

КОСМИЧЕСКАЯ ЭЛЕКТРОМЕХАНИКА. КОСМИЧЕСКИЕ АППАРАТЫ. ИССЛЕДОВАНИЕ ОКОЛОЗЕМНОГО КОСМИЧЕСКОГО ПРОСТРАНСТВА

УДК 004.032.26

МЕТОД КРАТКОСРОЧНОГО ПРОГНОЗИРОВАНИЯ ТОЧНОСТНЫХ ХАРАКТЕРИСТИК СИСТЕМЫ ГЛОНАСС С ИСПОЛЬЗОВАНИЕМ ПРЕЦЕДЕНТОВ

Г. А. Зубков

Статья посвящена разработке метода краткосрочного прогнозирования точностных характеристик системы ГЛОНАСС, в основе которого лежит обучение рекуррентной нейронной сети на наборе измерительной информации, полученной с космических аппаратов серии «Глонасс-М». Необходимость прогнозирования точностных характеристик системы ГЛОНАСС обусловлена возрастающим уровнем сложности задач, решаемых орбитальным и наземным сегментами системы ГЛОНАСС, а также отсутствием реализованных методов по прогнозированию состояния орбитальной группировки космических аппаратов системы ГЛОНАСС. Предложенный метод включает в себя алгоритм восстановления утраченной измерительной информации и частный алгоритм обратного распространения ошибки при обучении рекуррентной нейронной сети. Применение данного метода позволило спрогнозировать значение точностных характеристик системы ГЛОНАСС с точностью, позволяющей своевременно принимать меры по планированию применения орбитальной группировки по целевому назначению. Качественная оценка производилась путём сравнения реальных и спрогнозированных значений точностных характеристик системы ГЛОНАСС.

Ключевые слова: нейронная сеть, космический аппарат, орбитальная группировка, прогнозирование, ГЛОНАСС.

Введение

В настоящее время существует четыре функционирующие глобальные навигационные спутниковые системы: GPS, Galileo, BeiDou и ГЛОНАСС, – в которых реализованы различные системы краткосрочного прогнозирования, основанные на применении алгоритмов с использованием классических математических методов экстраполяции функций и уравнений преобразования Фурье. Недостатками применения данных методов являются повышенные вычислительные затраты на вычисление степенных и экспоненциальных функций, а также невозможность построения прогнозирующей модели с учетом нефиксированного набора функциональных зависимостей, что сказывается на качестве получения прогнозных данных. В последнее десятилетие в связи с резким скачком в развитии вычислительной техники начали применяться алгоритмы прогнозирования на основе обработки временных рядов нейронными сетями, для обучения которых требуются большие наборы статистической информации. Несомненными плюсами применения нейронных сетей является учет различных деструктивных воздействий внешней и внутренней среды космического аппарата (КА), которые не учитываются в классических моделях прогнозирования.

В соответствии с Федеральной целевой программой «Поддержание, развитие и использование системы ГЛОНАСС на 2012 – 2020 годы» [1] количество характеристик орбитальной группировки (ОГ) ГЛОНАСС, определяющих точность решения задач координатно-временного и навигационного обеспе-

чения (КВНО), соответствует значениям:

1. Эквивалентная погрешность псевдодальноности (ЭПД) в пространстве за счет ошибок космического сегмента.
2. Эквивалентная погрешность псевдоскорости (ЭПС) в пространстве за счет ошибок космического сегмента.
3. Погрешность определения потребителем пространственных координат за счет ошибок космического сегмента.
4. Погрешность определения времени потребителем в системной шкале времени космического комплекса (КК) системы ГЛОНАСС за счет ошибок космического сегмента.
5. Погрешность определения расхождения системной шкалы времени КК системы ГЛОНАСС с национальной шкалой координированного времени UTC.

В соответствии с ГОСТ 32454-2013 [2] ЭПД является потенциальной точностью системы ГЛОНАСС при работе в реальном масштабе времени. ЭПД можно представить в виде набора статистических данных – временного ряда, который является входной информацией для обучения нейронной сети.

Одной из решаемых задач в обучении нейронных сетей является прогнозирование временных рядов, цель которого – снижение рисков в процессе принятия решений. Назначение рекуррентной нейронной сети – обработка последовательности значений:

$$\{\mathbf{x}^{t-1}, \mathbf{x}^t, \mathbf{x}^{t+1}, \dots, \mathbf{x}^r\},$$

где \mathbf{x}^t – значение искомого параметра в определенный

момент времени, t изменяется в пределах $[1 \dots \tau]$ [3].

Обычно прогноз получается с небольшой погрешностью, которая зависит от системы прогнозирования и качества предварительных данных. Качество данных – это обобщенное понятие, которое отражает степень их пригодности к решению задачи обучения нейронной сети. Основными критериями качества измерительной информации являются полнота, достоверность, точность, непротиворечивость, доступность и своевременность полученной информации с борта КА.

Функция потерь, используемая для оценки качества обучения, характеризует близость прогнозируемых значений к значениям имеющегося набора измерительной информации. Существует множество различных функций потерь, выбор которых зависит от решаемой задачи. Применительно к решаемой задаче функцией потерь было выбрано среднее линейное отклонение, которое интерпретирует средний модуль отклонений значений характеристики от среднего арифметического значения характеристики в наборе измерительной информации. Другими словами, равенство среднего линейного отклонения нулю означает, что объясняемая переменная точно описывается рассматриваемой моделью [4].

Целью проведенного исследования является разработка метода, позволяющего спрогнозировать значение точностных характеристик системы ГЛОНАСС с максимальной степенью достоверности. Результаты прогноза точностных характеристик могут быть использованы при оперативной оценке состояния навигационного поля в условиях деструктивных воздействий на элементы системы и дестабилизирующих факторов внешней и внутренней среды. В ходе исследования был подготовлен набор измерительной информации для обучения рекуррентной нейронной сети. Впоследствии набор измерительной информации был обработан с использованием предложенного метода для получения прогнозных значений искомых величин. В итоге было проведено сравнение реальных и спрогнозированных значений точностных характеристик системы ГЛОНАСС с использованием среднего линейного отклонения модели. Среднее линейное отклонение модели, полученное при обучении рекуррентной нейронной сети набором измерительной информации, показало результат, позволяющий использовать данный метод при планировании применения ОГ по целевому назначению (ЦН).

Материалы исследования

Данные, необходимые для реализации метода прогнозирования точностных характеристик, полу-

чены в секторе анализа центра управления системой ГЛОНАСС и представляют собой множество векторов точностных характеристик отдельных КА на усредненном интервале измерения, равном пяти минутам. Рассматриваемый метод включает этапы обработки пропусков в наборе измерительной информации и реализацию модифицированного алгоритма обратного распространения ошибки обучения для прогнозирования точностных характеристик системы ГЛОНАСС. Выполнение данных условий в конечном итоге позволит спрогнозировать значения точностных характеристик на интервале времени, равном 8 часам. Рассматриваемый метод представлен в виде алгоритма на рис. 1.

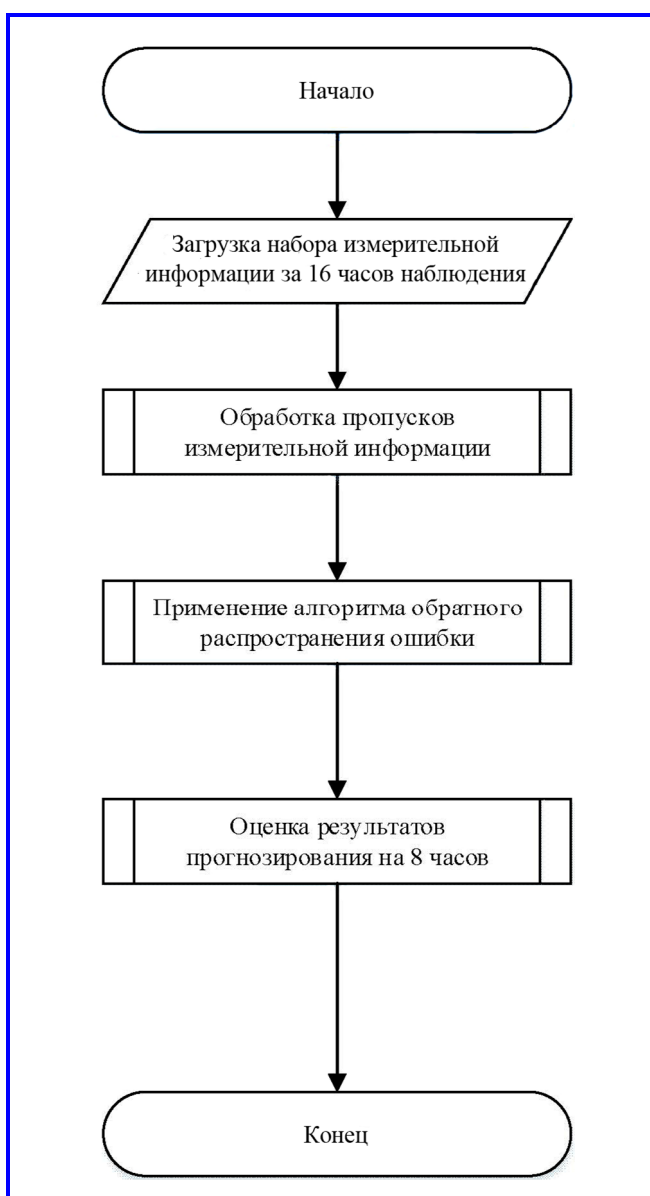


Рис. 1. Алгоритм прогнозирования точностных характеристик

На вход поступает измерительная информация, содержащая в себе сведения о точностных характеристиках отдельного КА на усредненном интервале времени, равном 5 минутам. Применение усреднения на 5-минутном интервале обусловлено высокой емкостью исходной базы измерительной информации, что влечет за собой увеличение времени вычисления прогнозных значений точностных характеристик. После получения данных необходимо провести обработку пропусков в базе измерительной информации. Так как значения параметров специальной аппаратуры, характеризующих выполнение навигационным КА задач по целевому назначению, в общем виде можно описать логнормальным законом распределения, то предлагается использовать процедуру восстановления функции нормального распределения. Функция плотности вероятности стандартного нормального распределения имеет вид:

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

Интегральная функция распределения вероятности имеет следующий вид:

$$F(x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{(u-\mu)^2}{2\sigma^2}} du,$$

где μ и σ – математическое ожидание и среднеквадратичное отклонение нормального распределения.

Интегральная функция распределения вероятности, как правило, учитывается применением специальной функции $Erf(x)$:

$$Erf(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-u^2} du.$$

Изменение исходного набора значений измерительной информации x_j , распределенных по нормальному закону с параметрами μ и σ осуществляется следующим образом:

$$x_i = \frac{1}{2} \left(1 + Erf \left(\frac{x_i - \mu}{\sqrt{2}\sigma} \right) \right).$$

Используя полученное выражение, исходная измерительная информация приводится к равномерному распределению [5].

После проведения процедуры обработки пропусков в наборе измерительной информации следует процедура обучения рекуррентной нейронной сети при помощи модифицированного алгоритма обратного распространения ошибки. Рассматрива-

емая в данной работе рекуррентная нейронная сеть изображена на рис. 2.

Функционирование рекуррентной сети прямого распространения описывается следующим уравнением:

$$a^{(t)} = \mathbf{b} + W\mathbf{h}^{(t+1)} + U\mathbf{x}^{(t)},$$

где $a^{(t)}$ – функция, описывающая прямое распространение в модели в момент времени t ; \mathbf{b} – вектор смещения модели; W – рекуррентные связи между скрытыми блоками; $\mathbf{h}^{(t+1)}$ – вектор состояния модели в момент времени $t + 1$; U – рекуррентные связи между входными и скрытыми блоками.

Для каждого временного шага применяется следующая система уравнений:

$$\mathbf{h}^{(t)} = \tanh(a^{(t)});$$

$$o^{(t)} = \mathbf{c} + \mathbf{V}\mathbf{h}^{(t)};$$

$$\hat{\mathbf{y}}^{(t)} = \text{softmax}(o^{(t)}),$$

где \tanh – функция активации для скрытых блоков; $o^{(t)}$ – ненормированная логарифмическая вероятность в момент времени t ; \mathbf{c} – вектор смещения модели; \mathbf{V} – вектор смещения модели; $\hat{\mathbf{y}}^{(t)}$ – вектор нормированных вероятностей в момент времени t ; softmax – функция активации для скрытых блоков.

На рис. 2 изображен граф вычисления потерь при обучении рекуррентной нейронной сети, который отображает входную последовательность значений x в выходную последовательность значений o . Функция потерь L измеряет, насколько далеко каждый элемент o отдален от соответствующего значения y . При использовании к выходам нейросети функции softmax считается, что o – ненормированная логарифмическая вероятность.

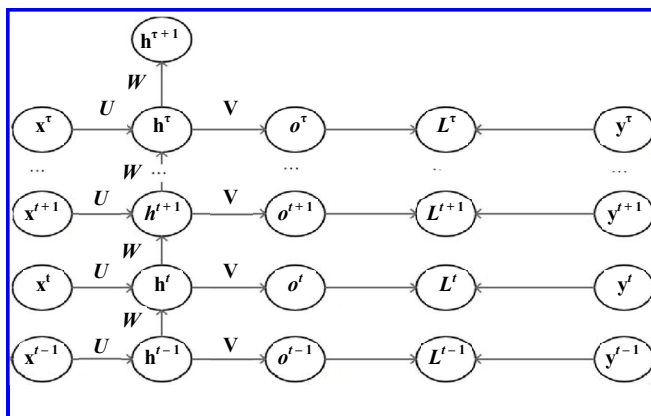


Рис. 2. Граф вычислений потерь при прогнозировании точностных характеристик системы ГЛОНАСС

Вычисление градиента в рекуррентной нейронной сети проводится по алгоритму обратного распространения для развернутого графа вычислений.

В использованном графе вычислений имеются параметры $U, \mathbf{V}, W, \mathbf{b}, \mathbf{c}$, а также последовательность вершин, определенная в момент времени t : $\mathbf{x}^t, \mathbf{h}^t, o^t$ и L^t . Для каждой вершины N мы должны рекурсивно вычислить градиент $\nabla_N L$, учитывая градиенты, вычисленные в вершинах, следующих за ней в графе в момент времени $t + 1$. Рекурсия начинается с вершин, предшествующих окончательной потере:

$$\frac{\partial L}{\partial L} = 1.$$

Предполагается, что выходы o^t используются в качестве аргумента функции *softmax* для получения вектора вероятностей выходов $\hat{\mathbf{y}}$. Функция потерь – это отрицательное логарифмическое правдоподобие истинной метки \mathbf{y}^t при известных к этому моменту входах. Градиент $\nabla_{o^t} L$ по выходам в момент t для всех i , t имеет вид:

$$\left(\nabla_{o^t} L\right)_i = \frac{\partial L}{\partial o_i^{(t)}} = \hat{\mathbf{y}}_i^{(t)} - 1_{i, \mathbf{y}^{(t)}}.$$

Так как в данной системе уравнений движение осуществляется от конца последовательности к ее началу, то в последний момент времени τ вершина \mathbf{h}^τ есть только один потомок o^t и градиент вычисляется следующим образом:

$$\nabla_{\mathbf{h}^\tau} L = \mathbf{V}^T \nabla_{o^t} L.$$

Далее проводим итерации назад во времени для момента времени t , изменяющегося в пределах $[\tau \dots 1]$. Потомками для \mathbf{h}^t являются o^t и \mathbf{h}^{t+1} , градиент вычисляется следующим образом:

$$\nabla_{\mathbf{h}^t} L = \left(\frac{\partial \mathbf{h}^{(t+1)}}{\partial \mathbf{h}^{(t)}}\right)^T \left(\left(\nabla_{\mathbf{h}^{(t+1)}} L\right) + \left(\frac{\partial o^t}{\partial \mathbf{h}^{(t)}}\right)^T \right) \left(\nabla_{o^t} L\right).$$

Также существует необходимость в вычислении градиентов по вершинам параметров $U, \mathbf{V}, W, \mathbf{b}, \mathbf{c}$. В уравнениях, приведенных ниже, используется метод обратного распространения ошибки, который вычисляет вклад в градиент одного ребра графа вы-

числений. Оператор $\nabla_w f$ учитывает вклад рекуррентной связи между скрытыми блоками в значение f , вносимый всеми ребрами графа вычислений. Для решения данной проблемы вводятся фиктивные переменные $W^{(t)}$, которые являются копиями W , но учитывающиеся только на временном шаге t . Тогда $\nabla_{W^{(t)}} f$ разрешено учитывать для учета вклада весов W на временном шаге t . Градиенты по вершинам параметров будут иметь следующий вид [6]:

$$\nabla_{\mathbf{c}} L = \sum_t \left(\frac{\partial o^t}{\partial \mathbf{c}}\right)^T \nabla_{o^t} L;$$

$$\nabla_{\mathbf{b}} L = \sum_t \left(\frac{\partial \mathbf{h}^t}{\partial \mathbf{b}}\right)^T \nabla_{\mathbf{h}^t} L;$$

$$\nabla_{\mathbf{V}} L = \sum_t \sum_i \left(\frac{\partial \mathbf{h}^t}{\partial \mathbf{b}}\right)^T \nabla_{\mathbf{V}} L o_i^{(t)};$$

$$\nabla_W L = \sum_t \sum_i \left(\frac{\partial L}{\partial \mathbf{h}^{(t)}}\right)^T \nabla_W L \mathbf{h}_i^{(t)}.$$

Результаты исследования

Используемая модель для решения задачи краткосрочного прогнозирования точностных характеристик системы ГЛОНАСС – рекуррентная нейронная сеть, входным слоем которой является слой *Embedding*, скрытые слои – два слоя *LSTM* со 128-ю и 64-мя нейронами в каждом слое с активированной рекуррентностью, выходной слой – *Dense* с одним выходным нейроном. Набором данных для обучения нейронной сети является информация о функционировании специальной бортовой аппаратуры навигационных КА, полученных в центре управления системой ГЛОНАСС в период с 01.09.2020 – 31.11.2020, который составляет 307908 векторов измерительной информации.

Применение данного метода для прогнозирования точностных характеристик системы ГЛОНАСС показало высокую точность на краткосрочном интервале. Максимальная точность прогнозирования достигается при применении базы измерительной информации, содержащей данные, как минимум, за 16 часов наблюдения и, как максимум, на 8 часов прогнозирования. На рис. 3 показан результат прогнозирования ЭПД для КА «Глонасс-М» № 760.

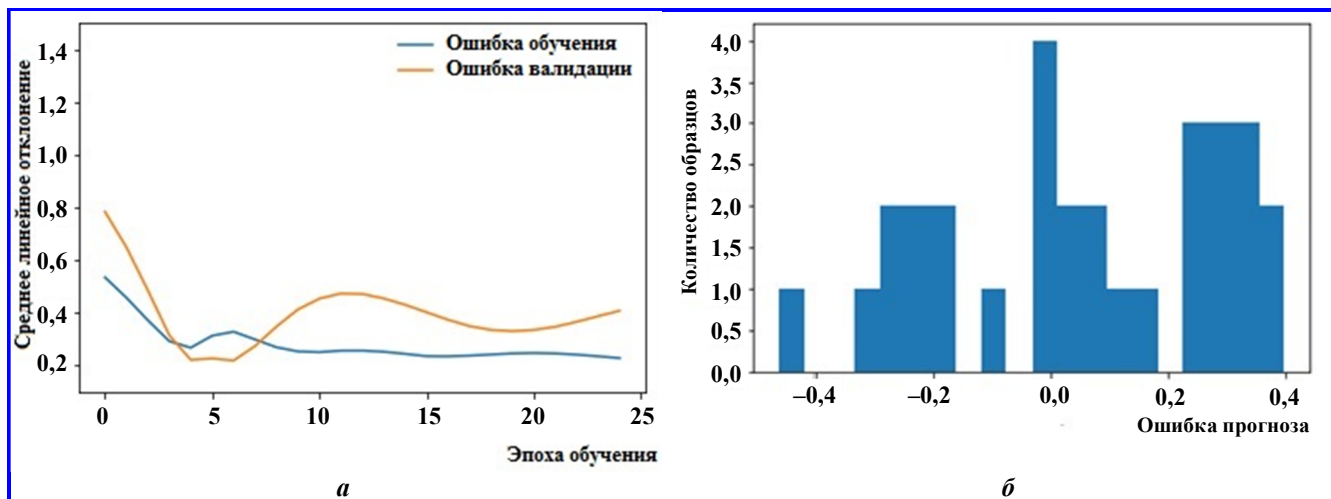


Рис. 3. Результат прогнозирования эквивалентной погрешности псевдодальности: *a* – зависимость среднего линейного отклонения от эпохи обучения; *б* – диаграмма распределения ошибки прогнозирования

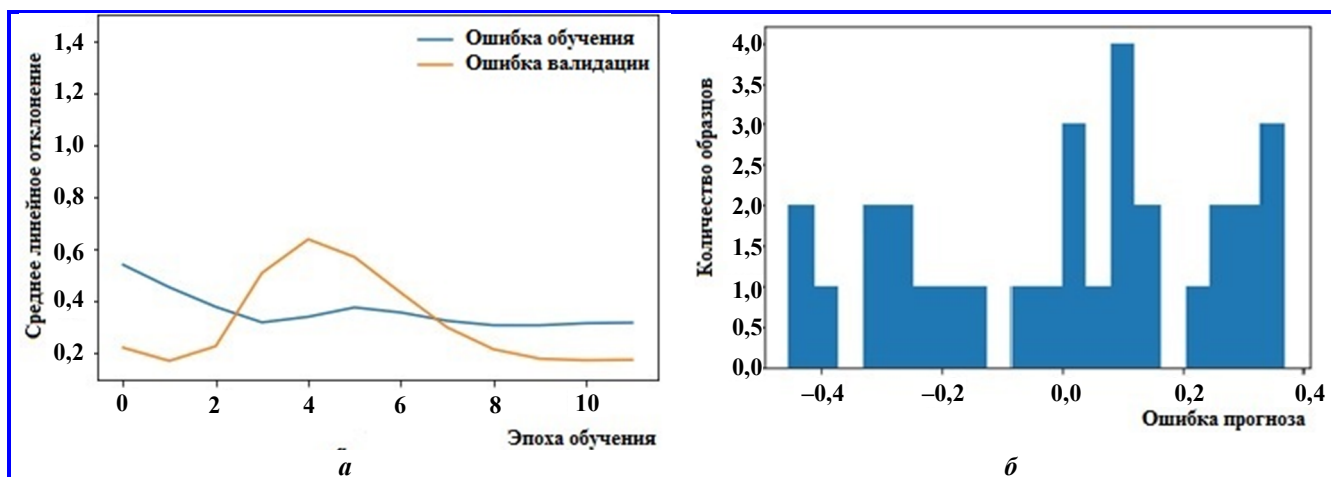


Рис. 4. Результат прогнозирования эквивалентной погрешности псевдоскорости: *a* – зависимость среднего линейного отклонения от эпохи обучения; *б* – диаграмма распределения ошибки прогнозирования

На рис. 3, *a*, видно, что ошибка на тестовом наборе данных имеет затухающий характер – модель обучилась. Значение среднего модуля отклонения модели 0,2003 м.

На рис. 3, *б*, проведена оценка распределения ошибок обучения при прогнозировании значения ЭПД, из которой следует, что модель чаще всего ошибается на значение, не превышающее 0,2 м, что удовлетворяет требованиям краткосрочного прогнозирования ЭПД КА «Глонасс-М». На рис. 4 показан результат прогнозирования ЭПС для КА «Глонасс-М» № 760.

На рис. 4, *a*, видно, что ошибка на тестовом наборе данных имеет затухающий характер, что подразумевает под собой обучение построенной модели. Значение среднего модуля отклонения модели 0,21 мм/с.

На рис. 4, *б*, проведена оценка распределения

ошибок обучения при прогнозировании значения ЭПС, из которой следует, что модель чаще всего ошибается на значение, не превышающее 0,22 мм/с, что удовлетворяет требованиям краткосрочного прогнозирования ЭПС КА «Глонасс-М».

Улучшение разработанной модели прогнозирования возможно при выполнении следующих условий:

- увеличения количества слоев и блоков в них, что приведет к увеличению репрезентативной емкости модели и, соответственно, к увеличению времени прогнозирования;

- увеличения количества эпох обучения, что повлечет за собой увеличение времени обучения модели;

- применения данных с каждого сеанса измерения телеметрической информации, что также приведет к увеличению времени прогнозирования;

- применения информации о параметрах радионавигационного поля станций измерения;
- применения информации об окружающей среде в месте приема измерительной информации;
- применения информации о релятивистских и гравитационных воздействиях, влияющих на КА.

Заключение

Разработанный метод краткосрочного прогнозирования точностных характеристик системы ГЛОНАСС с использованием прецедентов позволил получить значения ЭПД и ЭПС на 8-часовом интервале прогнозирования. В основе метода лежит применение модифицированной рекуррентной нейронной сети, входными значениями которой являются параметры целевой аппаратуры. Также учитывается «опыт» – состояние навигационного поля. Результаты прогноза точностных характеристик позволяют оперативно оценивать значения ЭПД и ЭПС в условиях деструктивных воздействий на элементы системы и дестабилизирующих факторов внутренней и внешней среды. Полученные результаты могут быть использованы при разработке математической модели интеллектуальной системы анализа состояния навигационного КА. Данная интеллектуальная система может быть положена в основу аппаратно-программного комплекса, который позволит в полной мере оптимизировать процесс анализа статистической информации на этапе проведения испытаний и применения космических навигационных систем.

Поступила в редакцию 01.12.2020

*Георгий Алексеевич Зубков, научный сотрудник, т. (495) 802-05-44,
e-mail: GeorgyZubkov@mail.ru.*

*(Главный испытательный космический центр Министерства обороны
Российской Федерации им. Г.С. Титова (ГИКЦ МО РФ им. Г.С. Титова)).*

Литература

1. Федеральная целевая программа «Поддержание, развитие и использование системы ГЛОНАСС на 2012 – 2020 годы» в рамках государственной программы Российской Федерации «Космическая деятельность России»: утверждена постановлением Правительства Российской Федерации от 3 марта 2012 г. – 2012. – № 189.
2. ГОСТ 32454-2013. Глобальная навигационная спутниковая система. Параметры радионавигационного поля. Технические требования и методы испытаний: национальный стандарт Российской Федерации: утвержден и введен Приказом Федерального агентства по техническому регулированию и метрологии от 15 апреля 2014 г. № 355-ст: введен впервые: дата введения 2014-07-01 / подготовлен Открытым акционерным обществом «Научно-технический центр современных навигационных технологий «Интернавигация» (ОАО «НТЦ «Интернавигация»). – Москва: Стандартинформ, 2014. – 20 с.
3. Neural networks and physical systems with emergent collective computational abilities / J. J. Hopfield // Proceedings of National Academy of Sciences. – 1982. – Vol. 79. – № 8. – P. 2554 – 2558. – DOI: 10.1073/pnas.79.8.2554.
4. Метод программной обработки телеметрической информации космического аппарата для решения задач прогнозирования технического состояния / Г. А. Зубков // XXI век: итоги прошлого и проблемы настоящего плюс. – 2020. – Т. 9. – № 4 (52). – С. 46 – 50.
5. Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Г. Курвилль; пер. с англ. А. А. Слинкина. – 2-е изд., испр. – Москва: ДМК Пресс, 2018. – 652 с.: цв. ил.
6. Применение рекуррентных нейронных сетей для прогнозирования технического состояния космического аппарата / Г. А. Зубков // Научный электронный журнал «Инновации. Наука. Образование». – Тольятти, 2020. – № 21 (ноябрь) – С. 1268 – 1273.

METHOD FOR SHORT-TERM PREDICTION OF THE ACCURACY CHARACTERISTICS OF THE GLONASS SYSTEM USING PRECEDENTS

G. A. Zubkov

The article is devoted to the development of a method for short-term forecasting of the accuracy characteristics of the GLONASS system, which is based on the training of a recurrent neural network on a set of measuring information received from the "Glonass-M" series spacecraft. The relevance of predicting the accuracy characteristics of the GLONASS system is due to the increasing level of complexity of the tasks solved by the GLONASS system control center, as well as the lack of implemented methods for predicting the state of the orbital constellation of GLONASS spacecraft. The proposed method includes an algorithm for recovering the lost measurement information and a private algorithm for back propagation of an error when training a recurrent neural network. The application of this method made it possible to predict the value of the accuracy characteristics of the GLONASS system with an accuracy that allows timely taking measures to plan the use of the orbital constellation for its intended purpose. A qualitative assessment was made by comparing the real and predicted values of the accuracy characteristics of the GLONASS system.

Keywords: neural network, spacecraft, orbital constellation, forecasting, GLONASS.

References

1. Federal Target Program ‘Maintenance, development and use of GLONASS 2012 – 2020’ under the Russian Federal Program ‘Space-related activities of Russia’ : approved by RF Government order of March 3, 2012. – 2012. – No. 189.
2. GOST 32454-2013. Global Navigation Satellite System. Parameters of radio navigation field. Technical requirements and test methods : National standard of the Russian Federation : approved and introduced by the Order of the Federal Agency for Technical Regulation and Metrology No. 355-ст of April 15, 2014 : introduced for the first time : date of introduction 01.07.2014 / prepared by the Joint Stock Company ‘Internavigation Research & Technical Centre of Advanced Navigation Technologies’ (JSC RTC ‘Internavigation’) – Moscow : Standartinform, 2014. – 20 p.
3. Neural networks and physical systems with emergent collective computational abilities / J. J. Hopfield // Proceedings of National Academy of Sciences. – 1982. – Vol. 79. – No. 8. – P. 2554 – 2558. – DOI : 10.1073/pnas.79.8.2554.
4. Method of software processing of spacecraft telemetry information for addressing the tasks of technical state prediction / G. A. Zubkov // XXI Century: Resumes of the Past and Challenges of the Present plus. – 2020. – Vol. 9. – No. 4 (52). – Pp. 46 – 50.
5. Ian Goodfellow. Deep learning / Ian Goodfellow, Yoshua Bengio, Aaron Courville; translated from Engl. by A. A. Slinkina. – 2nd edition, correct. – Moscow : DMK Press, 2018. – 652 p.: col. ill.
6. Application of recurrent neural networks for prediction of spacecraft technical state/ G. A. Zubkov // Electronic scientific journal ‘Innovations. Science. Education’. – Togliatti, 2020. – No. 21 (November) – Pp. 1268 – 1273.

*Georgy Alekseevich Zubkov, Researcher, Main test space center of the Ministry of Defense of the Russian Federation named after G.S. Titov,
tel. +7(495) 802-05-44, e-mail: GeorgyZubkov@mail.ru.
(MTSC MO RF named after G.S. Titov).*