

В. Ю. СКОБЦОВ

Объединенный институт проблем информатики Национальной академии наук Беларуси, Минск

НЕЙРОСЕТЕВАЯ КЛАССИФИКАЦИЯ ДАННЫХ ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ МАЛЫХ КОСМИЧЕСКИХ АППАРАТОВ

В докладе представлены решения актуальной задачи интеллектуального анализа данных телеметрической информации 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 классификации данных телеметрической информации, позволяющие определять штатное и нештатные состояния функционирования МКА или его подсистем. Проведены компьютерные эксперименты по обучению, валидации и тестированию построенных нейросетевых моделей, показавшие их достаточно высокую точность.

Введение. Одной из важнейших задач на всех этапах жизненного цикла малых космических аппаратов (МКА) является анализ их телеметрической информации (ТМИ) о функционировании МКА с точки зрения определения их технического состояния для обеспечения их корректного и безопасного функционирования. Их актуальность обусловлена, прежде всего, тем, что одной из основных причин потерь МКА являются отказы, сбои и некорректная работа систем МКА.

Большое количество информации, поступающей и накапливающейся в специализированных банках данных с МКА, может быть эффективно использовано для определения технического состояния МКА и его подсистем. В современных условиях для решения задач обеспечения требуемой степени автономности, качества и оперативности управления такими сложными объектами как МКА необходимо выполнить комплексную автоматизацию и интеллектуализацию процессов многомодельного анализа данных ТМИ МКА. Однако в большинстве случаев на практике автоматизация выполнена, в лучшем случае, лишь частично, и многое делается зачастую вручную, базируясь на эвристических правилах [1]. При этом в соответствии с ГОСТ 1410-002-2010 [2] и Стратегией цифровой трансформации ракетно-космической отрасли до 2025 г. и перспективой до 2030 г. 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 телеметрии МКА с целью определения технического состояния МКА является актуальной и востребованной. При этом разработка и применение методов анализа данных ТМИ МКА на основе моделей искусственного интеллекта, машинного обучения и биоинспирированных систем позволяет на новом научно-техническом теоретическом и прикладном уровнях решить поставленную задачу и повысить эффективность принимаемых управленческих и эксплуатационных решений наземных комплексов управления (НКУ) МКА.

Задача классификации данных ТМИ МКА. Исходные данные ТМИ являются временным рядом, который можно представить 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 $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M)$ состоит из M различных одномерных временных рядов $\mathbf{X}_j \in R^T$.

Очевидно, что рассматриваемый временной ряд данных ТМИ является M -мерным временным рядом $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_M)$.

Для каждого вектора показателей ТМИ в i -й момент времени \mathbf{X}_i в соответствие поставлена метка класса $y_i \in \mathbf{Y}$, который характеризует состояние функционирования анализируемого по

данным ТМИ МКА или его подсистемы. В исследуемой задаче мы рассматриваем случаи k -классовой классификации, где k – общее число состояний, определяемое экспертом. Конечной целью является классификация векторов X_i M -мерного временного ряда 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 X_i M -мерного временного ряда 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.

Анализ нейросетевых моделей. В течение последних двух десятилетий классификация временных рядов считается одной из самых сложных проблем в области интеллектуального анализа данных [3, 4]. Фактически, любая проблема классификации, использующая данные, которые регистрируются с учетом некоторого понятия упорядочивания можно рассматривать как проблему классификации временного ряда. Временные ряды встречаются во многих реальных приложениях: электронных медицинских карт, распознавания человеческой деятельности, классификации акустических сцен, кибербезопасности, анализа состояний функционирования МКА по данным ТМИ [4, 5].

Проанализировав текущее состояние классических неглубоких (не нейросетевых) моделей классификаторов и установив непрактичность с позиции вычислительной сложности передовых подходов (COTE, NIVE-COTE) в ряде случаев решения реальных задач интеллектуального анализа больших данных, мы сосредоточимся на моделях глубокого обучения или нейросетевых моделях [4].

Определение 3. Искусственной нейронной сетью (нейросетевой моделью) называется система, состоящая из совокупности связанных между собой по типу узлов направленного графа элементарных процессоров, называемых *искусственными или формальными нейронами*, и способная генерировать выходную информацию в ответ на входное воздействие.

В анализе и разработке нейросетевых моделей мы будем рассматривать нейросетевые модели от простого к более сложному, начиная с основных на текущий момент нейросетевых моделей:

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

и продолжая их комбинациями, в том числе, на основе методики остаточных связей архитектуры ResNet [6,7].

В качестве активационных функций будем использовать следующие широко используемые активационные функции [6, 7]:

- функция *relu* – rectified linear unit, линейный выпрямитель $\text{relu}(z) = \max(0, z)$;
- обобщение логистической функции для One-Hot кодирования меток классов $\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{i=0}^1 e^{z_i}}$.

В качестве функции ошибки будем использовать функцию двоичной и категориальной кросс-энтропии (*binary crossentropy*, *categorical crossentropy*), для случаев $k = 2$ и $k = 3$ соответственно, поскольку мы решаем задачу бинарной классификации [6, 7].

Для проведения компьютерных экспериментов и анализа точности разработанных нейросетевых классификационных моделей использованы данные ТМИ навигационной подсистемы Белорусского космического аппарата (БКА) и всей бортовой аппаратуры (БА) МКА группировки МКА АИСТ Самарского национального исследовательского университета имени академика С.П.Королева.

Для БКА вектор матрицы ТМИ X_i имеет размерность 9 и помечается 0 в случае штатного состояния и 1 в случае нештатного состояния подсистемы. Общая размерность 9-мерного временного ряда X составляет 121690 векторов, из которых 77881 векторов составляет обуча-

ющий набор данных, 19471 векторов составляет валидационный набор данных, 24338 вектор составляет тестовый набор данных.

Для МКА АИСТ вектор матрицы ТМИ 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.

Основываясь на описанных выше нейросетевых архитектурах, были предложены и исследованы 3-слойная MLP модель, 5-слойная сверточная 1D CNN модель, 4-слойные рекуррентные LSTM и GRU модели. Каждая из них использовала финальный классификационный полносвязный слой из одного нейрона с *softmax* активационной функцией.

Для приведенной выше группы нейросетевых моделей обучение и валидация проводились при следующих значениях гиперпараметров: метод обучения 'adam' (как один из наиболее эффективных на текущий момент), функция потерь – 'binary_crossentropy', число эпох обучения – 500, размер мини-пакета – 128. На тестовом наборе модели не оценивались. Механизм раннего останова [7] не использовался и процесс обучения и валидации проходил на всех 500 эпохах.

Как показывают данные экспериментов, наименьшей точностью как на этапе обучения 0.8713, так и на этапе валидации, 0.8706, обладает полносвязная модель, при этом ее время обучения и валидации является наименьшим – 2 секунды. Более точной моделью (0.9036, 0.901) является одномерная сверточная модель, причем время обучения и валидации немногим больше полносвязной модели – 3 сек. Лидерами по точности, очевидно, являются рекуррентные модели, причем модель GRU на этапе обучения чуть уступает LSTM – $0.9496 < 0.9557$, а на этапе валидации даже превосходит ее – $0.9330 > 0.9322$. При этом по времени обучения и валидации модель GRU достаточно выигрывает у LSTM – $29 < 34$ сек. Поэтому делаем вывод о ее лидерстве в данной серии экспериментов. Если же точность модели достаточно иметь больше 0.9, и важен фактор времени обучения и легковесности модели, то более привлекательной является сверточная модель 1D CNN. Увеличение числа слоев и нейронов в слоях моделей к увеличению качества моделей не привело, зачастую наблюдался обратный эффект выхода на плато и понижения точности в процессе обучения.

Дальнейшей целью исследований было с одной стороны повысить точность модели, с другой стороны уменьшить ее время обучения и валидации, то есть получить более легковесную модель по сравнению с рекуррентными.

Для этого были последовательно соединены три блока слоев: сверточный 1D CNN, рекуррентный GRU или LSTM и в итоге как классификатор полносвязный блок:

$$Z = \text{Conv1D}(\text{filters}=512, \text{kernel_size}=4, \text{activation}='relu')(X_i)$$

$$Z = \text{Conv1D}(\text{filters}=512, \text{kernel_size}=4, \text{activation}='relu')(Z)$$

$$Z = \text{Conv1D}(\text{filters}=512, \text{kernel_size}=4, \text{activation}='relu')(Z)$$

$$Z = \text{Pooling1D}(2)(Z)$$

$$Z = \text{Conv1D}(\text{filters}=256, \text{kernel_size}=2, \text{activation}='relu')(Z)$$

$$Z = \text{Conv1D}(\text{filters}=256, \text{kernel_size}=2, \text{activation}='relu')(Z)$$

$$Z = \text{Conv1D}(\text{filters}=256, \text{kernel_size}=2, \text{activation}='relu')(Z)$$

$$Z = \text{RNN}(\text{units}=64)(Z)$$

$$Z = \text{Dense}(1, \text{activation}='sigmoid')(Z) / \text{Dense}(2, \text{activation}='softmax')(Z)$$

На основе данной архитектуры были получены несколько нейросетевых моделей путем использования в слое агрегации методов AveragePooling и MaxPooling, в рекуррентных слоях ячейки типа GRU и LSTM. Добавлен этап тестирования моделей. Обучение проводилось также на 500 эпохах, но при этом использовался механизм раннего останова в случае выхода на плато значения точности валидации в течение 10 итераций. Как показали эксперименты, в этом случае обучение выполнялось не более 160 эпох. В рекуррентном слое применялась $l1$ и $l2$ регуляризация.

Как показали данные экспериментов, точность всех моделей (за исключением одной) на этапах валидации и тестирования больше 0.96 и варьируется в значениях сотых и тысячных. По-

этому можно сделать выбор по критерию минимального времени обучения одной эпохи. С этой точки зрения с небольшим преимуществом лидирует модель с параметрами AveragePooling, GRU и показателями точности на обучающем, валидационном и тестовом этапах: 0.9850, 0.9668, 0.9661, и временем одной эпохи обучения и валидации 14 сек.

Следующая группа моделей строилась на основе архитектуры предыдущей модели и методики добавления остаточных связей, развитие которой началось с появления семейства сетей ResNet [7]. Также было увеличено число сверточных слоев и уменьшено число фильтров n в них.

$$Z_1 = \text{Conv1D}(\text{filters}=n, \text{kernel_size}=4, \text{activation}='relu')(X_i)$$

$$Z_1 = \text{Conv1D}(\text{filters}=n, \text{kernel_size}=4, \text{activation}='relu')(Z_1) * 9 \text{ слоев}$$

$$Z_2 = \text{add}([Z_1, X_i]) - \text{проброс остаточной связи входа } X_i$$

$$Z_2 = \text{Pooling1D}(2)(Z_2)$$

$$Z_3 = \text{Conv1D}(\text{filters}=n, \text{kernel_size}=2, \text{activation}='relu')(Z_2)$$

$$Z_3 = \text{Conv1D}(\text{filters}=n, \text{kernel_size}=2, \text{activation}='relu')(Z_2) * 9 \text{ слоев}$$

$$Z_4 = \text{Pooling1D}(2)(X_i)$$

Output = add([Z₂, Z₃, Z₄]) – проброс остаточных связей Z₂ и агрегированного входа Z₄ = Pooling1D(2)(X_i)

$$\text{Output} = \text{Dense}(32, \text{activation}='relu')(\text{Output})$$

$$\text{Output} = \text{Dense}(1, \text{activation}='sigmoid')(Z) / \text{Dense}(2, \text{activation}='softmax')(\text{Output})$$

Для задачи бинарной классификации на данных ТМИ БКА по данным экспериментов, исходя из соотношения значения точности и функции потерь, на этапах обучения, валидации и тестирования, а также времени одной эпохи обучения и валидации лидером является модель с параметрами: AveragePooling, GRU, $n=64$ с показателями точности на обучающем, валидационном и тестовом этапах: ~0.98, ~0.97, ~0.97, и временем обучения эпохи 12 сек.

Проведен сравнительный анализ полученных гибридных нейросетевых моделей с широко распространенными глубокими нейросетевыми классификаторами: Encoder, LeNet, AlexNet, Xception, Yolo, MobileNet, Inception, ResNet, модифицированными для анализа временных рядов. Для задачи бинарной классификации на данных ТМИ БКА, разработанная гибридная нейросетевая модель с использованием остаточных связей сравнима по точности с нейросетевой классификационной моделью Inception (остальные классификаторы имеют меньшую точность): ~0.98 (этап обучения), ~0.97 (этапы валидации и тестирования). При этом полученная гибридная модель в 2.5 раза быстрее по времени обучения и валидации и имеет более облегченную структуру, что важно для ее реализации. Для задачи многоклассовой классификации на данных ТМИ МКА АИСТ для разработанной гибридной нейросетевой модели с использованием остаточных связей по технологии ResNet при $n=8$ были получены точности: ~0.99 (этап обучения), ~0.979 (этап валидации), ~0.978 (этап тестирования). В данном случае модель Inception показала немного худшие результаты по сравнению с предложенной нами гибридной моделью: ~0.98 (этап обучения), ~0.967 (этап валидации), ~0.954 (этап тестирования). Модифицированная же модель TimeResNet показала сравнимые результаты: ~0.99 (этап обучения), ~0.978 (этап валидации) и ~0.976 (этап тестирования). Но время одной эпохи обучения и валидации у модели Inception в 2 раза выше, и в 3 раза выше в последнем случае, что при дальнейшем увеличении выборки приведет к существенным увеличениям затрат времени.

Машинный анализ разработанных моделей показал преимущество гибридных нейросетевых глубоких моделей, представляющих собой последовательное соединение трех блоков слоев: сверточного 1D CNN, рекуррентного GRU и итогового полносвязного блока-классификатора, с применением слоя агрегации AveragePooling, метода добавления остаточных связей семейства архитектур ResNet в силу преимущества по точности на этапах валидации и тестирования и времени обучения и валидации.

ЛИТЕРАТУРА

1. Охтилев М.Ю., Мустафин Н.Г., Миллер В.Е., Соколов Б.В. Концепция проактивного управления сложными объектами: теоретические и технологические основы. *Известия вузов. Приборостроение*. 2014. Том 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.
3. **Yang Q., Wu X.** 10 challenging problems in data mining research. *Inf Technol Decis Mak*, (2006) 05(04), pp.597–604.
4. **Hassan Ismail Fawaz, Germain Forestier, Jonathan Weber, Lhassane Idoumghar, Pierre-Alain Muller** Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery* (2019) 33, pp.917–963.
5. **Скобцов В.Ю., Архипов В.И.** Нейросетевой анализ данных телеметрической информации бортовой аппаратуры космических аппаратов. *Космическая техника и технологии*, 2021, С.111-124.
6. **Николенко С., Кадурич А., Архангельская Е.** Глубокое обучение. СПб.: Питер, 2018. 480 с.
7. **Шолле Ф.** Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.

V.Yu.Skobtsov (United Institute of Informatics Problems of the National Academy of Sciences of Belarus)

Neural network classification of telemetry data of small spacecrafts

The paper presents solutions to the actual problem of intelligent data analysis of telemetry data 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 classifying the telemetry data, allowing determining the normal and abnormal states of the functioning of the SS or its subsystems. Computer experiments were carried out on training, validation and testing of the developed neural network models, which showed fairly high accuracy.