcpu	smokelevel	zasvetka	flags	safactions	f_talrm	f_tfire	f_dtalrm	f_dtfire	f_disp_alarm	f_disp_fier	f_alarm	f_fire
2	14.01.2024 0:00	1181-4	53118	49902	22.27	25	1	157	0	0	0	0	0	0	0	0	0	0
3	14.01.2024 0:00	1181-4	53118	49902	22.27	25	1	157	0	0	0	0	0	0	0	0	0	0
4	14.01.2024 0:00	1181-4	53118	49900	22.28	25	4	154	0	0	0	0	0	0	0	0	0	0
5	14.01.2024 0:00	1181-4	53118	49900	22.28	25	4	154	0	0	0	0	0	0	0	0	0	0
6	14.01.2024 0:00	1181-4	53115	49898	22.27	25	13	157	0	0	0	0	0	0	0	0	0	0
7	14.01.2024 0:00	1181-4	53115	49898	22.27	25	13	157	0	0	0	0	0	0	0	0	0	0
8	14.01.2024 0:00	1181-4	53116	49900	22.27	25	5	157	0	0	0	0	0	0	0	0	0	0
9	14.01.2024 0:00	1181-4	53116	49900	22.27	25	5	157	0	0	0	0	0	0	0	0	0	0
10	14.01.2024 0:00	1181-4	53119	49903	22.27	25	18	156	0	0	0	0	0	0	0	0	0	0
11	14.01.2024 0:00	1181-4	53119	49903	22.27	25	18	156	0	0	0	0	0	0	0	0	0	0
12	14.01.2024 0:00	1181-4	53121	49901	22.27	25	8	155	0	0	0	0	0	0	0	0	0	0
13	14.01.2024 0:00	1181-4	53121	49901	22.27	25	8	155	0	0	0	0	0	0	0	0	0	0
14	14.01.2024 0:00	1181-4	53120	49902	22.27	25	2	156	0	0	0	0	0	0	0	0	0	0
15	14.01.2024 0:00	1181-4	53120	49902	22.27	25	2	156	0	0	0	0	0	0	0	0	0	0
16	14.01.2024 0:00	1181-4	53121	49903	22.28	25	2	154	0	0	0	0	0	0	0	0	0	0
17	14.01.2024 0:00	1181-4	53121	49903	22.28	25	2	154	0	0	0	0	0	0	0	0	0	0

Рис. 2. Первый паттерн данных из базы данных

Из рис. 2 и 3 видно, что данные из разных источников имеют разное количество столбцов – различных признаков, включающих информативные и неинформативные для задачи классификации. С этой целью разработан алгоритм парсинга данных из базы данных с возможностью переключения его в автоматический и ручной режим.

	A	B	C	D	E	F	G	H	I
1	Дата_и_время	V1_ПСН Темп1	V1_ПСН Темп2	V1_ПСН Красн1	V1_ПСН Красн2	V1_ПСН Красн3	V1_ПСН Синий1	V1_ПСН Синий2	V1_ПСН Синий3
2	11.11.2022 0:00	26,75	24,75	60119	60117	60120	60123	60121	60118
3	11.11.2022 0:00	26,75	24,75	60119	60117	60120	60123	60121	60118
4	11.11.2022 0:00	26,75	24,75	60119	60117	60120	60123	60121	60118
5	11.11.2022 0:00	26,76	24,77	60123	60120	60117	60118	60123	60122
6	11.11.2022 0:00	26,76	24,77	60123	60120	60117	60118	60123	60122
7	11.11.2022 0:00	26,76	24,77	60123	60120	60117	60118	60123	60122
8	11.11.2022 0:00	26,78	24,77	60119	60123	60120	60118	60123	60122
9	11.11.2022 0:00	26,78	24,77	60119	60123	60120	60118	60123	60122
10	11.11.2022 0:00	26,78	24,77	60119	60123	60120	60118	60123	60122

Рис. 3. Второй паттерн данных из базы данных

Алгоритм парсинга данных представлен на рис. 4.




Рис. 4. Блок-схема алгоритма парсинга данных

Из рис. 4 условно можно выделить два ветвления $auto == 1$ и $auto != 1$, $auto$ является флагом включения автоматического режима в случае, если равен 1, и ручного режима в случае, если $auto$ не равен 0. Разберем каждый из режимов подробнее.

Ручной режим необходим для подготовки обучающих данных, в связи наличия более гибкого и контролируемого вручную функционала изменения получаемых данных. Автоматическим режим используется для работы обученной классифицирующей модели, а именно выполняет парсинг данных, получаемых в реальном времени.

Получаемые данные из базы данных условно можно разделить на два общих паттерна по максимальному количеству столбцов данных, а также типу и содержанию данных. Примеры паттернов представлены на рис. 2, 3. Алгоритм сравнивает полученные из БД данные с каждым паттерном, в случае соответствия одному из паттернов выполняет предписанные предписания, если полученные данные не соответствуют ни одному из паттернов, выводится соответствующая ошибка, сохраняется файл вызвавшие ошибку для его дальнейшего анализа и при необходимости добавления нового паттерна.

Данные для обучения модели. Обучающая выборка данных, содержит разделение данных по 5 параметрам: температура вне датчика, температура внутри датчика и три параметра задымленности, за основу взяты реальные данные обнаруженных аномалий в метрополитенах на местах установки комплекса взаимосвязанных пожарных датчиков. В выборку вошло 126 дней с размеченными маркерами обнаруженных аномалий, разделенных на 13 классов. Более подробно процесс разбиения на классы рассмотрен в статье [6]. Всего в выборку вошло 1 333 000 временных отрезков.

Тестовая выборка устроена по аналогичному обучающей выборке принципу, её размер составляет 60 дней, в выборку вошло 632 022 отрезка.

Обработка и подготовка данных. Нормализация данных с пожарных датчиков является обязательным шагом [18], данные могут принимать широкий диапазон значений, что затрудняет их интерпретацию с помощью нейронных сетей [19]. В работе исследовались следующие методы нормализации данных: Min-Max scaling с диапазоном изменений значений, учитывающих минимальное и максимальное возможное значение, принимаемое каждым параметром, Min-Max scaling, Z-score и Robust scaling [20–22].

Рассмотрим Min-Max scaling с диапазоном изменений значений подробнее. Ключевым его отличием от стандартного Min-Max заключается в том, что минимальное и максимальное значение выбирается не исходя из минимального и максимального значения в данных, а исходя из реального изменения параметра.

Формула нормализованного значения признака x_n Min-Max scaling с диапазоном изменений значений:

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} * (new_{max} - new_{min}) + new_{min}, \quad (1)$$

где x – исходное значение признака.

x_{min} – минимальное значение признака в исходных данных.

x_{max} – максимальное значение признака в исходных данных.

new_{max} – нижняя граница нового диапазона (в данном случае 0).

new_{min} – верхняя граница нового диапазона (в данном случае 1).

Например, диапазон температуры изменяется от -50 до 200 градусов. Подставив в формулу 1, получим:

$$x_n = \frac{x - (-50)}{200 - (-50)} * (1 - 0) + 0 = \frac{x + 50}{250} = x * \frac{1}{250} + 0.2 = \frac{23.49}{250} + 0.2 = 0.29. \quad (2)$$

Формула расчета x_{zn} нормализованного значения с помощью Z-score:

$$x_{zn} = \frac{x - \mu}{\sigma}, \quad (3)$$

где μ – среднее значение признака; σ – стандартное отклонение признака.

Например, для температуры снаружи датчика с используемой выборкой данных, значения очередного нормализованного значения x_{zn1} :

$$x_{zn1} = \frac{23.49 - 30.37}{7.15} = -0.96, \quad (4)$$

Формула расчета $x_{nrobust}$ нормализованного значения с помощью Robust scaling:

$$x_{nrobust} = \frac{x - \text{median}(x)}{IQR(x)}, \quad (5)$$

где $\text{median}(x)$ – медиана признака; $IQR(x)$ – межквартильный размах признака (разница между 75-м и 25-м процентилями)

Например, для температуры снаружи датчика с используемой выборкой данных, значения очередного нормализованного значения $x_{nrobust1}$:

$$x_{nrobust1} = \frac{23.49 - 30.37}{10.18} = -0.69. \quad (6)$$

Следует отметить, что диапазон изменения показаний датчика температуры изменится с -50 до 200 градусов.

Входе экспериментов, включающих моделирования KAN [23–25] алгоритма классификации с применением нормализации и без неё, сделан вывод, что KAN модель имеет низкую точность при работе с ненормализованными данными [26–32].

Тестирование обученной нейронной сети. Точности алгоритма оценивается по трем параметрам: общая точность системы, точность обнаружения аномалий, ошибка обнаружения. Дополнительно ошибки обнаружения подразделяются на необнаруженные аномалии и ложные аномалии, формулы расчета точности рассмотрены в статье [6].

Требования к параметрам точности алгоритма классификации представлены в табл. 1.

Таблица 1

Желаемые параметры точности

Accuracy, %	Precision, %	Detection Error, %	ignored, %	fake, %
Не менее 88	Не менее 85	Не более 15	нет	нет

Таблица 2

Изменения параметров точности классификаторов на обучающей выборке

Модель	Метод нормализации	Accuracy, %	Precision, %	Detection Error, %	ignored, %	fake, %
KAN	Min-Max scale	98.57	93.13	6.87	72.61	27.39
KAN	Z-score	95.33	82.22	17.78	55.43	44.57
KAN	Robust scaling	97.30	86.93	13.07	94.96	5.04
Random Forest	Min-Max scale	99.96	91.44	8.56	88.24	11.76
Random Forest	Z-score	99.96	90.84	9.16	88.46	11.54
Random Forest	Robust scaling	99.96	91.34	8.66	88.72	11.28
RNN	Min-Max scale	99.00	91	9.00	71.65	28.35
RNN	Z-score	98.56	89.55	10.45	70.22	29.78
RNN	Robust scaling	98.31	90.22	9.78	73.87	26.13

Таблица 3

Изменения параметров точности классификаторов на тестовой выборке

Модель	Метод нормализации	Accuracy, %	Presicion, %	Detection Error, %	ignored, %	fake, %
KAN	Min-Max scale	89.88	87.23	12.77	72.44	27.56
KAN	Z-score	85.33	84.22	15.78	82.34	17.66
KAN	Robust scaling	85.58	84.39	15.61	74.78	15.22
Random Forest	Min-Max scale	98.49	97.33	2.67	83.02	16.98
Random Forest	Z-score	97.12	94.51	5.49	82.69	17.31
Random Forest	Robust scaling	98.25	95.54	4.46	80.77	19.23
RNN	Min-Max scale	98.65	97.36	2.64	63.45	36.55
RNN	Z-score	96.55	92.55	7.45	61.25	38.75
RNN	Robust scaling	95.55	93.67	6.33	55.57	44.43




Рис. 5. График классификации данных на выделенном участке с помощью KAN классификатора с Min-Max нормализации

Обсуждение. Анализируя полученные параметры точности после моделирования алгоритма с требованиями, поставленными в табл. 1, можно сделать вывод, что предложенный алгоритм классификации соответствует поставленным требованиям: accuracy (общая точность) не менее 88%, precision (точность обнаружения) не менее 85%, detection error (ошибка обнаружения) не более 15% при методе нормализации Min-Max scale. В ходе работы с обучающей выборкой получены следующие показатели точности: общая точность 98.57%, точность обнаружения 93.13%, ошибка обнаружения 6.87%, что не ниже поставленных требований. Классификация данных тестовой выборки показала: общая точность 89.88%, точность обнаружения 87.23, ошибка обнаружения 12.77%, что также не ниже поставленных требований. Исходя из полученных результатов предложенный алгоритм классификации на основе KAN, можно использовать для классификации данных получаемых из комплекса взаимосвязанных датчиков.

Заключение. Алгоритм классификации пожароопасной ситуаций с помощью KAN сетей является новым решением, обладающим исходя из полученных значений точности хорошими перспективами использования. Применение этой модели может не только повысить точность и эффективность принятия решения в задаче классификации, но откроет возможность к проведению более глубокого анализа пожароопасных ситуаций, на основе получаемого символического представления модели классификации.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. KAN documentation. – URL: <https://kindxiaoming.github.io/pykan/> (дата обращения: 03.08.2024).
2. *Ziming Liu, Yixuan Wang*. KAN: Kolmogorov-Arnold Networks, 30 Apr 2024. – DOI: <https://doi.org/10.48550/arXiv.2404.19756>.
3. *Саутин И.Г.* Противопожарная защита: технологии и решения // Транспорт, Противопожарная защита. Пожарная автоматика. Средства спасения. – 2018.
4. *Саутин И.Г.* Особое мнение. Можно ли доверить свою жизнь дымовому пожарному извещателю? // Алгоритм безопасности. – 2019. – № 6.
5. *Сингх С., Прибыльский А.В.* Синтез системы сверхбыстрого обнаружения пожароопасных ситуаций на основе комплекса взаимосвязанных датчиков // Известие ЮФУ. Технические науки. – 2024. – № 2. – С. 121-132.
6. *Сингх С., Прибыльский А.В.* Алгоритм классификации пожароопасных ситуаций на основе нейросетевых технологий // Известие ЮФУ. Технические науки. – 2024. – № 3. – С. 138-147.
7. NFPA 72: National Fire Alarm and Signaling Code. – 2019.
8. UL 268: Standard for Smoke Detectors for Fire Protective Signaling Systems. – 2019.
9. ISO 7240-14: Fire detection and alarm systems – Part 14: Requirements and test methods for smoke detectors. – 2018.
10. BS 5839-1:2017: Fire alarm systems for commercial and industrial premises. Code of practice for design, installation, commissioning and maintenance.
11. ГОСТ Р 53325-2009: Системы пожарной сигнализации. Общие технические требования.
12. *Полевин П.В. [и др.]*. Пожары и пожарная безопасность в 2020 году: Сб. статей / под общ. ред. Д.М. Гордиенко. – М.: ВНИИПО, 2021. – 112 с.
13. *Solovyeva E.* Types of recurrent neural networks for non-linear dynamic system modelling // Proceedings of 2017 XX IEEE International Conference on Soft Computing and Measurements (SCM2017). St. Petersburg: Saint-Petersburg Electrotechnical University «LETI». Russia, St. Petersburg, May 24–26, 2017. – P. 1-4.
14. *Wang Z., Yan W., Oates T.* Time series classification from scratch with deep neural networks: A strong baseline // In: 2017 International Joint Conference on Neural Networks. – IJCNN, IEEE, 2017. – P. 1578-1585.
15. *Fedorov A., Bytcinskaya T., Lukyanchenko A., Hung T.D.* Trends in the development of automatic fire detectors // Technol. Technosphere Saf. – 2009. – 23. – P. 111-114. – Available online: <https://cyberleninka.ru/article/n/tendentsii-razvitiya-avtomaticheskikh-pozharnyh-izveschateley-1> (accessed on 20 December 2023).
16. *Han J., Kamber M., & Pei J.* Data Normalization for Big Data Analytics // IEEE Transactions on Knowledge and Data Engineering. – 2017. – 29 (10). – P. 2435-2448. – DOI: 10.1109/TKDE.2017.2734444.
17. *Rao S.S., Iyengar S.S., & Venayagamoorthy G.K.* Big Data Normalization: A Survey // IEEE Transactions on Big Data. – 2018. – 4 (2). – P. 149-163. – DOI: 10.1109/TBDDATA.2018.2823718.
18. *Singh A.K., Singh S.K., & Singh R.K.* Data Parsing and Normalization for Social Media Analytics // Journal of Intelligent Information Systems. – 2020. – 56 (2). – P. 257-273. – DOI: 10.1007/s10844-019-00563-4.
19. *Liu J., Zhang Y., & Li X.* Machine Learning for Data Normalization in Big Data Analytics // IEEE Transactions on Neural Networks and Learning Systems. – 2019. – 30 (1). – P. 201-214. – DOI: 10.1109/TNNLS.2018.2873818.
20. *Kate R.J.* Using dynamic time warping distances as features for improved timeseries classification // Data Min. Knowl. Discov. – 2016. – 30 (2). – P. 283-312.
21. *Abandah G., Abdel-Karim A.* Accurate and fast recurrent neural network solution for the automatic diacritization of Arabic text // Jordan. J. Comp. Inform. Technol. – 2020. – 6 (2). – P. 103-121.
22. *Géron A.* Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media. – 2019.
23. Pykan documentation and apps. – URL: <https://github.com/KindXiaoming/pykan> (дата обращения: 03.08.2024).
24. Scikit-learn for supervised learning documentation. – URL: https://scikit-learn.org/stable/supervised_learning.html (дата обращения: 03.08.2024).
25. MathWorks. «MATLAB & Simulink Help Center» MathWorks, 2023. – <https://www.mathworks.com/help/index.html> (accessed 20 December 2023).
26. *Bozogasl Z., & Chen H.* Wav-KAN: Wavelet kolmogorov-arnold networks // arXiv preprint arXiv:2405.12832. – June 2024. – Retrieved from <https://arxiv.org/abs/2405.12832>.
27. *Federico Girosi, Tomaso Poggio.* Representation Properties of Networks: Kolmogorov's Theorem Is Irrelevant // Neural Comput. – 1989. – 1 (4). – P. 465-469. – DOI: <https://doi.org/10.1162/neco.1989.1.4.465>.

28. Galitsky B.A. Kolmogorov-Arnold Network for Word-Level Explainable Meaning Representation // Preprints. – 2024. – Retrieved from <https://www.preprints.org/manuscript/202405.1981>.
29. Hao H., Zhang X., Li B., & Zhou A. A First Look at Kolmogorov-Arnold Networks in Surrogate-assisted Evolutionary Algorithms // arXiv preprint arXiv:2405.16494. – 2024. – Retrieved from <https://arxiv.org/abs/2405.16494>.
30. Vaca-Rubio C.J., Blanco L., & Pereira R. Kolmogorov-Arnold Networks (KANs) for Time Series Analysis // arXiv preprint arXiv:2405.08790. – 2024. – Retrieved from <https://arxiv.org/abs/2405.08790>.
31. Galitsky B.A. Kolmogorov-Arnold Network for Word-Level Explainable Meaning Representation // Preprints. – 2024. – Retrieved from <https://www.preprints.org/manuscript/202405.1981>.
32. Genet R., & Inzirillo H. TKAN: Temporal Kolmogorov-Arnold Networks // arXiv preprint arXiv:2405.07344. – 2024. – Retrieved from <https://arxiv.org/abs/2405.07344>.

REFERENCES

1. KAN documentation. Available at: <https://kindxiaoming.github.io/pykan/> (accessed: 03 August 2024).
2. Ziming Liu, Yixuan Wang. KAN: Kolmogorov-Arnold Networks, 30 Apr 2024. DOI: <https://doi.org/10.48550/arXiv.2404.19756>.
3. Sautin I.G. Protivopozharnaya zashchita: tekhnologii i resheniya [Fire protection: technologies and solutions], Transport, Protivopozharnaya zashchita. Pozharnaya avtomatika. Sredstva spaseniya [Transport, Fire protection. Fire automation. Rescue equipment], 2018.
4. Sautin I.G. Osoboe mnenie. Mozhno li doverit' svoyu zhizn' dymovomu pozharnomu izveshchatel'yu? [Dissenting opinion. Can you trust your life to a smoke alarm?], *Algoritm bezopasnosti* [Security Algorithm], 2019, No. 6.
5. Singkh S., Pribyl'skiy A.V. Sintez sistemy sverkhbystrogo obnaruzheniya pozharoopasnykh situatsiy na osnove kompleksa vzaimosvyazannykh datchikov [Synthesis of a system for ultra-fast detection of fire hazardous situations based on a complex of interconnected sensors], *Izvestie YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2024, No. 2, pp. 121-132.
6. Singkh S., Pribyl'skiy A.V. Algoritm klassifikatsii pozharoopasnykh situatsiy na osnove neyrosetevykh tekhnologiy [Algorithm for classification of fire hazardous situations based on neural network technologies], *Izvestie YuFU. Tekhnicheskie nauki* [Izvestiya SFedU. Engineering Sciences], 2024, No. 3, pp. 138-147.
7. NFPA 72: National Fire Alarm and Signaling Code, 2019.
8. UL 268: Standard for Smoke Detectors for Fire Protective Signaling Systems, 2019.
9. ISO 7240-14: Fire detection and alarm systems – Part 14: Requirements and test methods for smoke detectors, 2018.
10. BS 5839-1:2017: Fire alarm systems for commercial and industrial premises. Code of practice for design, installation, commissioning and maintenance.
11. GOST R 53325-2009: Sistemy pozharnoy signalizatsii. Obshchie tekhnicheskie trebovaniya [GOST R 53325-2009: Fire alarm systems. General technical requirements].
12. Polekhin P.V. [i dr.]. Pozhary i pozharnaya bezopasnost' v 2020 godu: Sb. statey [Fires and fire safety in 2020: Collection of articles], under the general ed. of D.M. Gordienko. Moscow: VNIPO, 2021, 112 p.
13. Solovyeva E. Types of recurrent neural networks for non-linear dynamic system modeling, *Proceedings of 2017 XX IEEE International Conference on Soft Computing and Measurements (SCM2017)*. St. Petersburg: Saint-Petersburg Electrotechnical University «LETI». Russia, St. Petersburg, May 24–26, 2017, pp. 1-4.
14. Wang Z., Yan W., Oates T. Time series classification from scratch with deep neural networks: A strong baseline, In: *2017 International Joint Conference on Neural Networks. IJCNN*, IEEE, 2017, pp. 1578-1585.
15. Fedorov A., Bytinskaya T., Lukyanchenko A., Hung T.D. Trends in the development of automatic fire detectors, *Technol. Technosphere Saf.*, 2009, 23, pp. 111-114. Available online: <https://cyberleninka.ru/article/n/tendentsii-razvitiya-avtomaticheskikh-pozharnykh-izveshchateley-1> (accessed on 20 December 2023).
16. Han J., Kamber M., & Pei J. Data Normalization for Big Data Analytics, *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29 (10), pp. 2435-2448. DOI: 10.1109/TKDE.2017.2734444.
17. Rao S.S., Iyengar S.S., & Venayagamoorthy G.K. Big Data Normalization: A Survey, *IEEE Transactions on Big Data*, 2018, 4 (2), pp. 149-163. DOI: 10.1109/TBDDATA.2018.2823718.
18. Singh A.K., Singh S.K., & Singh R.K. Data Parsing and Normalization for Social Media Analytics, *Journal of Intelligent Information Systems*, 2020, 56 (2), pp. 257-273. DOI: 10.1007/s10844-019-00563-4.
19. Liu J., Zhang Y., & Li X. Machine Learning for Data Normalization in Big Data Analytics, *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30 (1), pp. 201-214. DOI: 10.1109/TNNLS.2018.2873818.
20. Kate R.J. Using dynamic time warping distances as features for improved timeseries classification, *Data Min. Knowl. Discov*, 2016, 30 (2), pp. 283-312.

21. Abandah G., Abdel-Karim A. Accurate and fast recurrent neural network solution for the automatic diacritization of Arabic text, *Jordan. J. Comp. Inform. Technol.*, 2020, 6 (2), pp. 103-121.
22. Géron A. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media, 2019.
23. Pykan documentation and apps. Available at: <https://github.com/KindXiaoming/pykan> (accessed 03 August 2024).
24. Scikit-learn for supervised learning documentation. Available at: https://scikit-learn.org/stable/supervised_learning.html (03 August 2024).
25. MathWorks. «MATLAB & Simulink Help Center» MathWorks, 2023. Available at: <https://www.mathworks.com/help/index.html> (accessed 20 December 2023).
26. Bozorgasl Z., & Chen H. Wav-KAN: Wavelet kolmogorov-arnold networks, *arXiv preprint arXiv:2405.12832*, June 2024. Retrieved from <https://arxiv.org/abs/2405.12832>.
27. Federico Giosi, Tomaso Poggio. Representation Properties of Networks: Kolmogorov's Theorem Is Irrelevant, *Neural Comput.*, 1989, 1 (4), pp. 465-469. DOI: <https://doi.org/10.1162/neco.1989.1.4.465>.
28. Galitsky B.A. Kolmogorov-Arnold Network for Word-Level Explainable Meaning Representation, *Preprints*, 2024. Retrieved from <https://www.preprints.org/manuscript/202405.1981>.
29. Hao H., Zhang X., Li B., & Zhou A. A First Look at Kolmogorov-Arnold Networks in Surrogate-assisted Evolutionary Algorithms, *arXiv preprint arXiv:2405.16494*, 2024. Retrieved from <https://arxiv.org/abs/2405.16494>.
30. Vaca-Rubio C.J., Blanco L., & Pereira R. Kolmogorov-Arnold Networks (KANs) for Time Series Analysis, *arXiv preprint arXiv:2405.08790*, 2024. Retrieved from <https://arxiv.org/abs/2405.08790>.
31. Galitsky B.A. Kolmogorov-Arnold Network for Word-Level Explainable Meaning Representation, *Preprints*, 2024. Retrieved from <https://www.preprints.org/manuscript/202405.1981>.
32. Genet R., & Inzirillo H. TKAN: Temporal Kolmogorov-Arnold Networks, *arXiv preprint arXiv:2405.07344*, 2024. Retrieved from <https://arxiv.org/abs/2405.07344>.

Сингх Санны – Южный федеральный университет; e-mail: singkh@sfedu.ru; г. Таганрог, Россия; тел.: +79885751350; кафедра систем автоматического управления; аспирант.

Прибыльский Алексей Васильевич – e-mail: apribylsky@sfedu.ru; тел.: +79885619718; кафедра систем автоматического управления; к.т.н.; доцент.

Singh Sanni – Southern Federal University; e-mail: singkh@sfedu.ru; Taganrog, Russia; phone: +79885751350; the Department of Automatic Control Systems; graduate student.

Pribylskiy Alexey Vasilievich – e-mail: apribylsky@sfedu.ru; phone: +79885619718; the Department of Automatic Control Systems; cand. of eng. sc.; assistant professor.

УДК 004.896

DOI 10.18522/2311-3103-2024-6-15-29

В.В. Курейчик, Ю.В. Балясова, В.В. Бова

ОБЗОР И АНАЛИЗ МЕТОДОВ ТРЕХМЕРНОЙ УПАКОВКИ ПРИ МОРСКИХ ГРУЗОПЕРЕВОЗКАХ

Описана проблема трёхмерной упаковки товаров в различные типы контейнеров при осуществлении морских грузоперевозок. Морские грузоперевозки играют значительную роль в международной торговле, реализуются в специфичных и нестандартных условиях, характеризуются усиленной влажностью, контактом с морской солью, вибрацией, интерференцией температур и осуществляются посредством судов контейнеровозов, транспортирующих различные категории товаров в контейнерах, подбираемых с учётом специфики перевозимого груза, что обеспечивает надёжность и безопасность. Особую важность приобретает присутствие защиты товара от многообразных негативных и техногенных факторов окружающей среды, что подтверждает немаловажность правильно разработанной морской упаковки груза, обеспечивающей сохранение товара, оборудования, сырья, либо материалов на всём времени транспортировки по морю, а также надёжного крепления на палубе, либо