

<https://doi.org/10.21869/2223-1536-2024-14-2-194-212>

УДК 004.8.032.26

Разработка имитационной модели и настройка гиперпараметров нейронной сети для прогнозирования возможных состояний сети малых космических аппаратов

Е. А. Шиленков¹, С. Н. Фролов¹, Е. А. Титенко¹ ✉

¹ Юго-Западный государственный университет
ул. 50 лет Октября, д. 94, г. Курск 305040, Российская Федерация

✉ e-mail: johntit@mail.ru

Резюме

Целью исследования является разработка имитационной модели и настройка гиперпараметров нейронной сети для прогнозирования возможных состояний.

Методы основаны на методах теории искусственного интеллекта для управления группировкой малых космических аппаратов (МКА) – использование адаптивных средств, позволяющих принимать решения аналогично механизмам мышления человека. Применительно к системам космической связи с гетерогенной структурой методы и технологии искусственного интеллекта направлены на процессы прогнозирования состояния в каналах связи между узлами сети и автоматической реконфигурации сети аппаратов на основе процессов обучения нейронной сети. Одной из наиболее важных функций сетевого программного обеспечения для применения когнитивных алгоритмов является прогнозирование качества связи между парами МКА.

Результаты. Разработан метод применения нейронной сети архитектуры Transformer для прогнозирования возможных состояний сети МКА, который обеспечивает агрегирование и временную синхронизацию данных о состоянии сети МКА, их применение для обучения нейронной сети, а также использования нейронной сети для прогнозирования качества связи. Создан формат данных для обучающей выборки, основанный на представлении состояния сети МКА, которая обеспечивает генерацию начального состояния сети, моделирование проактивного режима её работы, сбор маркеров состояния сети МКА для порождения наборов обучающих данных, в виде хронологических последовательностей, группируемых в кадры, и позволяющий снизить объем данных, передаваемый между МКА при создании обучающей выборки. Разработана имитационная модель сети МКА, которая обеспечивает генерацию начального состояния сети, моделирование проактивного режима ее работы, сбор сведений о состоянии сети МКА для порождения наборов синтетических обучающих данных.

Заключение. В статье разработана имитационная модель сети МКА для порождения синтетических обучающих данных и прогнозирования возможных состояний сети МКА, а также метод применения нейронной сети для прогнозирования возможных состояний сети МКА.

Ключевые слова: малый космический аппарат; искусственная нейронная сеть; прогнозирование; имитационная модель сети; данные; формат; интерфейс.

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

Для цитирования: Шиленков Е. А., Фролов С. Н., Титенко Е. А. Разработка имитационной модели и настройка гиперпараметров нейронной сети для прогнозирования возможных состояний сети малых космических аппаратов // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024. Т. 14, № 2. С. 194–212. <https://doi.org/10.21869/2223-1536-2024-14-2-194-212>

Поступила в редакцию 10.04.2024

Подписана в печать 04.05.2024

Опубликована 28.06.2024

© Шиленков Е. А., Фролов С. Н., Титенко Е. А., 2024

Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2024; 14(2): 194–212

Development of a simulation model and adjustment of hyperparameters of a neural network for predicting possible states of a network of small space carriages

Egor A. Shilenkov¹, Sergey N. Frolov¹, Evgeniy A. Titenko¹ ✉

¹ Southwest State University
50 Let Oktyabrya Str. 94, Kursk 305040, Russian Federation

✉ e-mail: johntit@mail.ru

Abstract

The purpose of the research is to develop a simulation model and tune the hyperparameters of a neural network to predict possible states of a network of small spacecraft.

The research methods are based on the concepts of the theory of artificial intelligence to control a group of small spacecraft (SSV) – the use of adaptive methods and tools to make decisions, similar to the mechanisms of human thinking. In relation to space communication systems with a heterogeneous structure, artificial intelligence methods and technologies are aimed at predicting the state of communication channels between network nodes and automatically reconfiguring a network of devices based on neural network learning processes. One of the most important functions of network software for the application of cognitive algorithms is to predict the quality of communication between pairs of SSVs.

Results. A method has been developed for using the Transformer architecture neural network to predict possible states of the SSV network, which provides aggregation and time synchronization of data on the state of the SSV network, their use for training the neural network, as well as using the neural network to predict the quality of communication. The data format for the training sample has been created, based on the representation of the state of the SSV network, which ensures the generation of the initial state of the network, modeling the proactive mode of its operation, collecting SSV network state markers to generate training data sets in the form of chronological sequences grouped into frames, and allowing to reduce the amount of data transferred between SSVs when creating a training set. A simulation model of the SSV network has been developed, which provides generation of the initial state of the network, modeling of the proactive mode of its operation, and collection of information about the state of the SSV network to generate sets of synthetic training data.

Conclusion. The article develops a simulation model of the SSV network for generating synthetic training data and predicting possible states of the SSV network, as well as a method for using a neural network to predict possible states of the SSV network.

Keywords: small spacecraft; artificial neural network; forecasting; network simulation model; data; format; interface.

Conflict of interest: The Authors declares the absence of obvious and potential conflicts of interest related to the publication of this article.

For citation: Shilenkov E.A., Frolov S.N., Titenko E.A. Development of a simulation model and adjustment of hyperparameters of a neural network for predicting possible states of a network of small space carriages. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naja tekhnika, informatika. Meditsinskoe priborostroenie* = *Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2024;14(2):194–212. (In Russ.) <https://doi.org/10.21869/2223-1536-2024-14-2-194-212>

Received 10.04.2024

Accepted 04.05.2024

Published 28.06.2024

Введение

Весьма востребованной функцией сетевого программного обеспечения для применения когнитивных алгоритмов является прогнозирование качества связи между парами малых космических аппаратов (МКА), результаты которого будут использованы для построения маршрутов передачи данных с учетом минимизации потерь данных [1]. Согласно параметрической модели сети МКА, задача прогнозирования заключается в формировании матрицы качества связи $Q(t_+)$ на основе рассчитанной матрицы прямой видимости $D(t_+)$ и текущего множества векторов состояний МКА $\{V_i(t)\}$ с помощью функционала $F_{Q+}(\cdot)$ [2]. Кроме того, данный функционал в качестве параметра также принимает матрицу весовых коэффициентов $W(t_-)$, которая формируется путём обучения $F_{Ql}(\cdot)$ на основе фактических данных о пространственных координатах МКА $\{p_i(t_-)\}$, их состоянии $\{V_i(t_-)\}$ и качестве связи $Q(t_-)$ [3].

Метод применения нейронной сети для прогнозирования возможных состояний сети малых космических аппаратов должен реализовать функционалы обучения $F_{Ql}(\cdot)$ и прогнозирования $F_{Q+}(\cdot)$ и соответственно разделен на две части:

1. Сбор фактических данных о состоянии сети МКА и обучение или дообучение нейросетевого алгоритма прогнозирования с формированием весовых коэффициентов.

2. Расчет матрицы прямой видимости МКА и прогнозирование матрицы качества связи в заданном интервале времени [4].

Для реализации $F_{Ql}(\cdot)$ необходимо получить следующие данные о состоянии сети в целом и каждого МКА в частности:

- трехмерные геодезические координаты $p_i(t_-)$ МКА, которые рассчитываются на основе их актуальных кеплеровских параметров орбиты (*TLE*);
- векторы состояния МКА $V_i(t_-)$, формируемые средствами диагностики аппаратной платформы;
- матрицы фактического качества связи $Q(t_-)$, которые создаются на основе отправки тестовых сигналов и регистрации времени их получения в активной фазе работы сети МКА.

Материалы и методы

Все данные для обучения являются хронологическими рядами, причем каждый из компонентов имеет собственный открытый интервал обновления: $p_i(t_-)$ – 1–5 с; $Q(t_-)$ – 5–20 с; $V_i(t_-)$ – 5–10 мин (рис. 1).




Рис. 1. Хронологические ряды данных о состоянии малого космического аппарата и сети

Fig. 1. Chronological series of data on the state of a small spacecraft and network

Как показано на рисунке 1, для обучения используются хронологические срезы, формируемые с заданным временным интервалом Δt . До момента обновления действительными считаются крайние полученные данные. Так, например, для момента времени t_{7-} хронологический срез включает в себя $p_i(t_{7-}) \rightarrow 7$, $Q(t_{7-}) \rightarrow 2$, $V_i(t_{7-}) \rightarrow 1$. Формируемые таким образом срезы являются исходными данными для обучения.

В рамках концептуальной модели сети МКА показано, что наилучший вариант применения ИНС для прогнозирования качества связи описывается отображением $\langle (p_i(t_+), V_i(t_+)), (p_j(t_+), V_j(t_+)) \rangle \rightarrow q_{ij}(t_+)$, которое связывает пространственные геодезические координаты и векторы состояний пары МКА с качеством связи между ними. Следует отметить, что отображение некоммутативно, поскольку $q_{ij}(t_+) \neq q_{ji}(t_+)$, хотя, без сомнений, значения должны быть близки.

В рамках модели сети МКА также отмечена временная коррелированность

всех указанных выше значений, что позволяет обобщить отображение на заданный начальный момент t_{0+} временной интервал с шагом Δt длиной N_t :

$$\langle p_i, V_i, p_j, V_j \rangle_\tau \rightarrow \langle q_{ij} \rangle_\tau, \quad \tau = t_{0+} + m \cdot \Delta t, m = \overline{1, N_t}, \quad (1)$$

где τ – дискретное время, используемое для обучения искусственной нейронной сети (ИНС) и прогнозирования [5].

Таким образом, как при обучении ИНС, так и при прогнозировании используются хронологические последовательности («временные» окна) данных, что позволяет использовать когнитивные возможности алгоритмов для выявления темпоральных связей в обучающих данных. Функционал $F_{QI}(\cdot)$ заключается в итеративном применении функции корректировки весов на основе предъявляемых на вход сети хронологических последовательностей данных о положении и состоянии МКА и соответствующих им данных о качестве связи:

$$W_n = f_{QI} \left(\langle p_i, V_i, p_j, V_j, q_{ij} \rangle_\tau, W_{n-1} \right), \quad (2)$$

$$\begin{aligned} \tau = t_{0-} + m \cdot \Delta t, m = \overline{1, N_t}, i = \\ = \overline{1, N_{MKA}(\tau)}, j = \overline{1, N_{MKA}(\tau)} \end{aligned} \quad (3)$$

Реализация функции f_{Ql} корректировки весов и принципы группировки подаваемых на вход данных зависят от выбранной архитектуры ИНС.

Количество итераций N_l обучения зависит от достижения необходимой точности прогнозирования ξ , определяемой путем применения функции $f_{Q+}(\cdot)$ к фактическим данным, не входящим в обучающий набор и называемый валидационным [6]:

$$\begin{aligned} N_l = \arg \min_m M \left[f_{Q+} \left(d_{ij}(t_-), p_i(t_-), p_j(t_-), \right. \right. \\ \left. \left. V_i(t_-), V_j(t_-), W_n \right) - q_{ij}(t_-) \right] < \xi. \end{aligned} \quad (4)$$

где $i = j$.

Полноценное обучение с использованием случайным образом заданных начальных значений весов W_0 необходимо выполнять лишь на начальном этапе работы сети МКА по результатам тестовой эксплуатации. В дальнейшем начальной матрицей весов должен выступать результат предыдущего обучения в соответствии с концепцией дообучения или тонкой настройки (fine tune) ИНС для адаптации к изменениям структуры сети и внешних параметров.

Перед дообучением логичным шагом является верификация – оценка точности прогнозирования $f_{Q+}(\cdot)$ с использованием текущей матрицы W на накопленных фактических данных с момента последнего обучения. Дообучение

необходимо выполнять только в том случае, если средняя погрешность прогнозирования превышает заданное пороговое значение ξ .

Полное переобучение с весов W_0 используется в случае, если не удалось достигнуть требуемого значения ошибки прогнозирования за заданное максимальное количество итераций сети.

Предлагаемая периодичность дообучения алгоритма составляет 1 раз в неделю.

Сформированная матрица весовых коэффициентов W используется для прогнозирования качества значений связи $q_{ij}(t_+)$ между парами МКА. Результатом прогнозирования по аналогии с обучением является не единичное значение, а хронологическая последовательность:

$$\begin{aligned} \langle q_{ij} \rangle_\tau = f_{Q+} \left(\langle p_i, V_i, p_j, V_j \rangle_\tau, W \right), \\ \tau = t_{0+} + m \cdot \Delta t, m = \overline{1, N_t} \end{aligned} \quad (5)$$

Учитывая тот факт, что точность прогнозирования в центре диапазона выше, чем на его границах требуемый интервал прогнозирования $[t_{1+}, t_{2+}]$ разбивается на фрагменты с 50% перекрытием, как показано на рисунке 2, для чего используются два хронологических ряда $q_{ij}^{(1)}, q_{ij}^{(2)}$, объединяемые с помощью весового коэффициента $\omega(t) \in [0, 1]$,

$$q_{ij}(t) = \omega(t) \cdot q_{ij}^{(1)}(t) + (1 - \omega(t)) q_{ij}^{(2)}(t). \quad (6)$$




Рис. 2. Чередующееся разбиение двух хронологических рядов

Fig. 2. Alternating division of two chronological series

Согласно разработанному методу применения нейронной сети, базовым элементом обучающей выборки является хронологическая последовательность $\langle p_i, V_i, p_j, V_j, q_{ij} \rangle_\tau$, $\tau = t_{0-} + m \cdot \Delta t$, $m = \overline{1, N_t}$,

причем пространственные положения и векторы состояний являются входными данными обучаемой ИНС, а качество связи – их разметкой (аннотацией), используемой для корректировки весов (рис. 3).




Рис. 3. Организация подачи обучающей выборки и корректировка весов

Fig. 3. Organizing the supply of the training sample and adjusting the weights

Частота дискретизации последовательности, определяемая шагом Δt , должна соответствовать частоте изменения выходных данных ИНС, т. е. лежит в диапазон 3–12 измерений / мин

($\Delta t \rightarrow 5\text{--}20$ с). Расчет пространственных координат МКА имеет смысл синхронизировать с обновлением информации о качестве связи, поскольку большая частота влечет неоправданное повышение

вычислительной нагрузки на аппаратную платформу МКА и снижает качество обучающих данных: разным значениям пространственных координат будут соответствовать одинаковые значения качества [7].

При частоте измерений 3–12 мин за 1 неделю для одной пары МКА в пределе будет накоплено от 30 240 до 120 960 измерений, что достижимо только в случае синхронных орбит пары МКА и наличия постоянной прямой видимости между ними. В остальных случаях значительная часть изменений будет пустой (средняя доля информативных измерений будет определена втором этапе) [8].

Для представления входных данных использован формат с плавающей запятой FP32 (4 байта), поддерживаемый всеми библиотеками нейросетевых вычислений Darknet [9], нейросетевыми ускорителями и большинством процессоров [10]. С учетом ограничений на диапазоны входных и выходных данных также подходит формат FP16, который позволяет добиться более высокой скорости обучения и прогнозирования, но поддерживается он лишь ограниченным числом библиотек и устройств и используется в связке с FP32 [11].

Таким образом, предельный объем данных, накапливаемый за одну неделю для пары МКА при указанном выше диапазоне частот измерений, составляет 120 960–483 840 байт.

Результаты и их обсуждение

Длина хронологической последовательности N_i является гиперпараметром, подлежащим оптимизации в процессе обучения, однако, чтобы не прибегать к перебору значений или эмпирической оценке, необходимо некоторое стартовое значение, рассчитанное из априорной информации об орбитальных параметрах МКА. Большая часть аппаратов – низкоорбитальные (запускаются с разгонных блоков ракетополетчиков или МКС), примем среднюю высоту орбиты МКА, равной 420 км. Орбитальная скорость составляет 7,7 км/с, предельная скорость взаимного движения пары аппаратов – 15,7 км/с, средняя при ортогональных курсах – 10,9 км/с. Радиус прямой видимости на данной высоте составляет 2500 км (с учетом формы орбиты 2520 км), которые пара МКА при средней скорости взаимного движения преодолеет за 230 с. Следовательно, в среднем за одно «окно» прямой видимости пара МКА сможет выполнить от 11 до 46 измерений качества связи [12]. Точность прогнозирования напрямую зависит от количества обучающих данных, поэтому предпочтение отдается максимально возможной частоте измерений. Принимая во внимание особенности точности работы ИНС на границах входных фрагментов, размер хронологического «окна» N_i следует сделать не менее чем двукратно превосходящим количество

измерений, т. е. не менее 92. В итоге принимаем стартовое значение $N_t = 100$.

Вектор $\mathbf{v}_i$ принимаем состоящим из одного интегрального показателя, отражающего текущую выработку ресурса МКА.

Во избежание дублирования данных о положении и состоянии МКА

необходимо хранить их отдельно от показателей качества связи, для чего предлагается следующий формат хранения данных (рис. 4).

Представленную на рисунке 4 структуру, которая является единицей хранения данных обучающей выборки, будем называть кадром состояния сети МКА.




Рис. 4. Формат хранения обучающих данных

Fig. 4. Training data storage format

Каждый кадр при $N_t = 100$ и $\Delta t = 5$ с описывает 500-секундный отрезок

состояния сети МКА и включает фиксированную часть, содержащую данные о

пространственном положении МКА и их состоянии, и переменную часть с данными о качестве связи. Строки кадра содержат индексный заголовок, отражающий номер МКА и индекс элемента: тип координаты, номер элемента вектора или номер второго МКА для значений качества [13].

Объем памяти V_s для хранения строки кадра составляет

$$V_s = (N_t + \text{sizeof}(\text{index})) \cdot \text{sizeof}(\text{FP32}) = \\ = (100 + 2) \cdot 4 = 408 \text{ байт.}$$

Объем памяти для хранения фиксированной части кадра зависит исключительно от количества МКА в составе сети и рассчитывается как

$$V_f(N_{\text{МКА}}) = V_s \cdot (|p_i| + |V_i|) \cdot N_{\text{МКА}} = \\ = 408 \cdot (3 + 1) \cdot N_{\text{МКА}} = 1632 \cdot N_{\text{МКА}} \text{ байт.}$$

Так, для группировки из 100 МКА $V_f(100) = 163\,200$ байт.

Объем памяти для хранения переменной части варьируется в пределах от нуля до $V_Q(N_{\text{МКА}})$:

$$V_Q(N_{\text{МКА}}) = V_s \cdot (N_{\text{МКА}} - 1)^2 = \\ = 408 \cdot (N_{\text{МКА}} - 1)^2 \text{ байт.}$$

Для группировки из 100 МКА предельный объем памяти составляет

$$V_Q(100) = 408 \cdot (100 - 1)^2 = \\ = 3\,998\,808 \text{ байт}$$

Средний фактический объем V_{QM} переменной части зависит от наличия ненулевых данных о качестве связи (нулевые строки $q_{ij}(\tau)$ игнорируются).

При высоте орбиты 420 км В равномерном распределении МКА оценивается как 3,5% V_Q (соотношение площади окружности с радиусом 2500 км, соответствующей зоне прямой видимости одного МКА и площади сферы с радиусом 6800 км, доступной для расположения узлов сети МКА) [14].

$$V_{QM}(100) = 408 \cdot (100 - 1)^2 \cdot 0,035 = \\ = 139\,958 \text{ байт.}$$

Средний общий объем $V(N_{\text{МКА}})$ рассчитывается как

$$V(N_{\text{МКА}}) = V_f(N_{\text{МКА}}) + V_{QM}(N_{\text{МКА}}) = \\ = 408 \cdot (4 \cdot N_{\text{МКА}} + 0,035(N_{\text{МКА}} - 1)^2) \\ \text{байт.}$$

$$V(100) = 303\,158 \text{ байт.}$$

Кадр состояния сети сопровождается метаданными, включающими:

– временную метку начала кадра Start Datetime (UTC, Int64) и GUID МКА (2 x Int64), сформировавшего кадр (Sender GUID);

– словарь, который связывает номер МКА (Index, Int64) с его уникальным идентификатором GUID (2 x Int64) (рис. 5).




Рис. 5. Метаданные кадра состояния сети

Fig. 5. Network Status Frame Metadata

Объем памяти $V_H(N_{MKA})$ для хранения заголовка составляет

$$V_H(N_{MKA}) = (\text{sizeof}(\text{Int } 64) + \text{sizeof}(\text{GUID})) \times (N_{MKA} + 1) = 24 \cdot (N_{MKA} + 1).$$

$$V_H(100) = 2424 \text{ байт.}$$

В качестве контейнера для кадров состояния сети и метаданных предлагается использовать растровый формат Tagged Image File Format (TIFF), чтение-запись которого выполняется с помощью библиотек libtiff [15] или GDAL [16], реализованных на языках C/C++. Растр метаданных имеет базовый тип данных Int64, кадр состояния сети – FP32. В целях экономии полосы пропускания для передачи кадров между МКА или на наземный сегмент сети при создании могут использоваться алгоритмы сжатия LZW, DEFLATE или ZSTD [17].

В процессе работы рассматривались альтернативные варианты организации кадров состояния сети:

1. Текстовый формат хранения данных – более удобен для интерпретации и

анализа, но имеет в ~10 раз больший объем данных, поэтому применяется лишь на этапе имитационного моделирования.

2. Формат с хронологической маркировкой, пример Robot Operation System (ROS) Bag [18], предназначенный для совместного хранения и хронологической привязки потоков разноскоростных данных (видеопотоков, информации от гироскопа, акселерометра, магнитометра и т. п.). Формат имеет развитый SDK, средства визуализации и рассматривался как основной до принятия решения о синхронизации данных пространственного положения МКА и качества связи, после чего применение формата ROS Bag утратило смысл в силу избыточности временных меток, необходимости синхронизации перед обучением или прогнозированием и большего по сравнению с TIFF размера.

Описанный формат позволяет представить обучающие данные, накапливаемые в течение недели в виде 1210 кадров состояния сети, средний суммарный

объем для сети из 100 МКА которых составляет 352,63 Мбайт.

Для создания первичной обучающей выборки разработан программный имитатор сети МКА на основе библиотек osgEarth [19] и Qt [20]. Имитатор позволяет задавать количество МКА в

группировке, назначать TLE и длительность моделирования (снимок окна визуализации процесса в трехмерном режиме представлен на рис. 6, в двумерном режиме – на рис. 7).

Структура имитационной модели представлена ниже (рис. 8).




Рис. 6. Схема визуализации сети малых космических аппаратов в трехмерном режиме

Fig. 6. Diagram of visualization of a network of small spacecraft in three-dimensional mode




Рис. 7. Окно визуализации сети малых космических аппаратов в двумерном пространстве

Fig. 7. Visualization window for a network of small spacecraft in two-dimensional space

Имитационная модель включает в себя следующие компоненты:

1. Трехмерный визуализатор сети МКА и графический интерфейс имитатора. Компонент предназначен для настройки параметров имитационного моделирования и отображения результатов на трехмерной модели геоида.

2. Генератор орбит МКА, позволяющий случайным образом создать заданное количество равномерно распределенных над поверхностью геоида начальных положений аппаратов, каждое из которых описывается геодезическими координатами, высотой над уровнем моря и начальным вектором движения. В процессе моделирования генератор способен имитировать «запуск» дополнительных МКА для включения в группировку.

3. Имитатор измерителя орбитальных параметров МКА. Обеспечивает расчет (TLE) параметров МКА на основе стартовых положений от генератора орбит.

4. Имитатор состояния аппаратной платформы МКА. Компонент имитирует старение аппаратной платформы МКА с заданным средним временем жизни. Возвращает вектор текущего состояния V заданных аппаратов.

5. Имитатор драйвера приема-передачи данных МКА и имитатор драйвера передачи данных абонента. Используют стандартные механизмы Q_i для организации связи и передачи данных между моделями МКА и абонентов.

6. Имитатор среды передачи данных. Предназначен для имитации ошибок и разрывов связи при передаче данных. Имеет два варианта моделей ошибки:

1) модель Маркова для переключения между «хорошим» и «плохим» режимами передачи данных (различаются битовой частотой ошибки, BER);

2) качество связи определяется исходя из наличия прямой видимости и нормированной гауссовской модели прохождения пакетов в зависимости от расстояния между парой МКА с нулевым математическим ожиданием и $\sigma = 2500$ км.

7. Имитатор системы единого времени с ускорением и замедлением. Предназначен для обеспечения единого системного времени группировки МКА и позволяет управлять скоростью моделирования.

8. Случайное размещение абонентов системы связи. Компонент аналогично размещению МКА позволяет случайным образом создать заданное количество равномерно распределенных на поверхности геоида абонентов сети связи МКА. В процессе имитационного моделирования способен добавлять абонентов в сеть.

9. Имитатор модуля глобального позиционирования. Выдает текущее значение геодезических координат с заданной ошибкой. В перспективе будет имитировать движение абонента.

10. Имитатор абонента системы связи. Компонент имитирует сеансы

связи, создаваемые с заданной частотой. Инициатор и адресат определяются по равномерному закону, средний интервал между сеансами и длительность – нормальный закон.

11. Программное обеспечение абонента и программное обеспечение МКА. Компоненты, обеспечивающие точки подключения для компонентов разрабатываемого сетевого ПО. На данный момент предоставляет минимально функциональные заглушки, имитирующие проактивный режим работы сети МКА, достаточные для моделирования.

Модель содержит два внешних компонента:

1. Компонент адресации абонентов, который обеспечивает получение уникального идентификатора абонента поттекстовому обозначению или по описанию (аналог сервиса Domain Name Service).

2. Компонент прогнозирования качества связи и обучение ИНС, который выполняет накопление кадров состояния сети МКА, обучение и дообучение НС, а также прогнозирование качества связи в заданном интервале времени для текущей конфигурации группировки МКА с использованием обученной НС.

Имитационная модель имеет два режима работы:

1. Сбор статистики качества связи для обучения нейронной сети. Использует только проактивный режим работы сети для измерения фактического качества связи для сбора кадров состояния

сети МКА и создания обучающей выборки.

2. Тестирование точности прогнозирования качества связи путем сопоставления результатов работы НС с фактическими значениями качества связи проактивного режима работы сети МКА, полученными в результате имитационного моделирования.

Выводы

Таким образом, можно сделать следующие выводы:

1. Разработан метод применения нейронной сети для прогнозирования возможных состояний сети малых космических аппаратов, который обеспечивает агрегирование и временную синхронизацию данных о состоянии сети МКА, их применение для обучения нейронной сети, а также использования нейронной сети для прогнозирования качества связи.

2. Создан формат обучающей выборки, основанный на представлении состояния сети МКА, которая обеспечивает генерацию начального состояния сети, моделирование проактивного режима её работы, сбор «кадров» состояния сети МКА для порождения наборов синтетических обучающих данных, в виде набора хронологических последовательностей, группируемых в кадры, и позволяющий снизить объем данных, передаваемых между МКА при создании выборки.

3. Разработана имитационная модель сети МКА, которая обеспечивает

генерацию начального состояния сети, моделирование проактивного режима ее работы, сбор «кадров» состояния сети МКА для порождения наборов синтетических обучающих данных, а также

позволяет проводить обучение и тестирование результатов работы нейронной сети для прогнозирования возможных состояний сети МКА.

Список литературы

1. Выбор архитектуры нейронной сети для реализации когнитивных функций сетевого программного обеспечения управления группировкой взаимодействующих малых космических аппаратов / Е. А. Шиленков, С. Н. Фролов, Е. А. Титенко, С. Ю. Мирошниченко // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2023. Т. 13, № 4. С. 8–26. <https://doi.org/10.21869/2223-1536-2023-13-4-8-26>
2. Аганесов А. В. Анализ качества обслуживания в воздушно-космической сети связи на основе иерархического и децентрализованного принципов ретрансляции информационных потоков // Системы управления, связи и безопасности. 2015. № 3. С. 92–121.
3. Оценка своевременности связи при передаче мультисервисного трафика в сети спутниковой связи специального назначения / Е. А. Новиков, Д. Р. Уткин, А. Г. Шадрин, М. Н. Квасов // Системы управления, связи и безопасности. 2018. № 1. С. 136–155.
4. Интеллектуальная система распределенного управления групповыми операциями кластера малоразмерных космических аппаратов в задачах дистанционного зондирования Земли / А. В. Соллогуб, П. О. Скобелев, Е. В. Симонова, А. В. Царев, М. Е. Степанов, А. А. Жилиев // Информационно-управляющие системы. 2013. № 1. С. 16–26.
5. Dynamic surface control for omnidirectional mobile robot with full state constraints and input saturation / C. Zhiqiang, A. Y. Krasnov, L. Duzhesheng, Y. Qiusheng // Scientific and Technical Journal of Information Technologies, Mechanics and Optics. 2023. Vol. 23, no. 6. P. 1096–1105. <https://doi.org/10.17586/2226-1494-2023-23-6-1096-1105>
6. Alakshendra V., Chiddarwar S. S. Adaptive robust control of Mecanum-wheeled mobile robot with uncertainties // Nonlinear Dynamics. 2017. Vol. 87, N 4. P. 2147–2169. <https://doi.org/10.1007/s11071-016-3179-1>
7. Xi C., Dong J. Adaptive neural network-based control of uncertain nonlinear systems with time-varying full-state constraints and input constraint // Neurocomputing. 2019. Vol. 357. P. 108–115. <https://doi.org/10.1016/j.neucom.2019.04.060>
8. Dong C., Liu Y., Wang Q. Barrier Lyapunov function based adaptive finite-time control for hypersonic flight vehicles with state constraints // ISA Transactions. 2020. Vol. 96. P. 163–176. <https://doi.org/10.1016/j.isatra.2019.06.011>

9. Mofid O., Mobayen S. Adaptive finite-time backstepping global sliding mode tracker of quad-rotor UAVs under model uncertainty, wind perturbation, and input saturation // IEEE Transactions on Aerospace and Electronic Systems. 2022. Vol. 58, N 1. P. 140–151. <https://doi.org/10.1109/TAES.2021.3098168>
10. Neural control of robot manipulators with trajectory tracking constraints and input saturation / C. Yang, D. Huang, W. He, L. Cheng // IEEE Transactions on Neural Networks and Learning Systems. 2021. Vol. 32, N 9. P. 4231–4242. <https://doi.org/10.1109/TNNLS.2020.3017202>
11. Multi-robot mission planning with static energy replenishment / B. Li, B. Moridian, A. Kamal, S. Patankar, N. Mahmoudian // Journal of Intelligent and Robotic Systems. 2019. Vol. 95 (2). P. 745–759.
12. Guiding autonomous exploration with signal temporal logic / F. S. Barbosa, D. Duberg, P. Jensfelt, J. Tumova // IEEE Robotics and Automation Letters. 2019. Vol. 4, N 4. P. 3332–3339.
13. Robust collaborative object transportation using multiple MAVs / A. Tagliabue, M. Kamel, R. Siegwart, J. Nieto // International Journal of Robotics Research. 2019. Vol. 38 (9). P. 1020–1044.
14. A complete workflow for automatic forward kinematics model extraction of robotic total stations using the Denavit-Hartenberg convention / C. Klug, D. Schmalstieg, T. Gloor, C. Arth // Journal of Intelligent and Robotic Systems. 2018. Vol. 95. P. 311–329.
15. Калязина Д. М., Кашевник А. М. Разработка и оценка онтологии социкиберфизической системы на основе анализа типовых сценариев использования мобильных роботов // Научный вестник Новосибирского государственного технического университета. 2019. № 2 (75). С. 21–36. <https://doi.org/10.17212/1814-1196-2019-2-21-36>
16. Assessing Contact Graph Routing Performance and Reliability in Distributed Satellite Constellations / J. A. Fraire, P. G. Madoery, S. Burleigh, M. Feldmann, J. Finochietto, A. Charif, N. Zergainoh, R. Velazcol // Journal of Computer Networks and Communications. 2017. N 6. P. 1–18.
17. Система автономной навигации малого космического аппарата / А. В. Аверьянов, К. А. Эсаулов, О. Е. Молчанов, Т. И. Белая // Известия вузов. Приборостроение. 2015. Т. 58, № 1. С. 14–17.
18. Карсаев О. В. Обзор традиционных и инновационных систем планирования миссий космических аппаратов // Информатика и автоматизация. 2016. № 5 (48). С. 151–182.
19. Prognostic model of formation of bronchopulmonary disposition in unemployed children / N. A. Gladskikh [et al.] // Sistem analisys and management in biomedical systems. 2017. Vol. 16, N 3. P. 632–637.

20. Гансвинд И. Н. Малые космические аппараты – новое направление космической деятельности // Международный научно-исследовательский журнал. 2018. № 12-2 (78). С. 84–91. <https://doi.org/10.23670/IRJ.2018.78.12.053>

References

1. Shilenkov E.A., Frolov S.N., Titenko E.A., Miroshnichenko S.Y. Selection of neural network architecture for implementing cognitive functions of network software for controlling a group of interacting small spacecraft. *Izvestiya Yugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, vychislitel'naya tekhnika, informatika. Meditsinskoe priborostroenie = Proceedings of the Southwest State University. Series: Control, Computer Engineering, Information Science. Medical Instruments Engineering*. 2023;13(4):8–26. (In Russ.) <https://doi.org/10.21869/2223-1536-2023-13-4-8-26>
2. Aganesov A.V. Analysis of the quality of service in the aerospace communication network based on the hierarchical and decentralized principles of relaying information flows. *Sistemy upravleniya, svyazi i bezopasnosti. = Control, Communication and Security Systems*. 2015;(3):92–121. (In Russ.)
3. Novikov E.A., Utkin D.R., Shadrin A.G., Kvasov M.N. Assessing the timeliness of communication when transmitting multiservice traffic in a special-purpose satellite communication network. *Sistemy upravleniya, svyazi i bezopasnosti = Control, Communication and Security Systems*. 2018;(1):136–155. (In Russ.)
4. Sollogub A.V., Skobelev P.O., Simonova E.V., Tsarev A.V., Stepanov M.E., Zhi-lyayev A.A. Intelligent system for distributed control of group operations of a cluster of small-sized spacecraft in tasks of remote sensing of the Earth. *Informatsionno-upravlyayushchie sistemy = Information and Control Systems*. 2013;(1):16–26. (In Russ.)
5. Zhiqiang C., Krasnov A.Y., Duzhesheng L., Qiusheng Y. Dynamic surface control for omnidirectional mobile robot with full state constraints and input saturation. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*. 2023;23(6):1096–1105. <https://doi.org/10.17586/2226-1494-2023-23-6-1096-1105>
6. Alakshendra V., Chiddarwar S.S. Adaptive robust control of Mecanum-wheeled mobile robot with uncertainties. *Nonlinear Dynamics*. 2017;87(4):2147–2169. <https://doi.org/10.1007/s11071-016-3179-1>
7. Xi C., Dong J. Adaptive neural network-based control of uncertain nonlinear systems with time-varying full-state constraints and input constraint. *Neurocomputing*, 2019;357:108–115. <https://doi.org/10.1016/j.neucom.2019.04.060>
8. Dong C., Liu Y., Wang Q. Barrier Lyapunov function based adaptive finite-time control for hypersonic flight vehicles with state constraints. *ISA Transactions*. 2020;96:163–176. <https://doi.org/10.1016/j.isatra.2019.06.011>

9. Mofid O., Mobayen S. Adaptive finite-time backstepping global sliding mode tracker of quad-rotor UAVs under model uncertainty, wind perturbation, and input saturation. *IEEE Transactions on Aerospace and Electronic Systems*. 2022;58(1):140–151. <https://doi.org/10.1109/TAES.2021.3098168>
10. Yang C., Huang D., He W., Cheng L. Neural control of robot manipulators with trajectory tracking constraints and input saturation. *IEEE Transactions on Neural Networks and Learning Systems*. 2021;32(9):4231–4242. <https://doi.org/10.1109/TNNLS.2020.3017202>
11. Li B., Moridian B., Kamal A., Patankar S., Mahmoudian N. Multi-robot mission planning with static energy replenishment. *Journal of Intelligent and Robotic Systems*. 2019;95(2):745–759.
12. Barbosa F.S., Duberg D., Jensfelt P., Tumova J. Guiding autonomous exploration with signal temporal logic. *IEEE Robotics and Automation Letters*. 2019;4(4):3332–3339.
13. Tagliabue A., Kamel M., Siegwart R., Nieto J. Robust collaborative object transportation using multiple MAVs. *International Journal of Robotics Research*. 2019;38(9):1020–1044.
14. Klug C., Schmalstieg D., Gloor T., Arth C.A. complete workflow for automatic forward kinematics model extraction of robotic total stations using the Denavit-Hartenberg convention. *Journal of Intelligent and Robotic Systems*. 2018;95:311–329.
15. Kalyazina D.M., Kashevnik A.M. Development and evaluation of cyber-physical-social system ontology based on the analysis of typical scenarios for mobile robots interaction. *Nauchnyi vestnik Novosibirskogo gosudarstvennogo tekhnicheskogo universiteta = Science bulletin of the Novosibirsk State Technical University*. 2019;2(75):21–36. (In Russ.) <https://doi.org/10.17212/1814-1196-2019-2-21-36>
16. Fraire J.A., Madoery P., Burleigh S., Feldmann M., Finochietto J., Charif A., Zergainoh N., Velazcol R. Assessing Contact Graph Routing Performance and Reliability in Distributed Satellite Constellations. *Journal of Computer Networks and Communications*. 2017;(6):1–18.
17. Averyanov A.V., Esaulov K.A., Molchanov O.E., Belaya T.I. Autonomous navigation system for a small spacecraft. *Izvestiya vuzov. Priborostroenie = Proceedings of Universities. Instrument Making*. 2015;58(1):14–17.
18. Karsaev O.V. Review of traditional and innovative spacecraft mission planning systems. *Informatika i avtomatizatsiya = Computer Science and Automation*. 2016;(5):51–182.
19. Gladskikh N.A., et al. Prognostic model of formation of bronchopulmonary disposition in unemployed children. *Sistem Analysis and Management in Biomedical Systems*. 2017;16(3):632–637.
20. Gansvind I.N. Small spacecraft – a new direction in space activities. *Mezhdunarodnyi nauchno-issledovatel'skii zhurnal = International Scientific Research Journal*. 2018;(12-2):84–91. (In Russ.) <https://doi.org/10.23670/IRJ.2018.78.12.053>

Информация об авторах / Information about the Authors

Шиленков Егор Андреевич, кандидат технических наук, директор научно-исследовательского института космического приборостроения и радиоэлектронных систем имени Константина Эдуардовича Циолковского, Юго-Западный государственный университет, г. Курск, Российская Федерация
e-mail: ub3wcl@yandex.ru,
ORCID: 0000-0001-5855-4717

Egor A. Shilenkov, Candidate of Sciences (Engineering), Director of the Research Institute of Space Instrumentation and Radioelectronic Systems named after Konstantin Eduardovich Tsiolkovsky, Southwest State University, Kursk, Russian Federation,
e-mail: ub3wcl@yandex.ru,
ORCID: 0000-0001-5855-4717

Фролов Сергей Николаевич, кандидат технических наук, ведущий научный сотрудник научно-исследовательского института космического приборостроения и радиоэлектронных систем имени Константина Эдуардовича Циолковского, Юго-Западный государственный университет, г. Курск, Российская Федерация
e-mail: snfrolov@bk.ru,
ORCID: 0000-0002-6464-2462

Sergey N. Frolov, Candidate of Sciences (Engineering), Leading Researcher of the Research Institute of Space Instrumentation and Radioelectronic Systems named after Konstantin Eduardovich Tsiolkovsky, Southwest State University, Kursk, Russian Federation
e-mail: snfrolov@bk.ru,
ORCID: 0000-0002-6464-2462

Титенко Евгений Анатольевич, кандидат технических наук, ведущий научный сотрудник научно-исследовательского института космического приборостроения и радиоэлектронных систем имени Константина Эдуардовича Циолковского, Юго-Западный государственный университет, г. Курск, Российская Федерация,
e-mail: johntit@mail.ru,
ORCID: 0000-0002-5659-4747

Evgeniy A. Titenko, Candidate of Sciences (Engineering), Leading Researcher of the Research Institute of Space Instrumentation and Radioelectronic Systems named after Konstantin Eduardovich Tsiolkovsky, Southwest State University, Kursk, Russian Federation,
e-mail: johntit@mail.ru,
RCID: 0000-0002-5659-4747