

**АНСАМБЛИ НЕЙРОСЕТЕВЫХ КЛАССИФИКАТОРОВ
В ЗАДАЧЕ АНАЛИЗА ДАННЫХ ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ
МАЛОГО КОСМИЧЕСКОГО АППАРАТА****В. Ю. Скобцов**

*Санкт-Петербургский государственный университет аэрокосмического приборостроения,
Санкт-Петербург, Россия
Санкт-Петербургский институт информатики и автоматизации РАН, Санкт-Петербург, Россия
vasko_vasko@mail.ru*

Аннотация. Рассматривается задача классификационного анализа данных временных рядов телеметрической информации малого космического аппарата в целях определения его технического состояния. Представлены результаты разработки и исследования ансамблевых моделей гибридных нейросетевых классификаторов на базе ансамблей типа бэггинг и AdaBoost. Представлена базовая модель гибридного нейросетевого классификатора, полученная посредством разработанного генетического алгоритма автоматического поиска гибридных нейросетевых классификаторов. С использованием данной нейросетевой модели построена и обучена модель бэггинг-ансамбля гибридных нейросетевых классификаторов, качество которого превышает и качество базовой модели нейронной сети, и качество ансамблей классификаторов типа Random Forest, Bagging, Gradient Boosting, Adaptive Boosting, Histogram-based Gradient Boosting на базе деревьев принятия решения.

Ключевые слова: телеметрическая информация, малый космический аппарат, гибридные нейросетевые классификаторы, данные временных рядов, модели ансамблей, бэггинг, бустинг

Благодарности: исследования, выполненные по данной тематике, проводились при частичной финансовой поддержке бюджетной темы № FFZF-2022-0004.

Ссылка для цитирования: Скобцов В. Ю. Ансамбли нейросетевых классификаторов в задаче анализа данных телеметрической информации малого космического аппарата // Изв. вузов. Приборостроение. 2024. Т. 67, № 11. С. 943–950. DOI: 10.17586/0021-3454-2024-67-11-943-950.

**ENSEMBLES OF NEURAL NETWORK CLASSIFIERS IN THE PROBLEM
OF ANALYZING TELEMETRY INFORMATION DATA OF A SMALL SPACECRAFT****V. Yu. Skobtsov**

*St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia
St. Petersburg Institute for Informatics and Automation of the RAS, St. Petersburg, Russia
E-mail: vasko_vasko@mail.ru*

Abstract. The problem of classification analysis of time series data of telemetry information of a small spacecraft is considered in order to determine its technical state. Results of development and research of ensemble models of hybrid neural network classifiers based on ensembles such as bagging and AdaBoost, are presented. The basic model of a hybrid neural network classifier, obtained by automatic search using a genetic algorithm for searching hybrid neural network classifiers, is considered. This neural network model makes it possible to build and train a bagging model of an ensemble of hybrid neural network classifiers, the quality of which exceeds both the quality of the basic neural network model and the quality of ensembles of classifiers such as Random Forest, Bagging, Gradient Boosting, Adaptive Boosting (AdaBoost), Histogram-based Gradient Boosting based on decision trees.

Keywords: telemetry information, small spacecraft, hybrid neural network classifiers, time series data, ensemble models, bagging, boosting

Acknowledgments: the research conducted on this topic was carried out with partial financial support from budget topic No. FFZF-2022-0004.

For citation: Skobtsov V. Yu. Ensembles of neural network classifiers in the problem of analyzing telemetry information data of a small spacecraft. *Journal of Instrument Engineering*. 2024. Vol. 67, N 11. P. 943–950 (in Russian). DOI: 10.17586/0021-3454-2024-67-11-943-950.

Введение. Большие объемы данных о функционировании сложных технических объектов, накапливающиеся в специализированных хранилищах данных, могут эффективно использоваться для совершенствования процессов анализа и мониторинга жизненного цикла сложных объектов.

Методы машинного и глубокого обучения, как и методы искусственного интеллекта, — на текущий момент одни из самых перспективных и широко используемых подходов к анализу данных высокотехнологичных систем, разработанных ведущими мировыми IT-компаниями и университетами [1].

Для решения задач мониторинга и определения технического состояния таких сложных объектов, как малые космические аппараты (МКА), обеспечения требуемой степени их автономности, качества и оперативности управления необходима комплексная автоматизация и интеллектуализация процессов оценивания и многомодельного анализа данных телеметрической информации (ТМИ) МКА. В соответствии с ГОСТ 1410-002-2010 и Стратегией цифровой трансформации ракетно-космической отрасли до 2025 г. и перспективу до 2030 г. для Госкорпорации „Роскосмос“ важной задачей является создание так называемой системы информации о техническом состоянии и надежности космических комплексов и входящих в их состав изделий. Таким образом, задача интеллектуального анализа данных ТМИ МКА в целях определения технического состояния МКА на основе моделей машинного и глубокого обучения является актуальной и востребованной.

Методы определения состояний функционирования МКА на основе моделей кластерного анализа (обучения без учителя) [2, 3] требуют дальнейшей интерпретации сегментированных состояний. В то же время наличие данных ТМИ с эталонными полученными на основе экспертных знаний метками принадлежности векторов ТМИ техническим состояниям позволяет выполнять классификационный анализ временных рядов ТМИ МКА. Такой анализ, в свою очередь, позволяет решать задачу определения технического состояния МКА автоматически и более точно по сравнению с кластерным подходом. В этой связи в настоящей статье представлены результаты исследований и разработки ансамблевых гибридных нейросетевых классификаторов для решения задачи мультиклассовой классификации данных ТМИ МКА „Аист“ (Самарского национального исследовательского университета им. акад. С. П. Королёва) в целях определения его технического состояния.

Задача мультиклассовой классификации данных ТМИ МКА. Будем рассматривать анализируемый массив данных ТМИ как M -мерный временной ряд $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M)$, каждый элемент которого $\mathbf{X}_j \in R^T$ является столбцом матрицы $\mathbf{X}$ данных показателей ТМИ МКА, описывающим поведение j -го показателя системы на отрезке дискретных моментов времени [1, T].

Для каждого вектора показателей ТМИ в i -й момент времени $\mathbf{X}_i$ поставлена в соответствие метка класса $y_i \in Y$, который характеризует состояние функционирования анализируемого по данным ТМИ МКА. В исследуемой задаче рассматривается случай k -классовой классификации, где $k > 2$ — общее число состояний, определяемое экспертом. Конечной целью является классификация векторов $\mathbf{X}_i$ M -мерного временного ряда $\mathbf{X}$ ТМИ к штатному состоянию „0“ и двум нештатным состояниям: 1 — отказ и 2 — сбой. Иными словами, значения компонент вектора меток классов $Y \in \{0, 1, 2\}$. Таким образом, стоит задача построения модели глубокого обучения следующего отображения $y: X \rightarrow Y$.

Гибридные нейросетевые классификаторы. В обзорной аналитической работе [4] показано преимущество применения нейросетевых моделей глубокого обучения для задачи классификации временных рядов различной природы по сравнению с современными моделями (не нейросетевыми) „классического“ машинного обучения.

Эффективное применение нейросетевых моделей находят и в решении задачи мониторинга и определения состояния МКА. Так, в работах [5, 6] представлена нейросетевая система мониторинга состояния подсистем космических аппаратов по данным ТМИ для наземного командно-измерительного комплекса, которая обеспечивает контроль и прогнозирование состояния и работоспособности ряда подсистем белорусского космического аппарата (БКА). Достигнута

точность прогнозирования временных рядов свыше 94 %, причем улучшение результатов обеспечивается применением ансамбля нейронных сетей. В [7] приведены результаты комплексного сравнения методов машинного и глубокого обучения (статистических, классических, нейросетевых и ансамблевых: ARIMA, MLP, RNN, LSTM, SVR и XGBoost) для прогнозирования данных ТМИ низкоорбитальных КА. Согласно полученным результатам наиболее перспективной для анализа больших данных временных рядов ТМИ считается нейросетевая рекуррентная модель LSTM, которая превосходит такую прогрессивную ансамблевую „классическую“ модель машинного обучения, как XGBoost.

В последние несколько лет эффективное применение в задачах анализа различных типов данных находят так называемые гибридные глубокие нейронные сети, которые объединяют в своей архитектуре комбинации различных типов современных нейронных слоев. В работах [8, 9] китайских исследователей приведены результаты, показывающие превосходство по качеству гибридных нейросетевых моделей для задач анализа данных временных рядов.

В работах [10–12] коллектива отечественных специалистов также были исследованы и разработаны гибридные нейросетевые модели на основе комплексирования одномерных сверточных, рекуррентных типа GRU и полносвязных нейронных слоев как итоговых классификаторов/регрессоров для задач классификации/регрессии данных различной природы. В моделях применялась методика остаточных связей архитектур ResNet, поскольку это упрощает обучение сети за счет уменьшения эффекта исчезающего градиента [13]. Рассматривались двух- и трехклассовые задачи классификации для определения штатного и нештатных состояний навигационной подсистемы БКА и МКА „Аист“. Сравнительный анализ полученных гибридных нейросетевых моделей с известными глубокими нейросетевыми классификаторами LeNet, AlexNet, Xception, Yolo, MobileNet, Inception, ResNet показал преимущество разработанных моделей как по точности, так и по времени обучения и валидации. Для задачи бинарной классификации на данных ТМИ БКА разработанная гибридная нейросетевая модель сравнима по точности с моделью Inception — 0,97, при этом она в 2,5 раза быстрее по времени обучения и валидации и имеет более облегченную структуру. Для задачи трехклассовой классификации на данных ТМИ МКА „Аист“ для разработанной гибридной нейросетевой модели точность на этапе тестирования составляет $\approx 0,985$. Сравнительный анализ показал преимущество полученного решения по точности классификации на этапе тестирования для всех сравниваемых моделей на 1–7 %, по времени обучения и валидации — в 1,5–4 раза.

В целях сокращения времени создания нейросетевых моделей был разработан генетический алгоритм автоматического поиска гибридных нейросетевых моделей, который был применен для решения задач анализа данных ТМИ МКА „Аист“ [14]. Предложенный алгоритм выполняет поиск модели гибридной нейронной сети в целом. Для данных ТМИ МКА „Аист“ точность классификации составляет 98,8 %, для данных ТМИ БКА — 98 %, что превышает показатели для моделей, разработанных вручную.

Таким образом, на основании экспериментальных результатов можно утверждать, что для решения задачи анализа временных рядов ТМИ МКА в целях определения его состояния гибридные нейросетевые классификаторы — одни из самых перспективных моделей.

Ансамбли гибридных нейросетевых классификаторов. Современные распространенные ансамблевые модели являются достаточно эффективными при решении задач анализа данных временных рядов различной природы. Поэтому в настоящей статье приводятся результаты разработки, исследования и сравнительного анализа ансамблей типа бэггинг и бустинг [13] гибридных нейросетевых классификаторов для задачи определения штатного и нештатных состояний ТМИ МКА „Аист“ методом трехклассовой классификации.

Базовая модель ансамбля гибридных нейросетевых классификаторов. В качестве базовой модели взята полученная с помощью разработанного генетического алгоритма автоматического поиска [14] гибридная нейросетевая модель следующей структуры:

$$z_1 = \text{Conv1D}(\text{filters}=102, \text{kernel_size}=2, \text{activation}='relu')(x_i)$$

```

Z_1 = BatchNormalization (Z_1)
Z_1 = AveragePooling1D(2) (Z_1)
Z_1 = BatchNormalization (Z_1)
Z_1 = Conv1D(filters=118, kernel_size=2, activation='relu') (Z_1)
Z_1 = BatchNormalization (Z_1)
Z_1 = AveragePooling1D(2) (Z_1)
Z_1 = BatchNormalization (Z_1)
Output = GRU(units=72)
Output = Dense(304, activation='relu') (Output)
Output = Dense(3, activation='softmax') (Output)

```

В качестве активационных функций выбраны следующие широко используемые функции [13]: функция $\text{relu}(z)$ — rectified linear unit, обобщение логистической функции для многоклассового случая $\text{softmax}(z)$, а в качестве функции ошибки — функция категориальной кроссэнтропии, поскольку для случая $k = 3$ решается задача многоклассовой классификации. Применен алгоритм обучения Adam, который определен автоматически в результате поиска генетическим алгоритмом как наиболее эффективный. Размер мини-пакета равен 256, число эпох обучения — 50 [14]. Приведенные значения гиперпараметров применяются для обучения и валидации как одиночной базовой гибридной нейросетевой модели, так и ее ансамблей исследуемых типов.

Данная гибридная нейросетевая модель была получена в результате автоматического поиска гибридной нейросетевой классификационной модели на данных ТМИ БКА, решающей задачу бинарной классификации данных ТМИ БКА. Такой подход позволил экспериментально определить возможности использования модели, полученной на данных ТМИ одного МКА (БКА), для решения задачи классификации данных ТМИ другого МКА („Аист“) при условии изменения числа классов — состояний.

Метриками качества классификационных моделей будем считать интегральную метрику точности (ассигасу), а также F_1 -меру для каждого класса [13]. Последняя метрика используется в силу значимости детектирования, помимо класса „0“ штатного состояния МКА, также классов 1 — отказ и 2 — сбой.

Используемые модели ансамблей. Ансамблевые методы являются мощным инструментом машинного обучения и находят широкое применение. Цель ансамблевых методов — объединить прогнозируемые базовыми моделями оценки, чтобы улучшить обобщаемость/надежность по сравнению с оценкой, производимой одиночной базовой моделью. Модели нулевого уровня (базовые модели) — это обученные на тренировочных данных модели, прогнозируемые ими оценки интегрируются. Модель первого уровня (метамодель) — это модель, которая учится наилучшим образом комбинировать прогнозируемые базовыми моделями оценки.

В методах усреднения главный принцип состоит в том, чтобы построить несколько моделей независимо параллельно, а затем усреднить прогнозируемые ими оценки. Комбинированная оценка обычно лучше, чем любая из оценок, произведенных одной базовой моделью, так как ее дисперсия уменьшается. В методах усиления базовые оценки строятся последовательно, и каждая базовая модель пытается уменьшить смещение комбинированной оценки. Идея заключается в том, чтобы объединить несколько слабых моделей для создания мощного ансамбля. Наиболее широко используются такие ансамблевые методы, как бэггинг и бустинг [13].

Бэггинг (bagging, bootstrap aggregation), или модельное усреднение, — это разновидность параллельного ансамблирования, которое используется для урегулирования проблем, связанных с высокой дисперсией в моделях машинного обучения. Бутстрап-агрегирование подразумевает возможность обучения каждой из k базовых моделей ансамбля типа бэггинг на k отдельных поднаборах обучающего набора данных. Каждый обучающий поднабор данных строится путем случайного отбора экземпляров из исходного набора данных (с возвратом). Агрегирование выполняется по результатам работы k членов ансамблевой модели — берется большинство голосов в

случае классификационной задачи. При этом возможен вариант, когда бутстрап-режим отключен и все базовые модели ансамбля обучаются на всем исходном обучающем наборе данных [13].

Бустинг (первоначально называемый усилением гипотезы — hypothesis boosting), или модельное усиление, относится к любому ансамблевому методу, который способен комбинировать несколько слабых моделей в одну сильную. Основная идея большинства методов бустинга предусматривает последовательное обучение базовых моделей, причем каждая из них старается усилить/исправить предыдущую модель. Одни из самых распространенных моделей — AdaBoost (Adaptive Boosting — адаптивный бустинг) и градиентный бустинг (gradient boosting). Поскольку реализация модели AdaBoost, в отличие от градиентного бустинга, позволяет использовать произвольную базовую модель классификатора, то при разработке и исследовании ансамблевой модели на основе гибридной нейронной сети использовалась данная модель.

Экспериментальные результаты и сравнительный анализ. На основании вышеизложенного для построения модели ансамбля гибридных нейросетевых классификаторов применялись два типа ансамблевых моделей: бэггинг и AdaBoost. Реализация моделей осуществлена средствами языка Python и его пакетов: Keras, Scikit-Learn и Scikeras.

Для анализа использовались данные ТМИ МКА „Аист“ [15]. Общая размерность 49-мерного временного ряда данных ТМИ X составила 2679 векторов. Из них было выделено 1714 векторов для формирования обучающего набора данных, 429 векторов для формирования валидационного набора данных и 536 векторов — для тестового набора данных.

В табл. 1 приведены сравнительные результаты метрик качества: Accurasy для каждой из моделей и F_1 -мера для каждого класса обученных базовых моделей гибридного нейросетевого классификатора и ансамбля обученных базовых моделей типа AdaBoost для разного числа базовых моделей на тестовой выборке. При этом использован алгоритм дискретного повышения SAMME вместо алгоритма реального повышения SAMME.R, поскольку во втором случае F_1 -мера имеет меньшее значение: $0,8 < 0,82$ для класса 2 — сбой.

Таблица 1

Тип модели классификатора	Количество моделей	Accurasy	F_1 -мера		
			Класс 0	Класс 1	Класс 2
Базовый одиночный гибридный классификатор	1	0,98	0,99	0,95	0,77
Ансамбль типа AdaBoost	5	0,99	0,99	0,95	0,82
	50	0,99	0,99	0,95	0,82
	100	0,99	0,99	0,95	0,82

Как видно из табл. 1, показатель „Accurasy“ ансамблевой модели типа AdaBoost на основе гибридного нейросетевого классификатора увеличился до 0,99 для 5 базовых моделей и далее для 50 и 100 базовых моделей не повышался. При этом F_1 -мера увеличилась только для класса 2 — с 0,77 до 0,82 для ансамбля из 5 базовых моделей и далее не изменялась, т. е. увеличивать число базовых моделей выше 5 не имеет смысла.

В табл. 2 приведены сравнительные результаты аналогичных метрик качества для ансамблевой модели типа бэггинг.

Таблица 2

Тип модели классификатора	Количество моделей	Accurasy	F_1 -мера		
			Класс 0	Класс 1	Класс 2
Базовый одиночный гибридный классификатор	1	0,98	0,99	0,95	0,77
Ансамбль типа бэггинг	5	0,99	1,00	0,97	0,82
	50	0,99	1,00	0,97	0,82
	100	0,99	1,00	0,97	0,85

Анализ табл. 2 показывает, что изменение метрики „Accuracy“ ансамблевой модели типа бэггинг аналогично приведенному в табл. 1, при этом F_1 -мера для ансамбля из 5 базовых моделей для класса „0“ увеличилась до значения 1,00 и далее не изменялась, для класса 1 — увеличилась до значения 0,97 и далее не изменялась, для класса 2 ее значение существенно увеличилось с 0,77 до 0,82 для ансамбля из 5 базовых моделей и далее до значения 0,85 для 100 базовых моделей. Итак, лучшей ансамблевой моделью типа бэггинг является модель из 100 базовых гибридных нейросетевых классификаторов.

Таким образом, эксперименты показали преимущество ансамбля из 100 базовых моделей гибридных нейронных сетей типа бэггинг по сравнению с ансамблем типа AdaBoost и повышение эффективности разработанной модели по сравнению с базовым классификатором.

Далее сравним результаты метрик качества лучшей модели бэггинг-ансамбля гибридных нейросетевых классификаторов из 100 базовых моделей с ансамблевыми моделями из 100 базовых моделей типа деревьев принятия решения следующих наиболее распространенных типов: Random Forest, Bagging, Gradient Boosting, Adaptive Boosting (AdaBoost), Histogram-based Gradient Boosting [13]. Для каждой модели выполнялся поиск по сетке значений соответствующего набора гиперпараметров, что говорит об использовании для сравнения обученных квазиоптимальных моделей ансамблей заданных типов. В табл. 3 приведены экспериментальные значения метрик на тестовом наборе данных ТМИ „Аист“.

Таблица 3

Тип модели классификатора	Accuracy	F_1 -мера		
		Класс 0	Класс 1	Класс 2
Ансамбль гибридных нейросетевых классификаторов типа бэггинг	0,99	1,00	0,97	0,85
Random Forest	0,98	0,99	0,98	0,71
Bagging	0,98	0,99	0,99	0,60
AdaBoost	0,97	0,99	0,97	0,63
Gradient Boosting	0,98	0,99	0,99	0,65
Histogram-based Gradient Boosting	0,98	0,99	0,99	0,60

Проанализировав данные табл. 3, можно сказать, что лучшей моделью среди ансамблей деревьев принятия решений является модель Random Forest, имеющая следующие значения метрик классификации: показатель Accuracy — 0,98, F_1 -мера для класса „0“ — 0,99, для класса 1 — 0,98, для класса 2 — 0,71. При этом лучшей моделью по сравнению с моделями древовидных ансамблей является модель ансамбля типа бэггинг гибридных нейросетевых классификаторов.

Заключение. Представлены результаты разработки и исследования ансамблевых моделей гибридных нейросетевых классификаторов на базе ансамблей типа бэггинг и AdaBoost. Рассмотрена базовая модель гибридного нейросетевого классификатора, полученная посредством разработанного генетического алгоритма автоматического поиска гибридных нейросетевых классификаторов. Использование данной нейросетевой модели позволило построить и обучить модель бэггинг-ансамбля, качество которого превышает как качество базовой модели гибридной нейронной сети, так и качество ансамблей классификаторов на основе деревьев принятия решений.

Вследствие преимущества модели ансамбля гибридных нейросетевых классификаторов для решения задачи определения технического состояния таких сложных объектов, как МКА, перспективным является дальнейшее исследование гибридных нейросетевых моделей на основе их комплексирования с „классическими“ моделями машинного обучения, моделями нелинейных отображений и методами обработки сигналов.

СПИСОК ЛИТЕРАТУРЫ

1. Искусственный интеллект. Текущее состояние в России и мире. Стратегия России // Альманах „Искусственный интеллект“. 2019. № 1 [Электронный ресурс]: <https://disk.yandex.by/i/JywGWfSz3HKkpw>.
2. Скобцов В. Ю., Новоселов Н. А. Исследование алгоритмов потоковой кластеризации при решении задачи анализа данных телеметрии малых космических аппаратов // Изв. вузов. Приборостроение. 2020. Т. 63, № 11. С. 1003–1011. DOI: 10.17586/0021-3454-2020-63-11-1003-1011.
3. Скобцов В. Ю., Архипов В. И. Нейросетевой анализ данных телеметрии бортовой аппаратуры космических аппаратов // Космическая техника и технологии. 2021. № 3(34). С. 111–124.
4. Fawaz H. I. et al. Deep learning for time series classification: A review // Data Mining and Knowledge Discovery. 2019. Vol. 33. P. 917–963 [Электронный ресурс]: <https://doi.org/10.48550/arXiv.1809.04356>.
5. Дудкин А. А. и др. Нейросетевая система мониторинга состояния и поведения подсистем космических аппаратов по телеметрическим данным для наземного командно-измерительного комплекса // VII Белорусский космический конгресс: Материалы конгресса, 24–26 окт. 2017, Минск. Минск, 2017. Т. 2. С. 193–196.
6. Marushko E. E., Doudkin A. A. Ensembles of Neural Networks for Forecasting of Time Series of Spacecraft Telemetry // Optical Memory and Neural Networks. 2017. Vol. 26, N 1. P. 47–54.
7. Rinkal Jain, Minal Rohit, Anand Kumar, Ayush Bakliwal, Ashwinkumar Makwana, Mrugendra Rahevar. Prediction of Telemetry Data using Machine Learning Techniques // Intern. Journal of Engineering Research & Technology. 2022. Vol. 11, iss. 09.
8. Chen Haoze, Zhijie Zhang. Hybrid neural network based on novel audio feature for vehicle type identification // Prof. of the IEEE Intern. Instrumentation and Measurement Technology Conf. (I2MTC), 25–28 May 2020. DOI: 0.1109/I2MTC43012.2020.9129183.
9. Zhao N. Combination of Convolution-al Neural Network and Gated Recurrent Unit for Aspect-Based Sentiment Analysis // IEEE Access. 2021. Vol. 9. P. 15561–15569. DOI: 10.1109/ACCESS.2021.3052937.
10. Skobtsov V. Yu. Binary classification of small satellites telemetry data based on deep learning approach // Applied Aspects of Information Technology. 2021. Vol. 4, N 4. P. 299–310.
11. Скобцов В. Ю., Соколов Б. В. Гибридные нейросетевые модели в задаче мультиклассовой классификации данных телеметрической информации малых космических аппаратов // Вестн. ВГУ. Системный анализ и информационные технологии. 2022. № 3. С. 99–114.
12. Скобцов В. Ю., Соколов Б. В., Чжан В.-А., Фу М. Гибридные нейросетевые модели мониторинга данных временных рядов сложных объектов // Изв. вузов. Приборостроение. 2024. Т. 67, № 2. С. 200–204. DOI: 10.17586/0021-3454-2024-67-2-200-204.
13. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. Sebastopol, CA: O'Reilly Media, Inc., 2019. 1065 p.
14. Skobtsov V. Y., Stasiuk A. Automatic Searching the Neural Network Models for Time Series Classification of Small Spacecraft's Telemetry Data with Genetic Algorithms // Artificial Intelligence Application in Networks and Systems; Lecture Notes in Networks and Systems. 2023. Vol. 724. P. 800–811.
15. Кирилин А. Н. и др. Основные проектные характеристики и результаты эксплуатации группировки малых космических аппаратов научно-образовательного назначения серии „Аист“ // Космическая техника и технологии. 2019. № 1(24). С. 68–83.

СВЕДЕНИЯ ОБ АВТОРЕ

Вадим Юрьевич Скобцов

— канд. техн. наук, доцент; Санкт-Петербургский государственный университет аэрокосмического приборостроения, кафедра компьютерных технологий и программной инженерии; доцент; СПИИРАН, лаборатория информационных технологий в системном анализе и моделировании; ст. научный сотрудник; E-mail: vasko_vasko@mail.ru

Поступила в редакцию 23.07.24; одобрена после рецензирования 31.07.24; принята к публикации 23.09.24.

REFERENCES

1. *Artificial Intelligence*, 2019, no. 1, 151 p., <https://disk.yandex.by/i/JywGWfSz3HKkpw>. (in Russ.)
2. Skobtsov V.Yu., Novoselova N.A. *Journal of Instrument Engineering*, 2020, no. 11(63), pp. 1003–1011, DOI: 10.17586/0021-3454-2020-63-11-1003-1011. (in Russ.)
3. Skobtsov V.Yu., Arhipau V.I. *Space Engineering and Technology*, 2021, no. 3(34), pp. 111–124. (in Russ.)

4. Fawaz H.I. et al. *Data Mining and Knowledge Discovery*, 2019, vol. 33, pp. 917–963, <https://doi.org/10.48550/arXiv.1809.04356>.
5. Dudkin A.A. et al. *VII Belorusskiy kosmicheskiy kongress (VII Belarusian Space Congress)*, Materials of the Congress, Minsk, October 24–26, 2017, vol. 2, pp. 193–196. (in Russ.)
6. Marushko E.E. and Doudkin A.A. *Optical Memory and Neural Networks*, 2017, no. 1(26), pp. 47–54.
7. Rinkal Jain, Minal Rohit, Anand Kumar, Ayush Bakliwal, Ashwinkumar Makwana, Mrugendra Rahevar, *International journal of engineering research & technology (IJERT)*, 2022, no. 09(11).
8. Haoze Chen, Zhijie Zhang, *IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, Proc. of the Intern. Conf., May 25–28, 2020, 2021, DOI: 0.1109/I2MTC43012.2020.9129183.
9. Zhao N. *IEEE Access*, 2021, vol. 9, pp. 15561–15569, DOI: 10.1109/ACCESS.2021.3052937.
10. Skobtsov V.Yu. *Applied Aspects of Information Technology*, 2021, no. 4(4), pp. 299–310.
11. Skobtsov V.Yu., Sokolov B.V. *Bulletin of the VSU. System analysis and information technology*, 2022, no. 3, pp. 99–114. (in Russian)
12. Skobtsov V.Yu., Sokolov B.V., Zhang W.A., Fu M. *Journal of Instrument Engineering*, 2024, no. 2(67), pp. 200–204, DOI: 10.17586/0021-3454-2024-67-2-200-204. (in Russ.)
13. Géron A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, Sebastopol, CA, O'Reilly Media, Inc., 2019, 1065 p.
14. Skobtsov V.Y., Stasiuk A. *Artificial Intelligence Application in Networks and Systems*, CSOC 2023, Lecture Notes in Networks and Systems, 2023, vol. 724, pp. 800–811.
15. Kirilin A.N. et al. *Space Engineering and Technology*, 2019, no. 1(24), pp. 68–83. (in Russ.)

DATA ON AUTHOR

Vadim Yu. Skobtsov

— PhD, Associate Professor; St. Petersburg State University of Aerospace Instrumentation, Department of Computer Technology and Software Engineering; Associate Professor; St. Petersburg Institute for Informatics and Automation of the RAS, Laboratory of Information Technologies in the System Analysis and Modeling; Senior Researcher;
E-mail: vasko_vasko@mail.ru

Received 23.07.24; approved after reviewing 31.07.24; accepted for publication 23.09.24.