

ГИБРИДНЫЕ НЕЙРОСЕТЕВЫЕ МОДЕЛИ В ЗАДАЧЕ МУЛЬТИКЛАССОВОЙ КЛАССИФИКАЦИИ ДАННЫХ ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ МАЛЫХ КОСМИЧЕСКИХ АППАРАТОВ

© 2022 В. Ю. Скобцов¹, Б. В. Соколов²✉

¹Объединенный институт проблем информатики НАН Беларуси
ул. Сурганова, 6, 220012 Минск, Беларусь

²Санкт-Петербургский Федеральный исследовательский центр Российской академии наук
14 линия, 39, 199178 Санкт-Петербург, Российская Федерация

Аннотация. В статье представлены решения актуальной задачи интеллектуального анализа данных телеметрической информации (ТМИ) бортовой аппаратуры (БА) малых космических аппаратов (МКА) с целью определения их технических состояний. Исследованы и разработаны гибридные нейросетевые модели на основе современных архитектур глубокого обучения для решения задачи мультиклассовой классификации данных телеметрической информации, позволяющие определять штатное и нештатные состояния функционирования БА МКА. Предложенная гибридная нейросетевая модель представляет собой соединение трех блоков слоев: сверточного 1D CNN, рекуррентного GRU и итогового полносвязного блока-классификатора, с применением слоя агрегации AveragePooling и метода проброса остаточных связей семейства архитектур ResNet. Проведен компьютерный анализ на данных ТМИ БА МКА группировки АИСТ Самарского национального исследовательского университета имени академика С.П. Королёва., позволивший оценить качество разработанной модели на этапах обучения, валидации и тестирования. Для рассматриваемой задачи достигнута точность классификации на этапах валидации и тестирования более 98 %. Выполнен сравнительный анализ полученной гибридной нейросетевой модели (ГНМ) с широко распространенными глубокими нейросетевыми классификаторами, показавший преимущество полученного решения по точности классификации на этапе тестирования для всех сравниваемых моделей на 1–7 %. При этом по времени одной эпохи обучения и валидации почти для всех сравниваемых моделей получено улучшение выходных характеристик ГНМ в 1.5–4 раза. Результаты данного анализа подтвердили преимущество гибридной нейросетевой модели, реализующей методологию квалиметрии моделей, над «чистыми» сверточными, рекуррентными, полносвязными нейронными сетями и широко известными гибридными нейросетевыми моделями.

Ключевые слова: гибридные нейросетевые модели, анализ данных, классификация, телеметрическая информация, полносвязные нейронные сети/слои, одномерные сверточные нейронные сети/слои, рекуррентные нейронные сети/слои.

ВВЕДЕНИЕ

Одной из важнейших задач на всех этапах жизненного цикла малых космических аппаратов является анализ их телеметрической информации о функционировании БА МКА

с точки зрения определения их технического состояния для обеспечения их штатного и безопасного функционирования. Актуальность обусловлена прежде всего тем, что одной из основных причин потерь МКА являются отказы, сбои и некорректная работа систем БА МКА.

Большое количество информации, поступающей и накапливающейся в специа-

✉ Соколов Борис Владимирович
e-mail: sokol@iias.spb.su



Контент доступен под лицензией Creative Commons Attribution 4.0 License.
The content is available under Creative Commons Attribution 4.0 License.

лизированных банках данных о БА МКА, может быть эффективно использовано для совершенствования процесса определения технического состояния МКА. В связи с тем, что данные о функционировании БА МКА, включающие телеметрические измерения, представляют собой разнородные нерегулярные многомерные данные, актуальным является исследование, разработка и применение моделей, которые позволяют анализировать такого рода данные с возможностью извлечения из них полезной информации и последующего построения с их использованием классификационных и прогностических моделей с целью определения технического состояния МКА для принятия корректных управляющих и эксплуатационных решений в процессе функционирования МКА.

Методы машинного обучения, искусственного интеллекта и биоинспирированных технологий являются на текущий момент одними из самых перспективных и широко используемых подходов в анализе данных высокотехнологичных систем. Яркими и широко известными примерами их применения являются разработки таких компаний как Yandex, Facebook, Google, Amazon, научно-исследовательских центров МИТ, университетов Кэмбриджа, Стенфорда, Беркли, Принстона, Южной Калифорнии, МГТУ им. Баумана, МФТИ, ВШЭ, СПИИРАН.

В современных условиях для решения перечисленных задач, обеспечения требуемой степени автономности, качества и оперативности управления такими сложными объектами как МКА необходимо выполнить комплексную автоматизацию и интеллектуализацию процессов оценивания и многомодельного анализа данных телеметрической информации МКА. Однако, в большинстве случаев на практике автоматизация выполнена, в лучшем случае, лишь частично, и многое делается зачастую вручную, базирясь на эвристических правилах [1]. При этом в соответствии с ГОСТ 1410-002-2010 и Стратегией цифровой трансформации ракетно-космической отрасли до 2025 г. и перспективой до 2030 г. для Госкорпорации «Роскосмос» важной задачей является создание так назы-

ваемой системы информации о техническом состоянии и надежности космических комплексов и входящих в их состав изделий [2, 3].

Таким образом, задача интеллектуального анализа данных телеметрии БА МКА с целью определения технического состояния БА МКА является актуальной и востребованной.

С целью решения данной актуальной задачи в рамках программы Союзного государства «Мониторинг СГ» и партнёрских проектов Объединенного института проблем информатики НАН Беларуси и Санкт-Петербургского института информатики и автоматизации РАН был разработан экспериментальный образец комплекса программных средств и методик для анализа показателей надёжности БА МКА и интеллектуального анализа данных ТМИ БА малых КА [4–6]. В ходе создания комплекса были разработаны и исследованы методы определения состояний функционирования БА МКА на основе подходов кластерного анализа, то есть принципа обучения без учителя. Были предложены методы нейросетевой кластеризации на основе построения карты Кохонена и методов обработки изображений, и потоковой динамической кластеризации [7–9].

Продолжением данных исследований и результатов стали разработка и исследование гибридных глубоких нейросетевых моделей для решения задачи бинарной классификации данных ТМИ подсистемы БА Белорусского космического аппарата, опубликованные в работе [10]. Как развитие полученных для предыдущего случая результатов в данной статье представлены гибридные глубокие нейросетевые модели для решения задачи мультиклассовой классификации данных ТМИ БА МКА АИСТ-1 Самарского национального исследовательского университета имени академика С.П. Королёва с целью определения состояний штатного функционирования, отказа и сбоя.

1. ЗАДАЧА МУЛЬТИКЛАССОВОЙ КЛАССИФИКАЦИИ ДАННЫХ ТМИ МКА

Исходные телеметрические данные описаны временным рядом, который можно пред-

ставить как матрицу $\mathbf{X} = (x_{ij})$, где i -я строка \mathbf{X}_i является анализируемым вектором показателей ТМИ в i -й момент времени, индекс j соответствует j -му показателю ТМИ в i -м векторе \mathbf{X}_i .

Определение 1. Одномерный временной ряд $\mathbf{X} = (x_1, x_2, \dots, x_T)$ — упорядоченный набор вещественных значений. Длина \mathbf{X} равна количеству вещественных значений T .

Определение 2. M -мерный временной ряд $\mathbf{X} = (X_1, X_2, \dots, X_M)$ состоит из M различных одномерных временных рядов $X_j \in R^T$.

Очевидно, что рассматриваемый временной ряд данных ТМИ является M -мерным временным рядом $\mathbf{X} = (X_1, X_2, \dots, X_M)$.

Для каждого вектора показателей ТМИ в i -й момент времени \mathbf{X}_i в соответствие поставлена метка класса $y_i \in Y$, который характеризует состояние функционирования анализируемого по данным ТМИ БА МКА или его подсистемы. В исследуемой задаче мы рассматриваем 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 и $k - 1$ нештатным состояниям. В этом случае значения компонент вектора меток классов $Y \in \{0, 1, \dots, k - 1\}$, где 0 обозначает штатное состояние и $1, \dots, k - 1$ — нештатные состояния анализируемого МКА или его подсистемы. Таким образом, стоит задача нахождения модели следующего отображения:

$$y: X \rightarrow Y.$$

При этом для кодирования меток классов будем использовать так называемое One Hot кодирование. В этом случае вектору \mathbf{X}_i M -мерного временного ряда \mathbf{X} соответствует не скалярное значение метки класса, а вектор $Y_i = (y_{i0}, y_{i1}, \dots, y_{ik-1})$ размерности k . При этом в векторе Y_i присутствует только одно значение 1, соответствующее метке класса. На рис. 1 приведен пример One Hot кодирования для $k = 3$, то есть для случая 3-классовой классификации.

	0	1	2
472	1	0	0
473	0	1	0
474	0	1	0
475	0	1	0
476	0	1	0
477	0	1	0
478	0	1	0
479	0	1	0
480	0	1	0
481	1	0	0
482	1	0	0
483	1	0	0
484	1	0	0

Рис. 1. One Hot кодирование меток классов для $k = 3$

[Fig. 1. One Hot encoding of class labels for $k = 3$]

2. МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ В ЗАДАЧЕ КЛАССИФИКАЦИИ ВРЕМЕННЫХ РЯДОВ

В течение последних двух десятилетий классификация временных рядов считается одной из самых сложных проблем в области интеллектуального анализа данных [16, 17]. С увеличением доступности временных данных [18], сотни алгоритмов были предложены, начиная с 2015 года [19]. Фактически, любая проблема классификации, использующая данные, которые регистрируются с учетом некоторого понятия упорядочивания можно рассматривать как проблему классификации временного ряда [11]. Временные ряды встречаются во многих реальных приложениях: обработки электронных медицинских карт, распознавания человеческой деятельности, классификации акустических сцен, кибербезопасности, анализа состояний функционирования МКА по данным ТМИ [7–15].

Свежие публикации были сосредоточены на разработке методов ансамбля [20–23]. Эти подходы используют либо ансамбль деревьев

решений (случайный лес), либо ансамбль различных типов дискриминантных классификаторов (машины опорных векторов (SVM), классификаторы k ближайших соседей (kNN) с несколькими функциями расстояния) на одном или нескольких пространствах признаков. Большинство из этих подходов имеют этап предобработки данных, на котором преобразуются исходные временные ряды.

Данный подход послужил стимулом для разработки ансамбля из 35 классификаторов под названием COTE (Collective Of Transformation-based Ensembles) [20], который не только объединяет разные классификаторы для одного и того же преобразования, но и объединяет разные классификаторы для разных представлений временных рядов. В работах [24, 25] преимущества COTE были улучшены с помощью системы иерархического голосования, получившей названия метода NIVE-COTE. NIVE-COTE в настоящее время считается передовым методом классификации временных рядов среди классических методов и моделей машинного обучения при оценке по 85 наборам данных из архива UCR/UEA [19]. Для достижения высокой точности NIVE-COTE становится чрезвычайно требовательным к вычислениям и непрактичным для решения реальных проблем интеллектуального анализа больших данных [19]. Этот подход требует обучения 37 классификаторов, а также перекрестной валидации каждого гиперпараметра этих алгоритмов, что делает невозможным обучение соответствующей модели в некоторых ситуациях. Чтобы подчеркнуть эту невозможность, обратим внимание, что одним из этих 37 классификаторов является преобразование Shapelet [21], временная сложность которого составляет $O(n^2l^4)$, где n — количество временных рядов в наборе данных, а l — длина временного ряда.

Проанализировав текущее состояние классических неглубоких (не нейросетевых) моделей классификаторов и установив непрактичность указанных передовых подходов для решения реальных задач интеллектуального анализа больших данных в случае задачи классификации временных рядов, мы сосредоточим далее основное внимание

в статье на моделях глубокого обучения или нейросетевых моделях, последние годы широко применявшихся для решения различных задач интеллектуального анализа больших данных [26], которые мотивировали их использование при исследовании задач анализа временных рядов [11, 14, 27].

3. НЕЙРОСЕТЕВЫЕ МОДЕЛИ ГЛУБОКОГО ОБУЧЕНИЯ

Искусственные нейронные сети являются удобным и естественным базисом для представления информационных моделей. Нейросетевая модель, состоящая из совокупности связанных между собой искусственных нейронов, представляет собой биоинспирированную модель нейронных биологических систем [28, 29].

Нейронные сети находят эффективное применение в задачах анализа различных типов данных: изображений, видеорядов, текстовых и аудио данных, в том числе в задачах классификации данных временных рядов различной природы [8–15, 30, 31]. К базовым современным типам нейронных сетей/слоев, применяемых в задачах анализа временных рядов, можно отнести следующие:

- полносвязные нейронные сети/слои (многослойных перцептронов, MLP) [30, 31];
- одномерные сверточные нейронные сети/слои (1D CNN) [30, 31];
- рекуррентные нейронные сети/слои типа *Long Short-Term Memory* (LSTM) и *Gated Recurrent Units* (GRU) [30–32].

Полносвязные нейронные сети/слои можно рассмотреть на примере следующего 2-слойного MLP, который представлен на рис. 2 и задан формулами

$$Z^1 = W^1 X + b^1; \quad A^1 = a_1(Z^1); \quad Z^2 = W^2 X + b^2; \\ \hat{y} = A^2 = a_2(Z^2),$$

где W^i — значения весовых коэффициентов, $a_i(Z^i)$ — активационные функции слоев.

В отличие от двумерных сверточных нейронных сетей/слоев, применяемых в анализе изображений, мы будем исследовать одномерные сверточные сети/слои [17, 31]. Аналогично двумерным сверткам, извлекающим двумер-




Рис. 2. Пример 2-слойной полносвязной сети [Fig. 2. An example of a two-layer fully-connected neural network]

ные шаблоны из тензоров с изображениями и применяющими идентичные преобразования к каждому такому шаблону, можно использовать одномерные свертки для извлечения одномерных шаблонов (подпоследовательностей) из временных рядов. Такие одномерные сверточные слои способны распознавать локальные шаблоны в последовательности.

В отличие от MLP, одна и та же свертка (те же значения фильтра w и b) будет использоваться для нахождения результата для всех отметок времени $t \in [1, T]$. Это очень мощное свойство 1D CNN, которое позволяет им изучать фильтры, инвариантные во временном измерении. При рассмотрении временного ряда в качестве входных данных для сверточного слоя фильтр больше не имеет одного измерения (времени), но также имеет измерения, которые равны количеству измерений входного временного ряда. Поскольку к каждому шаблону применяются одни и те же преобразования, тот или иной шаблон, найденный в некоторой позиции в последовательности, позднее может быть опознан в другой позиции, что делает преобразования, выполняемые 1D CNN сетями/слоями, инвариантными (во времени). Например, 1D CNN сеть, обрабатывающая последовательность значений и использующая окно свертки с размером 5, способна запоминать подпоследовательности ряда длиной до 5 элементов и распознавать их в любом контексте во входной последовательности временного ряда (рис. 3).

Наконец, вместо того, чтобы вручную настраивать значения фильтра ω , эти значения следует изучать автоматически, поскольку они сильно зависят от целевого набора дан-

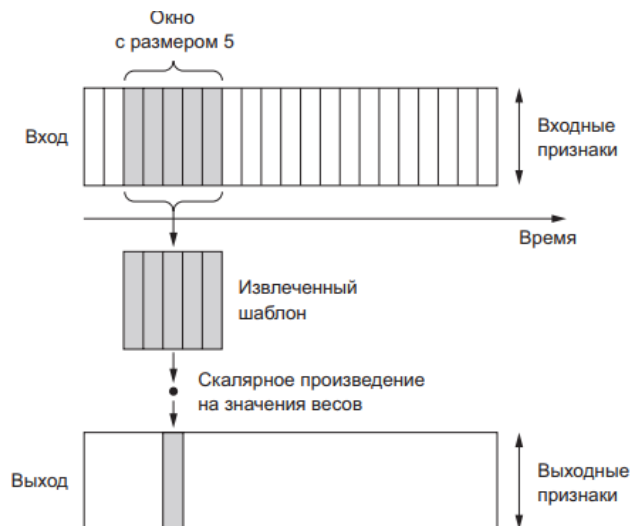


Рис. 3. Принцип действия одномерной сверточной нейронной сети/слоя [Fig. 3. The principle of operation of a one-dimensional convolutional neural network/layer]

ных. Например, один набор данных будет иметь оптимальный фильтр, равный $(1, 2, 2)$, тогда как другой набор данных будет иметь оптимальный фильтр, равный $(2, 0, -1)$. Под оптимальным мы понимаем фильтр, применение которого позволит классификатору легко различать классы набора данных [17, 31].

Извлеченная сверткой информация, подается, как и в случае с MLP, на вход активационной функции $a(Z)$. За блоком слоев 1D CNN должен следовать дискриминантный классификатор, который обычно является блоком полносвязных MLP слоев. Ему может предшествовать операция агрегации (Pooling), которая также может присутствовать как промежуточный слой между блоками 1D CNN слоев. Pooling средний (Average-Pooling) или максимальный (MaxPooling) принимает входной временной ряд и сокращает его длину T путем агрегирования в скользящем окне временного ряда. Например, если длина скользящего окна равна 3, результирующий объединенный временной ряд будет иметь длину, равную $T/3$ — это верно, только если шаг равен длине скользящего окна. Суть агрегации в поэлементном умножении в скользящем окне подпоследовательности на маску, вычислении среднего или максимального значения и замещении им подпоследовательности.

Отличительной чертой нейронных сетей/слоев, которые мы рассмотрели, является отсутствие памяти. Каждый вход обрабатывается ими независимо, без сохранения состояния между ними. Рекуррентная нейронная сеть (RNN) обрабатывает последовательность, перебирая ее элементы и сохраняя состояние, полученное при обработке предыдущих элементов. Фактически RNN — это разновидность нейронной сети, имеющей внутреннее состояние [30, 31] (рис. 4). При этом RNN напоминает микроэлектронные последовательностные схемы с памятью, разложенные в свой комбинационный итеративный эквивалент.

Одна из широко известных моделей RNN — это LSTM RNN (Long Short-Term Memory — длинная краткосрочная память). Ячейка LSTM представлена на рис. 5 и состоит из трех основных узлов-гейтов: input gate, forget gate и output gate, которые образуют рекуррентную ячейку со скрытым состоянием. Если обозначить через x_t входной вектор в момент времени t , h_t — вектор скрытого состояния, W_i (с разными вторыми индексами) — матрицы весов, применяющиеся ко входу, W_h — матрицы весов в рекуррентных соединениях, b — векторы свободных членов, мы получим следующее формальное определение того, как работает LSTM: на очередном входе x_t , имея скрытое состояние из предыдущего шага h_{t-1} и собственно состояние ячейки c_{t-1} , мы последовательно вычисляем [30]:




Рис. 4. Общая схема рекуррентной нейронной сети/слоя
[Fig. 4. General diagram of a recurrent neural network/layer]

$$\begin{aligned}
 c'_t &= \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b'_c) && \text{candidate state,} \\
 i_t &= \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) && \text{input gate,} \\
 f_t &= \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) && \text{forget gate,} \\
 o_t &= \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) && \text{output gate,} \\
 c_t &= f_t \circ c_{t-1} + i_t \circ c'_t && \text{cell state,} \\
 h_t &= o_t \circ \tanh(c_t) && \text{block output.}
 \end{aligned}$$

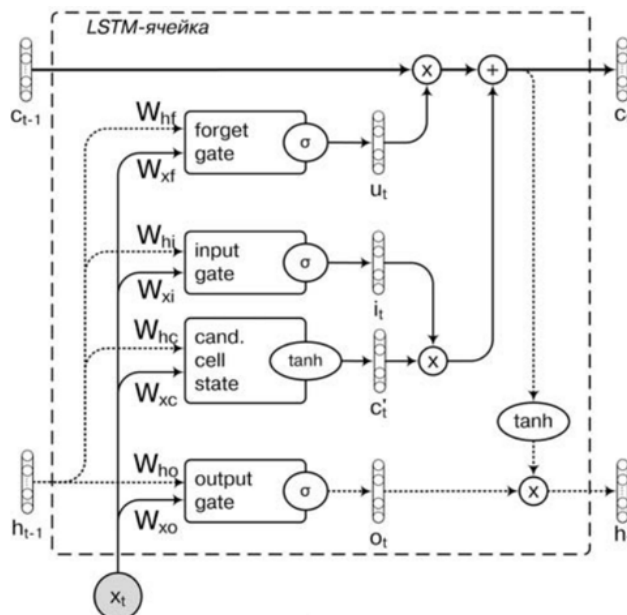


Рис. 5. Структура LSTM ячейки
[Fig. 5. LSTM cell structure]

В работе [32] 2014 года была предложена модификация LSTM рекуррентных сетей — Gated Recurrent Units (GRU), которая уменьшала сложность LSTM моделей и сокращала время обучения. В этой архитектуре скрытое состояние h_t совмещено со значением памяти c_t . Вот как работает одна GRU-ячейка [30]:

$$\begin{aligned}
 u_t &= \sigma(W_{xu}x_t + W_{hu}h_{t-1} + b_u), \\
 r_t &= \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r), \\
 h'_t &= \tanh(W_{xh}x_t + W_{hh}(r_t \circ h_{t-1})), \\
 h_t &= (1 - u_t) \circ h_{t-1} + u_t \circ h'_t.
 \end{aligned}$$

Здесь u_t — это update gate, r_t — это reset gate, он тоже отвечает за то, какую часть памяти нужно перенести дальше с прошлого шага, но делает это еще до применения нелинейной функции. Ячейка памяти и выход блока h_t в данном случае, в отличие от LSTM, никак не разделяются, и следующий выход h_t получается как комбинация (задаваемая гейтом u_t) предыдущего выхода h_{t-1} и текущего канди-

дата на выход h'_t , который, в свою очередь, тоже зависит от h_{t-1} , но через гейт перезагрузки r_t (рис. 6).




Рис. 6. Структура GRU ячейки
[Fig. 6. GRU cell structure]

4. ГИБРИДНЫЕ НЕЙРОСЕТЕВЫЕ МОДЕЛИ

В последнее десятилетие эффективное применение в задачах анализа различных типов данных (текстовых, аудио, временных рядов финансовых аналитических трендов и т. п.) находят так называемые гибридные глубокие нейронные сети, которые объединяют в своей архитектуре комбинации различных типов современных нейронных слоев:

- полносвязных нейронных сетей/слоев;
- одномерных сверточных нейронных сетей/слоев (1D CNN);
- рекуррентных нейронных сетей/слоев типа *Long Short-Term Memory* (LSTM) и *Gated Recurrent Units* (GRU).

Известно, что перечисленные типы нейронных сетей независимо друг от друга являются эффективными инструментами в решении задач анализа различного типа данных. Однако в работах [33–35] приведены еще более интересные результаты в смысле точности полученных решений для гибридных нейросетевых моделей.

Ранее в работе [10] была продемонстрирована эффективность гибридных нейросетевых моделей для решения задачи бинарной нейросетевой классификации данных ТМИ Белорусского космического аппарата с целью определения штатного и нештатного технического состояния одной из подсистем его БА. Проведенное исследование показало существенно более высокую точность бинарной классификации с помощью гибридных нейросетевых моделей по сравнению с «чистыми» полносвязными, одномерными сверточными и рекуррентными нейронными сетями, а также превосходство по точности и времени обучения и валидации по сравнению с широко известными глубокими нейросетевыми моделями.

В развитие данных исследований в данной работе приводятся результаты по разработке и анализу гибридных нейросетевых моделей для решения задачи k -классовой классификации для случая $k = 3$ данных ТМИ БА МКА АИСТ-1 Самарского национального исследовательского университета имени академика С. П. Королёва с целью определения состояний штатного функционирования, отказа и сбоя [37].

В работе [10] было экспериментально показано преимущество гибридной архитектуры на основе описанных выше базовых нейросетевых слоев: сверточного 1D CNN, рекуррентного слоях типа GRU и полносвязного классификационного. Было также экспериментально доказано преимущество использования слоя агрегации методом *AveragePooling* по сравнению с *MaxPooling* в блоках одномерных сверточных слоев. Полученная гибридная архитектура была также усилена с помощью методики добавления остаточных связей, развитие которой началось с появления семейства сетей *ResNet*, разработанного Kaiming He с коллегами в *Microsoft* [31, 36] (рис. 7).

Ниже приводится псевдокод предложенной гибридной нейросетевой модели *Hybrid Neural Network for Telemetry data AIST analysis — Hybrid_NN_TD_AIST*, состоящей из двух блоков одномерных сверточных слоев 1D CNN по десять слоев каждый,

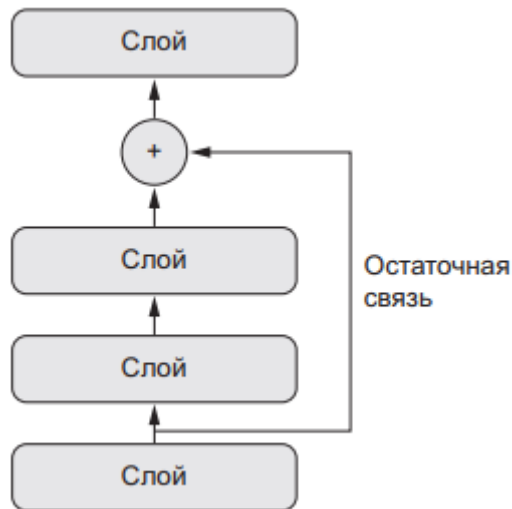


Рис. 7. Остаточные связи: повторное внедрение предыдущей исходящей информации добавлением в карту признаков поздних слоев

[Fig. 7. Residual connection: reinjection of prior information by adding to the feature map of later layers]

которые разделяются агрегационными слоями AveragePooling. Далее гибридная модель продолжается рекуррентным слоем типа GRU и двумя полносвязными классификационными слоями. Также в сети применяется методика проброса остаточных связей семейства ResNet.

```
Z1 = Conv1D(filters=n, kernel_size=4,
activation='relu') (Xi)
Z1 = Conv1D(filters=n, kernel_size=4,
activation='relu') (Z1) * 9 слоев
Z2 = add([Z1, Xi]) – проброс остаточной
связи входа Xi
Z2 = AveragePooling_1D(2)(Z2)
Z3 = Conv1D(filters=n, kernel_size=2,
activation='relu') (Z2)
Z3 = Conv1D(filters=n, kernel_size=2,
activation='relu') (Z3) * 9 слоев
Z4 = AveragePooling (2)(Z3)
Output = add([Z2, Z3, Z4]) – проброс оста-
точных связей Z2 и Z3
Output = GRU(units=32)
Output = Dense(32, activation='relu')
(Output)
Output = Dense(3, activation='softmax')
(Output)
```

В качестве активационных функций используем следующие широко используемые функции [30, 31]:

- функция relu — rectified linear unit, линейный выпрямитель $\text{relu}(z) = \max(0, z)$;
- обобщение логистической функции для One-Hot кодирования меток классов

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=0}^{k-1} e^{z_j}}$$

В качестве функции ошибки будем использовать функцию категориальной кроссэнтропии (categorical crossentropy), поскольку для случая $k = 3$ мы решаем задачу мультiclassовой классификации [30, 31].

Для проведения компьютерных экспериментов и анализа точности разработанных нейросетевых классификационных моделей использованы данные о ТМИ всей бортовой аппаратуры МКА АИСТ-1.

Вектор матрицы ТМИ после экспертного отбора существенных для анализа признаков X_i имеет размерность 49 и помечается 0 в случае штатного состояния, 1 в случае отказа, 2 — сбоя. Общая размерность 49-мерного временного ряда X составляет 2679 векторов, из которых 1714 векторов составляет обучающий набор данных, 429 векторов составляет валидационный набор данных и 536 векторов составляет тестовый набор данных.

Обучение проводилось на 750 эпохах. В рекуррентном и полносвязном слоях применялась соответственно l_2 и l_1 регуляризация для борьбы с переобучением. В качестве метода обучения применялся метод Adam как один из наиболее эффективных с точки зрения точности классификации обучаемой модели [30, 31].

Результаты компьютерных экспериментов, каждый из которых характеризовался соответствующими значениями показателя точности и функции потерь на обучающем, валидационном и тестовом наборах показали лучшие значения указанного показателя и функции потерь для количества фильтров в блоках сверточных слоев равных $n = 8$.

Проведен сравнительный анализ полученной гибридной нейросетевой модели *Hybrid_NN_TD_AIST* с широко распространенными глубокими нейросетевыми классификаторами: LeNet, AlexNet, Xception, Yolo, MobileNet, Inception, ResNet, модифицированными для

анализа временных рядов. За основу был использован программный код из репозитория серии онлайн семинаров «Machine Learning Tokyo — Democratizing Machine Learning» [38]. Результаты анализа в виде значений показателя точности классификации на этапах обучения, валидации и тестирования, времени одной эпохи обучения и валидации приведены в табл. 1.

Из табл. 1 видно, что по точности классификации на этапах валидации и тестирования данных ТМИ БА МКА АИСТ предложенная гибридная модель *Hybrid_NN_TD_AIST* превосходит стандартные глубокие нейросетевые модели. По времени одной эпохи обучения и валидации разработанная модель сравнима (2 сек.) с моделью AlexNet, но превосходит ее по точности классификации на этапе тестирования на 2 %. Модели LeNet и Yolo превосходят разработанную модель по времени — 1 сек. < 2 сек., но уступают по точности на этапе тестирования на 1–2 %. Остальные модели уступают предложенной модели по точности классификации на 1–7 % и по времени одной эпохи обучения и валидации в 1.5–4 раза. Преимущество в точности и времени может показаться небольшим, но в ситуации увеличении точности на «последней миле» (>90 %) прирост точности в 1–7 % является

существенным, особенно для таких критически важных объектов как МКА. Также, как и преимущество в несколько секунд для более объемных реальных данных приводит к существенному выигрышу по времени в целом.

ЗАКЛЮЧЕНИЕ

Разработана и исследована гибридная нейросетевая модель *Hybrid_NN_TD_AIST* на основе современных архитектур глубокого обучения для решения задачи мультиклассовой классификации данных ТМИ, с помощью которой осуществляется классификация состояний БА МКА. Проведен компьютерный анализ на данных реальной ТМИ БА МКА АИСТ, позволивший оценить качество разработанной модели на этапах обучения, валидации и тестирования. В основу указанного анализа были положены результаты исследований по многокритериальному оцениванию качества моделей, которые были ранее выполнены в рамках разрабатываемой авторами статьи квалиметрии моделей и полимодельных комплексов [39]. Данный анализ также показал преимущество нейросетевых моделей, представляющих собой последовательное соединение трех блоков слоев: сверточного 1D CNN, рекуррентного GRU и ито-

Таблица 1. Сравнительные экспериментальные данные модифицированных нейросетевых моделей и разработанной гибридной модели для классификации данных ТМИ АИСТ-1
 [Table 1. Comparative experimental data of modified neural network models and the developed hybrid model for classifying AIST-1 telemetry data]

Тип нейросетевой модели	Обучающий набор		Валидационный набор		Тестовый набор		Время обучения одной эпохи, сек
	Точность	Функция потерь	Точность	Функция потерь	Точность	Функция потерь	
LeNet	0.9977	0.0111	0.9744	0.2584	0.9757	0.1947	1
AlexNet	0.9988	0.0012	0.9697	0.3616	0.9682	0.2932	2
Xception	0.9988	0.0024	0.9744	0.1961	0.9646	0.2506	8
Yolo	0.9977	0.0127	0.9650	0.1918	0.9646	0.2602	1
MobileNet	0.9942	0.0221	0.9464	0.2811	0.9160	0.3289	3
Inception	0.9837	0.0607	0.9674	0.0927	0.9539	0.1154	4
ResNet	0.9942	0.0397	0.9782	0.0881	0.9757	0.0755	8
Hybrid_NN_TD_AIST	0.9977	0.0349	0.9814	0.0869	0.9851	0.0790	2

гового полносвязного блока-классификатора, с применением слоя агрегации AveragePooling и метода проброса остаточных связей семейства архитектур ResNet. В целом при решении рассматриваемой задачи достигнута точность классификации на этапах валидации и тестирования более 98 %. Проведен сравнительный анализ полученной гибридной нейросетевой модели Hybrid_NN_TD_AIST с широко распространенными глубокими нейросетевыми классификаторами: LeNet, AlexNet, Xception, Yolo, MobileNet, Inception, ResNet, показавший преимущество разработанной гибридной модели. Перспективным является дальнейшее исследование современных нейросетевых архитектур для задачи бинарной и мультiclassовой классификации временных рядов, а также методов автоматизации поиска оптимальных значений гиперпараметров моделей.

Исследования, выполненные по данной тематике, проводились при финансовой поддержке программы научных исследований докторанта Скобцова В. Ю. кафедры ПОИТ Белорусского государственного университета информатики и радиоэлектроники, ГПНИ «Информатика, космос и безопасность» НИР «Поведенческие и интеллектуальные методы обнаружения атак в телекоммуникационных сетях» ОИПИ НАН Беларуси (разделы 3, 4, Заключение), а также при финансовой поддержке гранта РНФ №22-19-00767 (Введение, разделы 1,2).

КОНФЛИКТ ИНТЕРЕСОВ

Авторы декларируют отсутствие явных и потенциальных конфликтов интересов, связанных с публикацией настоящей статьи.

СПИСОК ЛИТЕРАТУРЫ

1. Концепция проактивного управления сложными объектами: теоретические и технологические основы / М. Ю. Охтилев [и др.] // Известия вузов. Приборостроение. – 2014. – Т. 57, № 11. – С. 7–14.

2. ГОСТ РО 1410-002-2010. Ракетно-космическая техника. Система информации о

техническом состоянии и надежности космических комплексов и входящих в их состав изделий. – Введ. 2011-01-01. Москва : Изд-во стандартов, 2011. – 49 с.

3. Проект стратегии информационных технологий Госкорпорации «Роскосмос». – URL: <https://www.roscosmos.ru/25892/> (Дата обращения 2020-11-15).

4. Зеленцов, В. А. Сервис-ориентированный распределённый программный комплекс для оценивания и многокритериального анализа показателей надёжности и живучести бортовой аппаратуры малых космических аппаратов: российский и белорусский сегменты / В. А. Зеленцов [и др.] // Актуальные проблемы ракетно-космической техники» (V Козловские чтения) : сб. тр. V Всероссийской научно-технической конференции с международным участием (Самара, 11-15 сентября 2017 г.). – Самара, 2017. – С. 45–56.

5. Зеленцов, В. А. Распределённый программный комплекс для оценивания и анализа показателей надёжности и живучести бортовой аппаратуры малых космических аппаратов / В. А. Зеленцов [и др.] // Актуальные проблемы создания космических систем дистанционного зондирования Земли: тезисы докладов Шестой международной научно-технической конференции (Москва, 24 мая 2018 г.). – Москва, 2018. – 146 с.

6. Сервис-ориентированный распределённый программный комплекс для оценивания и многокритериального анализа показателей надёжности и живучести бортовой аппаратуры малых космических аппаратов: российский и белорусский сегменты / В. А. Зеленцов [и др.] // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. – 2017. – Т. 16, № 4. – С. 118–129. DOI: 10.18287/2541-7533-2017-16-4-118-129

7. Скобцов, В. Ю. Исследование алгоритмов потоковой кластеризации в решении задачи анализа данных телеметрии малых космических аппаратов / В. Ю. Скобцов, Н. А. Новоселова // Известия вузов. Приборостроение. – 2020. – Т. 63, № 11. – С.1003–1011. DOI: 10.17586/0021-3454-2020-63-11-1003-1011

8. Intelligent Telemetry Data Analysis of Small Satellites / V. Skobtsov [et al.] // In: Sil-

havy R., Senkerik R., Kominkova Oplatkova Z., Prokopova Z., Silhavy P. (eds) *Cybernetics and Mathematics Applications in Intelligent Systems*. CSOC 2017. *Advances in Intelligent Systems and Computing* – Springer International Publishing Switzerland. – 2017. – V. 574. – P. 351–361. DOI:10.1007/978-3-319-57264-2_36

9. Скобцов, В. Ю. Нейросетевой анализ данных телеметрии бортовой аппаратуры космических аппаратов / В. Ю. Скобцов, В. И. Архипов // *Космическая техника и технологии*. – 2021. – № 3(34). – С.111–124.

10. Skobtsov, V. Yu. Binary classification of small satellites telemetry data based on deep learning approach / V. Yu. Skobtsov // *Applied Aspects of Information Technology*. – 2021. – Vol. 4, No.4. – P. 299–310.

11. Borges Gamboa John Cristian Deep learning for time-series analysis. – Режим доступа: <https://arxiv.org/pdf/1701.01887.pdf>

12. Scalable and accurate deep learning for electronic health records / A. Rajkomar [et al] // *NPJ Digital Medicine*. – 2018. – May. – P.1:18. <https://europaemc.org/article/med/31304302> DOI: 10.1038/s41746-018-0029-1

13. Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: state of the art and research challenges / H. F. Nweke // *Expert Systems with Applications*. – 2018. – Vol. 105. – P. 233–261. <https://doi.org/10.1016/j.eswa.2018.03.056>

14. New, T. L. Convolutional neural network with multi-task learning scheme for acoustic scene classification / T. L. Nwe, T. H. Dat, B. Ma // *Annual Summit and Conference 2017: proceedings of APSIPA*. – P. 1347–1350. DOI: 10.1109/APSIPA.2017.8282241

15. Time-series classification methods: review and applications to power systems data // *Big data application in power systems* / G. A. Susto [et al]. – Elsevier Inc., 2018. – Chapter 9. –P. 179–220. <https://doi.org/10.1016/B978-0-12-811968-6.00009-7>

16. Yang, Q. 10 challenging problems in data mining research / Q. Yang Q, X. Wu // *International Journal of Information Technology & Decision Making*. – 2006. – Vol. 05, No. 04. – P. 597–604. <https://doi.org/10.1142/S0219622006002258>

17. Muller Deep learning for time series classification: a review / Hassan Ismail Fawaz [et al.] // *Data Mining and Knowledge Discovery*. – 2019. – Vol. 33. – P. 917–963. <https://doi.org/10.48550/arXiv.1809.04356>

18. Speeding up similarity search under dynamic time warping by pruning unpromising alignments / D. F. Silva [et al.] // *Data Mining and Knowledge Discovery*. – 2018. – Vol. 32, No 4. – P. 988–1016. <https://doi.org/10.1007/s10618-018-0557-y>.

19. The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances / A. Bagnall [et al.] // *Data Mining and Knowledge Discovery*. – 2017. – Vol. 31, No 3. – P. 606–660. <https://doi.org/10.1007/s10618-016-0483-9>

20. Bagnall A. Time-series classification with COTE: the collective of transformation-based ensembles / A. Banall [st al.] // *2016 IEEE 32nd International Conference on Data Engineering (ICDE): proceedings (May 2016)*. – 2016. – P. 1548–1549. DOI:10.1109/ICDE.2016.7498418

21. Classification of time series by shapelet transformation / J. Hills [et al.] // *Data Mining and Knowledge Discovery*. – 2014. – Vol. 28, No 4. – P. 851–881. <https://doi.org/10.1007/s10618-013-0322-1>

22. Bostrom, A. Binary shapelet transform for multiclass time series classification / A. Bostrom, A. Bagnall // *Conference on Big Data Analytics and Knowledge Discovery: proceedings of the International Conference*. – 2015. – P. 257–269. DOI: 10.1007/978-3-319-22729-0_20

23. Baydogan, M. G. Multivariate time series classification datasets. – <http://www.mussta-fabaydogan.com>. (Дата обращения: 5.10.2021).

24. Lines, J. HIVE-COTE: the hierarchical vote collective of transformation-based ensembles for time series classification / J. Lines, S. Taylor, A. Bagnall // *2016 IEEE 16th International Conference on Data Mining (ICDM): proceedings of the international conference (December 2016)*. – P. 1041–1046. DOI:10.1109/ICDM.2016.0133

25. Lines, J. Time series classification with HIVE-COTE: the hierarchical vote collective of transformation-based ensembles / J. Lines, S. Taylor, A. Bagnall // *ACM Trans Knowl Discov*

- Data. – 2018. – Vol. 2, Issue. 5. – Article No 52. – P. 1–35. <https://doi.org/10.1145/3182382>
26. *LeCun, Y.* Deep learning / Y. LeCun, Y. Bengio, G. Hinton // *Nature*. – 2015. – Vol. 521. – P. 436–444. <http://dx.doi.org/10.1038/nature14539>
27. *Wang Z., Yan W., Oates T.* Time series classification from scratch with deep neural networks: a strong baseline // 2017 International Joint Conference on Neural Networks (IJCNN): proceedings of the international joint conference (May 2017). – 2017. – P. 1578–1585. DOI: 10.1109/IJCNN.2017.7966039
28. *Горбань, А. Н.* Нейроинформатика / А. Н. Горбань [и др.]. – Новосибирск : Наука, 1998. – 296 с.
29. *Царегородцев, В. Г.* Нейроимитатор NEUROPRO / В. Г. Царегородцев // Нейроинформатика и ее приложения : тез. докл. VI Всероссийского семинара (2–5 октября 1998 г.) / под ред. А. Н. Горбаня. – Красноярск, 1998. – 207 с.
30. *Николенко, С.* Глубокое обучение / С. Николенко, А. Кадури, Е. Архангельская. – СПб. : Питер, 2018. – 480 с.
31. *Шолле, Ф.* Глубокое обучение на Python / Ф. Шолле. – СПб. : Питер, 2018. – 400 с.
32. *Cho, Kyunghyun.* Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation / Kyunghyun Cho [et al.] // *Empirical Methods in Natural Language Processing (EMNLP): proceedings of the 2014 Conference*. – 2014. – arXiv:1406.1078. DOI: 10.3115/v1/D14-1179
33. *Lin, Tao.* Hybrid Neural Networks for Learning the Trend in Time Series / Tao Lin, Tian Guo, Karl Aberer // *Artificial Intelligence (IJCAI-17): proceedings of the Twenty-Sixth International Joint Conference*. – 2017. – P. 2273–2279. DOI: 10.24963/ijcai.2017/316
34. *Chen, Haoze.* Hybrid neural network based on novel audio feature for vehicle type identification / Haoze Chen, Zhijie Zhang // 2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC): proceedings of the international conference (25–28 May 2020). – 2021. DOI: 10.1109/I2MTC43012.2020.9129183
35. *Zhao, N.* Combination of Convolutional Neural Network and Gated Recurrent Unit for Aspect-Based Sentiment Analysis / N. Zhao // *IEEE Access*. – Vol. 9. – P. 15561–15569. DOI: 10.1109/ACCESS.2021.3052937.
36. *He, Kaiming.* Deep Residual Learning for Image Recognition / Kaiming He [et al.] // *Conference on Computer Vision and Pattern Recognition: proceedings of the 2016 IEEE Conference*. – 2016. – <https://arxiv.org/abs/1512.03385>. DOI: 10.1109/CVPR.2016.90
37. *Волгин, С. С.* Результаты обработки данных телеметрических измерений, поступающих от группировки малых космических аппаратов «АИСТ» / С. С. Волгин // *Космонавтика и ракетостроение*. – 2019. – № 1. – С. 80–91.
38. Репозиторий онлайн семинаров «Machine Learning Tokyo – Democratizing Machine Learning». – Режим доступа: <https://github.com/Machine-Learning-Tokyo/DL-workshop-series/blob/master/Part%20I%20-%20Convolution%20Operations/ConvNets.ipynb>. – (Дата обращения 7.09.2021).
39. *Микони, С. В.* Квалиметрия моделей и полимодельных комплексов / С. В. Микони, Б. В. Соколов, Р. М. Юсупов. – М. : РАН, 2018. – 314 с.

Скобцов Вадим Юрьевич — канд. техн. наук, ведущий научный сотрудник Объединенного института проблем информатики НАН Беларуси, докторант кафедры ПОИТ ФКСИС Белорусского государственного университета информатики и радиоэлектроники.
E-mail: vasko_vasko@mail.ru ORCID iD: <https://orcid.org/>

Соколов Борис Владимирович — д-р техн. наук, проф., Заслуженный деятель науки РФ, Лауреат премии Правительства РФ в области науки и техники, заведующий лабораторией информационных технологий в системном анализе и моделировании Санкт-Петербургского института информатики и автоматизации РАН.
E-mail: sokol@iias.spb.su ORCID iD: <https://orcid.org/>

HYBRID NEURAL NETWORK MODELS IN THE PROBLEM OF TELEMETRY DATA MULTICLASS CLASSIFICATION OF SMALL SPACECRAFTS

© 2022 V. Yu. Skobtsov¹, B. V. Sokolov²✉

¹United Institute for Informatics Problems of the National Academy of Sciences of Belarus
6, Surganova Street, 220012 Minsk, Belarus

²St. Petersburg Federal Research Center of the Russian Academy of Sciences
39, 14 line V.O., 199178 Saint-Petersburg, Russian Federation

Annotation. The paper presents solutions to the actual problem of intelligent data analysis of telemetry data of onboard equipment (OE) of small spacecraft (SS) in order to determine their technical states. Hybrid neural network models based on modern deep learning architectures have been researched and developed to solve the problem of multiclass classification of telemetry data, which make it possible to determine the normal and abnormal states of the operation of the OE SS. For computer analysis, we used telemetry data from OE SS of the AIST group of the Samara National Research University named after Academician S. P. Korolev. Computer experiments were carried out on training, validation and testing of the constructed hybrid neural network models, which showed their sufficiently high accuracy in solving the problem under consideration. A comparative analysis of the obtained hybrid neural network models with widely used deep neural network classifiers was performed, which showed the advantage of the obtained solutions both in classification accuracy and in training and validation time.

Keywords: hybrid neural network models, data analysis, classification, telemetry data, fully connected neural networks/layers, one-dimensional convolutional neural networks/layers, recurrent neural networks/layers.

CONFLICT OF INTEREST

The authors declare the absence of obvious and potential conflicts of interest related to the publication of this article.

REFERENCES

1. Okhtilev M. Yu. [et al.] (2014) *Koncepcija proaktivnogo upravlenija slozhnymi ob'ektami: teoreticheskie i tehnologicheskie osnovy* [The concept of proactive management of complex objects: theoretical and technological foundations]. *Journal of instrument engineering*, 57(11). P. 7–14. (in Russian)

2. GOST RO 1410-002-2010. *Raketno-kosmicheskaja tehnika. Sistema informacii o tehničeskom sostojanii i nadezhnosti kosmicheskikh kompleksov i vkhodjashchih v ih sostav izdelij*

[Rocket and space technology. Information system on the technical condition and reliability of space complexes and their constituent products]. Introduced 2011-01-01. Moscow: Izd-vo standartov, 2011. 49 p. (in Russian)

3. *Proekt strategii informacionnyh tehnologij Goskorporacii «Roskosmos»* [Draft information technology strategy of the State Corporation Roscosmos.]. URL: <https://www.roscosmos.ru/25892/> (Accessed 2020-11-15). (in Russian)

4. Zelentsov V. A. [et al.] (2017) *Service-oriented distributed software package for evaluating and multi-criteria analysis of indicators of reliability and survivability of onboard equipment of small spacecraft: Russian and Belarusian segments*. In: *Actual problems of rocket and space technology “(V Kozlov readings): Proceedings of V All-Russian scientific and technical conference with international participation (Samara, September 11–15, 2017)*. Samara, 2017, P. 45–56. (in Russian)

5. Zelentsov V. A. [et al.] (2018) *Distributed software package for evaluating and analyzing in-*

✉ Sokolov Boris. V.
e-mail: sokol@iias.spb.su

dicators of reliability and survivability of onboard equipment of small spacecraft. In: *Actual problems of creating space systems for remote sensing of the Earth: abstracts of the Sixth International Scientific and Technical Conference (Moscow, May 24, 2018)*. Moscow, 2018, 146 p. (in Russian)

6. Zelentsov V. A. [et al.] (2017) Servis-orientirovannyj raspredeljonnyj programmnyj kompleks dlja ocenivaniya i mnogokriterial'nogo analiza pokazatelej nadjozhnosti i zhivuchesti bortovoj apparatury malyh kosmicheskikh apparatov: rossijskij i belorusskij segment [Service-oriented distributed software package for evaluating and multi-criteria analysis of indicators of reliability and survivability of onboard equipment of small spacecraft: Russian and Belarusian segments]. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 16(4). P. 118–129. DOI: 10.18287/2541-7533-2017-16-4-118-129 (in Russian)

7. Skobtsov V. Yu. and Novoselova N. A. (2020) Issledovanie algoritmov potokovoj klasterizacii v reshenii zadachi analiza dannyh telemektrii malyh kosmicheskikh apparatov [Investigation of stream clustering algorithms in solving the problem of analyzing telemetry data of small space vehicles]. *Journal of instrument engineering*. 63(11). P. 1003–1011. DOI: 10.17586/0021-3454-2020-63-11-1003-1011 (in Russian)

8. Skobtsov V. [et al.] (2017) Intelligent Telemetry Data Analysis of Small Satellites. In: *Silhavy R., Senkerik R., Kominkova Oplatkova Z., Prokopova Z., Silhavy P. (eds) Cybernetics and Mathematics Applications in Intelligent Systems. CSOC 2017. Advances in Intelligent Systems and Computing – Springer International Publishing Switzerland*. 574, P. 351–361. DOI:10.1007/978-3-319-57264-2_36

9. Skobtsov V. Yu. and Arkhipov V. I. (2021) Nejrosetevoj analiz dannyh telemektrii bortovoj apparatury kosmicheskikh apparatov [Neural network analysis of telemetry data of spacecraft onboard equipment]. *Space engineering and technology*. 3(34). P. 111–124. (in Russian)

10. Skobtsov V. Yu. (2021) Binary classification of small satellites telemetry data based on deep learning approach. *Applied Aspects of Information Technology*. 4(4). P. 299–310.

11. Gamboa B. and Cristian J. Deep learning for time-series analysis. <https://arxiv.org/pdf/1701.01887.pdf>

12. Rajkomar A. [et al.] (2018) Scalable and accurate deep learning for electronic health records. *NPJ Digital Medicine*. May, 1:18. <https://europepmc.org/article/med/31304302> DOI: 10.1038/s41746-018-0029-1

13. Nweke H. F. (2018) Deep learning algorithms for human activity recognition using mobile and wearable sensor networks: state of the art and research challenges. *Expert Systems with Applications*. 105. P. 233–261. <https://doi.org/10.1016/j.eswa.2018.03.056>

14. New T. L., Dat T. H. and Ma B. (2017) Convolutional neural network with multi-task learning scheme for acoustic scene classification. Annual Summit and Conference 2017: proceedings of APSIPA, P. 1347–1350. DOI: 10.1109/APSIPA.2017.8282241

15. Susto G. A. [et al.] (2018) Time-series classification methods: review and applications to power systems data. Big data application in power systems, Elsevier Inc., Chapter 9. P. 179–220. <https://doi.org/10.1016/B978-0-12-811968-6.00009-7>

16. Yang, Q. and Wu X. (2006) 10 challenging problems in data mining research. *International Journal of Information Technology & Decision Making*. 05(04). P. 597–604. <https://doi.org/10.1142/S0219622006002258>

17. Fawaz H. I. [et al.] (2019) Muller Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*. 33. P. 917–963. <https://doi.org/10.48550/arXiv.1809.04356>

18. Silva D. F. [et al.] (2018) Speeding up similarity search under dynamic time warping by pruning unpromising alignments. *Data Mining and Knowledge Discovery*. 32(4). P. 988–1016. <https://doi.org/10.1007/s10618-018-0557-y>.

19. Bagnall A. [et al.] (2017) The great time series classification bake off: a review and experimental evaluation of recent algorithmic advances. *Data Mining and Knowledge Discovery*. 31(3). P. 606–660. <https://doi.org/10.1007/s10618-016-0483-9>

20. Bagnall A. [et al.] (2016) Time-series classification with COTE: the collective of trans-

formation-based ensembles. *2016 IEEE 32nd International Conference on Data Engineering (ICDE): proceedings (May 2016)*. P. 1548–1549. DOI:10.1109/ICDE.2016.7498418

21. Hills J. [et al.] (2014) Classification of time series by shapelet transformation. *Data Mining and Knowledge Discovery*. 28(4). P. 851–881. <https://doi.org/10.1007/s10618-013-0322-1>

22. Bostrom A. and Bagnall A. (2015) Binary shapelet transform for multiclass time series classification. *Conference on Big Data Analytics and Knowledge Discovery: proceedings of the International Conference*. P. 257–269. DOI: 10.1007/978-3-319-22729-0_20

23. Baydogan M. G. Multivariate time series classification datasets. – <http://www.mussta-fabaydogan.com>. (accessed: 5.10.2021).

24. Lines J., Taylor S. and Bagnall A. (2016) HIVE-COTE: the hierarchical vote collective of transformation-based ensembles for time series classification. *2016 IEEE 16th International Conference on Data Mining (ICDM): proceedings of the international conference (December 2016)*. P. 1041–1046. DOI:10.1109/ICDM.2016.0133

25. Lines J., Taylor S. and Bagnall A. (2018) Time series classification with HIVE-COTE: the hierarchical vote collective of transformation-based ensembles. *ACM Trans Knowl Discov Data*. 2(5), Article No 52. P. 1–35. <https://doi.org/10.1145/3182382>

26. LeCun Y., Bengio Y. and Hinton G. (2015) Deep learning. *Nature*. 521. P. 436–444. <http://dx.doi.org/10.1038/nature14539>

27. Wang Z., Yan W. and Oates T. (2017) Time series classification from scratch with deep neural networks: a strong baseline. *2017 International Joint Conference on Neural Networks (IJCNN): proceedings of the international joint conference (May 2017)*. P. 1578–1585. DOI: 10.1109/IJCNN.2017.7966039

28. Gorban' A. N., Dunin-Barkovskij V. L., Kiridin A. N. [et al.] (1998) *Nejroinformatika* [Neuroinformatics]. Novosibirsk, Science. (in Russian)

29. Tsaregorodsev V. G. (1998) Neurosimulator NEUROPRO. *Neuroinformatics and its applications: abstract report VI All-Russian Seminar (October 2–5, 1998)* / ed. Gorban' A. N. Krasnoyarsk, 207 p. (in Russian)

30. Nikolenko S., Kadurin A. and Arhangel'skaja E. (2018) *Glubokoe obuchenie* [Deep Learning]. Saint-Petersburg, Piter. (in Russian)

31. Sholle F. (2018) *Glubokoe obuchenie na Python* [Deep Learning in Python]. Saint-Petersburg, Piter. (in Russian)

32. Cho Kyunghyun. (2014) Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *Empirical Methods in Natural Language Processing (EMNLP): proceedings of the 2014 Conference*. arXiv:1406.1078. DOI: 10.3115/v1/D14-1179

33. Lin Tao, Guo Tian and Aberer Karl. (2017) Hybrid Neural Networks for Learning the Trend in Time Series. *Artificial Intelligence (IJCAI-17): proceedings of the Twenty-Sixth International Joint Conference*. P. 2273–2279. DOI: 10.24963/ijcai.2017/316

34. Chen Haoze and Zhang Zhijie. (2020) Hybrid neural network based on novel audio feature for vehicle type identification. *2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC): proceedings of the international conference (25–28 May 2020)*. DOI: 10.1109/I2MTC43012.2020.9129183

35. Zhao N. (2021) Combination of Convolutional Neural Network and Gated Recurrent Unit for Aspect-Based Sentiment Analysis. *EEE Access*. 9. P. 15561–15569. DOI: 10.1109/ACCESS.2021.3052937.

36. He Kaiming [et al.] (2016) Deep Residual Learning for Image Recognition. *Conference on Computer Vision and Pattern Recognition: proceedings of the 2016 IEEE Conference*. <https://arxiv.org/abs/1512.03385>. DOI: 10.1109/CVPR.2016.90

37. Volgin S. S. (2019) Rezul'taty obrabotki dannyh telemekhanicheskikh izmerenij, postupajushhih ot gruppirovki malyh kosmicheskikh apparatov «AIST» [The results of processing data from telemetry measurements coming from the grouping of small spacecraft "AIST"]. *Kosmonavtika i raketostroenie*. (1). P. 80–91. (in Russian)

38. Repository of online seminars «Machine Learning Tokyo – Democratizing Machine Learning». <https://github.com/Machine-Learning-Tokyo/DL-workshop-series/blob/master/Part%20I%20-%20Convolution%20Operations/ConvNets.ipynb>. – (accessed: 7.09.2021).

39. *Mikoni S. V., Sokolov B. V. and Yusupov R. M.*
(2018). *Kvalimetrya modeley i polymodelnyx kompleksov. Moscow : RAN.* 314 p.

Skobtsov Vadim Yu. — PhD, Associate Professor, Leading Researcher at the United Institute of Informatics Problems of the National Academy of Sciences of Belarus, Doctoral Student of the Belarusian State University of Informatics and Radioelectronics.

E-mail: vasko_vasko@mail.ru

ORCID iD: <https://orcid.org/0000-0002-8546-0430>

Sokolov Boris. V. — Dr. Sci. (Tech), Professor, Head of the Laboratory of Information Technologies in System Analysis and Modeling of St. Petersburg Federal Research Center of the Russian Academy of Sciences.

E-mail: Sokolov_boris@inbox.ru

ORCID iD: <https://orcid.org/0000-0002-2295-7570>