

УДК 004.04

DOI: 10.46548/21vek-2020-0951-0008

МЕТОД ПРОГРАММНОЙ ОБРАБОТКИ ТЕЛЕМЕТРИЧЕСКОЙ ИНФОРМАЦИИ КОСМИЧЕСКОГО АППАРАТА ДЛЯ РЕШЕНИЯ ЗАДАЧ ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ

©2020

Зубков Георгий Алексеевич, научный сотрудник

Главный испытательный космический центр Министерства обороны Российской Федерации им. Г.С. Титова (143090, Россия, Московская область, Краснознаменск, улица Октябрьская д.3, e-mail: GeorgyZubkov@mail.ru)

Аннотация. Статья посвящена разработке метода программной обработки телеметрической информации для обучения многослойного перцептрона прямого распространения, который решает задачу прогнозирования технического состояния космического аппарата. Актуальность прогнозирования состояния космических аппаратов обусловлена возрастающим уровнем сложности задач, решаемых сектором анализа центра управления полётом. Описанный в статье метод был применен к набору телеметрической информации для обучения многослойного перцептрона прямого распространения, который представляет собой множество векторов состояния бортовой аппаратуры космических аппаратов. Особенностью данного набора телеметрической информации является то, что отражаемые характеристики имеют сложно формализованные нелинейные зависимости между собой, а также множество аномальных значений, искажающих конечный результат прогнозирования целевых характеристик. Предложенный метод включает в себя проведение программной подготовки данных путём обработки пропусков в телеметрической информации, а также комплексной обработки значений параметров бортовой аппаратуры. Применение данного метода позволило существенно улучшить качество обучения многослойного перцептрона прямого распространения по сравнению с исходным набором телеметрической информации без обработки. Качественная оценка производилась путём сравнения итоговых значений коэффициентов детерминации исходного и обработанного набора телеметрической информации.

Ключевые слова: нейронная сеть, многослойный перцептрон, космический аппарат, орбитальная группировка, телеметрическая информация.

METHOD OF SOFTWARE PROCESSING OF SPACE VEHICLE TELEMETRIC INFORMATION FOR SOLVING TECHNICAL STATE FORECASTING PROBLEMS

©2020

Zubkov Georgy Alekseevich, researcher

Main test space center of the Ministry of Defense of the Russian Federation named after G.S. Titova (143090, Russia, Moscow region, Krasnoznamensk, Otkyabrskaya street, 3, e-mail: GeorgyZubkov@mail.ru)

Abstract. This article is devoted to the development of a method for software processing of telemetric information for training a multi-layer perceptron of direct propagation, which solves the problem of predicting the technical state of a spacecraft. The relevance of predicting the state of spacecraft is due to the increasing level of complexity of the tasks performed by the analysis sector of the mission control center. The method described in the article was applied to a set of telemetric information for training a multi-layer perceptron of direct propagation, which is a set of vectors of the state of onboard spacecraft equipment. A feature of this set of telemetric information is that the reflected characteristics have complex formalized nonlinear relationships among themselves, as well as many anomalous values that distort the final result of predicting target characteristics. The proposed method includes software preparation of data by processing gaps in telemetry information, as well as complex processing of the values of parameters of onboard equipment. The application of this method made it possible to significantly improve the quality of training a multi-layer perceptron of direct propagation in comparison with the initial set of telemetric information without processing. A qualitative assessment was made by comparing the final values of the determination coefficients of the initial and processed set of telemetry information.

Key words: neural network, multilayer perceptron, spacecraft, orbital constellation, telemetric information.

Введение. Одной из решаемых задач в глубоком обучении является прогнозирование временных рядов, целью которого является снижение рисков в процессе принятия решений [1]. Назначение многослойного перцептрона (нейронной сети) прямого распространения – аппроксимация некоторой функции f . Каждый параметр бортовой аппаратуры x_j связан с каждым нейроном единственного слоя перцептрона посредством связи с весом w_{ij} , где $i = \overline{1, M}$ номер нейронов слоя из общего их числа M , $j = \overline{1, N}$ номер входных параметров нейронной сети из N возможных. Выход нейронного слоя (прогноз) вычисляется по сле-

дующей формуле:

$$y_i = f(w_{ij} * x_j)$$

Обыкновенно, прогноз получается с небольшой погрешностью, которая зависит от системы прогнозирования и качества предварительных данных [2]. Качество данных – это обобщенное понятие, которое отражает степень их пригодности к решению задачи обучения нейронной сети. Основными критериями качества телеметрической информации являются полнота, достоверность, точность, непротиворечивость, доступность и своевременность полученной информации с борта космического аппарата [3].

Окончательный набор телеметрической информации содержит отражаемые характеристики, которые имеют сложную нелинейную зависимость между ними, а также многочисленные аномальные значения, искажающие конечный результат прогноза целевых характеристик.

Функция потерь, используемая для оценки качества обучения, характеризует близость прогнозируемых значений к значениям имеющегося набора телеметрической информации. Существуют множество различных функций потерь, выбор которых зависит от решаемой задачи. Применительно к решаемой задаче функцией потерь был выбран коэффициент детерминации, который интерпретирует долю дисперсии зависимой переменной, объясняемой рассматриваемой моделью. В случае линейной зависимости R^2 является квадратом множественного коэффициента связи между целевой характеристикой и объясняющими параметрами бортовой аппаратуры. Другими словами, равенство коэффициента детерминации единице означает, что объясняемая переменная точно описывается рассматриваемой моделью [4].

Целью проведенного исследования является разработка метода, позволяющего обработать пропуски в телеметрической информации, а также провести комплексную обработку значений параметров бортовой аппаратуры. В ходе исследования был подготовлен набор телеметрической информации для обучения нейронной сети прямого распространения. Впоследствии набор телеметрической информации был обработан с использованием предложенного метода для повторного обучения многослойного перцептрона. В итоге было проведено сравнение двух функций потерь от процесса обучения многослойного перцептрона на исходном наборе телеметрии и обработанном наборе соответственно. Коэффициент детерминации, полученный при обучении перцептрона набором обработанной телеметрии, показал лучший результат.

Материалы исследования. Рассматриваемый метод включает этапы структурной программной подготовки телеметрической информации путём обработки пропусков в телеметрической информации, обработки аномальных значений параметров работы бортовой аппаратуры космического аппарата, кодирования категориальных признаков в телеметрическом кадре, а также нормализации всего набора параметров функционирования, полученных с космических аппаратов. Выполнение данных условий в конечном итоге позволит улучшить качество обучения нейронной сети прямого распространения [5 – 7]. Рассматриваемый метод обработки телеметрической информации представлен в виде алгоритма на рисунке 1.

На вход поступает телеметрическая информация, полученная с борта космического аппарата средствами наземного комплекса управления [8]. После получения данных необходимо исключить аномальные значения (выбросы) из набора телеметрической информации. Как правило, выброс является результатом измерения, отличным от других измерений. Обычно

база данных телеметрии может содержать более одного аномального значения [9]. Задачу определения аномальных значений решают путём оценки по заданному критерию значимости с учетом предполагаемого распределения значений параметров бортовой аппаратуры.

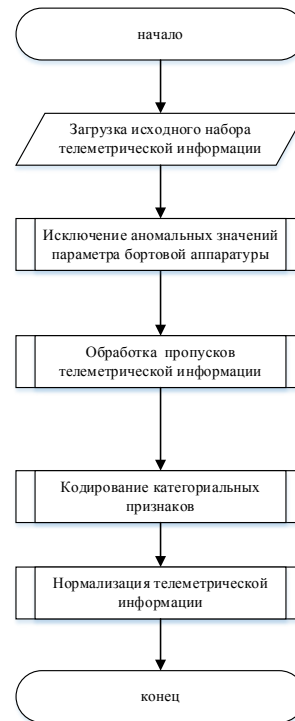


Рисунок 1 – Алгоритм обработки телеметрической информации

Аномальные значения редко являются «неверными» измерениями параметров, поэтому необходимо рассматривать их как признаки редких процессов, требующих дальнейшего изучения. Если аномальные значения телеметрии вызваны исключительно особенностями работы бортовой аппаратуры или наземного комплекса управления, то необходимо выявить причины выброса. Так как функционирование бортовой аппаратуры космического аппарата описывается нормальным законом распределения, то каждое 22-е значение измерений будет выходить из значения двух отклонений, а каждое 370-е измерение – из значения трех отклонений.

Проверку телеметрической информации необходимо начать с обычной зрительной проверки полученной телеметрии. Как правило, для обнаружения аномалий строят график вероятности и диаграмму размаха.

График вероятности позволяет провести графический контроль согласованности результатов измерений с предполагаемым распределением, а также выявить аномалии в наборе телеметрии. Точки на графике вероятности, сильно отклоняющиеся от прямой линии, вокруг которой лежат все остальные значения измерений, необходимо определять как выбросы [10].

Диаграмма размаха – это график, используемый в описательной статистике для компактного представления равномерного распределения вероятностей. На

диаграмме размаха наглядно изображены медиана, квартили, экстремумы выборки, а также аномальные значения. Нижние и верхние границы диаграммы размаха определяют следующим образом:

$$\frac{Q_l - k(Q_3 - Q_1)}{Q_l + k(Q_3 - Q_1)}$$

где Q_1 и Q_3 – первый и третий квантиль выборки, k – константа.

Так как целевые характеристики космического аппарата подчиняются логонормальному распределению, то один или более аномальных значений показателей работы бортовой аппаратуры в наборе телеметрических данных с нормальным распределением могут быть выявлены при помощи процедуры, известной как обобщенное экстремальное студентизированное отклонение (ОЭСО). Эта процедура подходит для мониторинга ошибки первого рода при обнаружении более чем l аномальных значений работы бортовой аппаратуры с уровнем значимости α и $l \leq m$, где m – установленное максимальное количество аномальных значений показателей работы бортовой аппаратуры (выбросов).

Процедура ОЭСО состоит из семи этапов:

1. Точки, соответствующие наблюдениям набора телеметрической информации x_1, x_2, \dots, x_n , наносятся на график логонормального распределения данных. Выбирается количество точек, значительно отклоняющихся от прямой, на которой располагаются остальные значения измеренных параметров бортовой аппаратуры. В результате находится приблизительное количество выбросов в наборе телеметрической информации.

2. Выбирается уровень авторитетности α и определяется количество аномалий m как число, большее или равное числу возможных аномальных значений, полученному на этапе 1. Следующие шаги начинают с $l=0$.

3. Определяется контрольная статистика:

$$\max |x - \bar{x}(L_l)|,$$

$$R_l = \frac{x_l \in L_l}{s(l)},$$

где L_l – редуцированный набор телеметрии объема $n-l$, полученный удалением элемента $x^{(l-l)}$ выборки $L_{(l-l)}$, что дает значение $R_{(l-l)}$; $\bar{x}(L_l)$ – выборочное среднее набора телеметрической информации L_l ; $s(L_l)$ – выборочное стандартное отклонение набора телеметрической информации L_l .

4. Определяется критическое значение:

$$p = (1 - \alpha/2)^{1/(n-l)},$$

$$\lambda_l = \frac{(n-l-1)t_{p, \mu-l-1}}{\sqrt{(n-l-2+t_{p, \mu-l-2}^2)(n-1)}},$$

где λ_l – критическое значение, p – процентиль уровня 100, $t_{p, \mu}$ – распределения с μ -степенями свободы.

Ввиду того, что аномальные значения могут быть только среди верхних или нижних экстремальных значений, α заменяется на $\alpha/2$.

5. Инкрементируется $l=l+1$.

6. Шаги 2...4 повторяются, пока l не станет равным m .

7. При выполнении условия $R_l \leq \lambda_l$ для $l=0, 1, 2, \dots, m$ считается, что аномалии отсутствуют. Иначе n_{out} наиболее экстремальных наблюдений $x^{(1)}, x^{(2)}, \dots, x^{(n_{out}-1)}$ редуцированных выборок считают аномальными, при этом:

$$n_{out} = l + \max\{l: R_l > \lambda_l\}.$$

Использование процесса ОЭСО равноценно применению критериев Шовене, Граббса и Пирса, Диксона для определения выбросов случайных процессов в совокупности.

Обычно принимают малое значение допустимых аномальных значений $m (< 3\%)$ от общего количества полученной телеметрической информации. Если количество аномальных значений телеметрической информации превышает это значение, то причиной выбросов может являться нештатная работа бортовой аппаратуры или средств наземного комплекса управления [11 – 13].

После выполнения процедуры исключения выбросов следует провести обработку пропусков телеметрической информации. Так как функционирование бортовой аппаратуры космического аппарата описывается логнормальным законом распределения, то предлагается использовать метод с использованием 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 телеметрической информации x_i , распределенных по нормальному закону с параметрами μ и σ осуществляется следующим образом:

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

Используя полученное выражение, исходная телеметрическая информация приводится к равномерному распределению [15, 16].

После проведения процедуры обработки пропусков телеметрической информации следует процедура кодирования категориальных признаков в телеметрической информации.

Пусть некоторый признак x_i принимает q значений $\{a_1, a_2, a_3, \dots, a_q\}$. Тогда для каждого объекта X_i можно заменить признак x_i на q бинарных признаков следу-

ющим образом:

$$Z_i^{ak} = I[X_i^k = a_k],$$

где $k \in \{1, \dots, q\}$,

Z_i^{ak} – описания X_i^{ak} объекта, которые были перекодированы

$I[A]$ – факт A ,

$$\text{т.е.: } I[A] = \begin{cases} 1, & \text{если } A \text{ истинно} \\ 0, & \text{если } A \text{ ложно} \end{cases}.$$

Данный тип кодирования категориальных признаков в наборе телеметрической информации называется *dummy*-кодированием или *one-hot*-кодированием. Закодировав каждый категориальный признак исходной матрицы телеметрии таким образом, к полученным описаниям Z_1, \dots, Z_n можно применять обучение нейронной сети для работы с вещественными числами.

Представленная матрица телеметрии при кажущейся простоте имеет несколько недостатков. Подобная перекодировка категориальных признаков накладывает ограничения на структуру признакового описания объектов, которую никак не учитывает нейронная сеть. Каждый старый признак перекодируется в несколько новых бинарных признаков ровно с одной единицей [16].

Учитывая то, что при анализе испытаний космической техники категориальных признаков x^i и значений q , которые может принимать эти признаки крайне мало (<10), использование данного кодирования является целесообразным.

Далее полученную матрицу векторов состояния бортовой аппаратуры необходимо нормализовать. Нормализация – это процесс предварительной обработки входной информации, при которой значения признаков в наборе телеметрии приводятся к определенному диапазону значений $[0...1]$ или $[-1...1]$.

Обязательность нормализации наборов телеметрии вызвана природой нейронных сетей [17]. Представленные данные в исходном наборе телеметрической информации отличаются не только по абсолютным значениям, но и по физическому смыслу. Отсутствие симметричного и унимодального распределения данных при обучении нейронных сетей может вызвать ухудшение качества разрабатываемой модели. После нормализации все значения параметров работы бортовой аппаратуры будут приведены к определенному диапазону значений, что позволит использовать их для более корректного обучения нейросети.

Для проведения нормализации необходимо знать экстремумы значений параметров бортовой аппаратуры, они и будут являться границами диапазонов нормализации значений [18, 19].

1. При нормализации и денормализации в пределах $[0, 1]$:

$$x_{ci} = \frac{(x_{\min i} + x_{\max i})}{2},$$

$$y_{cj} = \frac{(y_{\min j} + y_{\max j})}{2},$$

$$\widetilde{x}_{ik} = \frac{1}{e^{-a(x_{ik} - x_{ci}) + 1}},$$

$$y_{jk} = y_{cj} - \frac{1}{a} * \ln\left(\frac{1}{\widetilde{y}_{jk}} - 1\right),$$

где x_{ci} и y_{cj} – центры нормализуемых интервалов изменения входной и выходной переменных.

2. При нормализации и денормализации в пределах $[-1, 1]$:

$$\widetilde{x}_{ik} = \frac{e^{a(x_{ik} - x_{ci})} - 1}{e^{a(x_{ik} - x_{ci})} + 1},$$

$$y_{jk} = y_{cj} - \frac{1}{a} * \ln\left(\frac{1 - \widetilde{y}_{jk}}{1 + \widetilde{y}_{jk}}\right).$$

Результаты исследования. Результатом применения данного метода является существенное улучшение (на 7%) коэффициента детерминации по сравнению с исходным набором телеметрической информации. На рисунке 2 показана зависимость значения коэффициента детерминации от количества итераций при обучении многослойного перцептрона.

Зависимость значения коэффициента детерминации от количества итераций на наборе телеметрии




Рисунок 2 – Зависимость значения коэффициента детерминации от количества итераций

Заключение. Применяя предложенный метод для обработки поступающей с борта космического аппарата телеметрической информации удалось улучшить коэффициент детерминации при обучении многослойного перцептрона прямого распространения. Полученные результаты могут быть использованы при разработке математической модели интеллектуальной системы анализа состояния космического аппарата. Данная интеллектуальная система может быть положена в основу разрабатываемого аппаратно-программного комплекса, который позволит в полной мере оптимизировать процесс анализа статистической информации на этапе проведения испытаний и применения космических систем (комплексов).

СПИСОК ЛИТЕРАТУРЫ:

1. Солдатов О.П., Семенов В.В. Применение нейронных сетей для задачи прогноза. Электронный научный журнал «Исследования в России». 2006 г. – 1270 с.
2. Я. Гудфэллоу, И. Бенджио, А. Курвилль. Глубокое обучение. пер. с англ. А.А. Оликина. – 2-е изд. испр. – М.: ДМК Пресс, 2018. – 652 с.: цв. ил.
3. ГОСТ Р ИСО 9000-2015. Системы менеджмента и качества.
4. Бахрушин В.Е. Методы оценивания характеристик нелинейных статистических связей // Системные технологии. – 2011. – №2(73). – С. 9-14.
5. Скиена С. Алгоритмы. Руководство по разработке,

ВНУ // - 2017. - С. 720.

6. Гуцин В.Н. Основы устройства космических аппаратов: Учебник для вузов. М.: Машиностроение, 2003. – 272 с.

7. Вьюгин В.В. Математические основы машинного обучения и прогнозирования. – МЦНМО, 2013. – 387 с.

8. Вентцель Д. А., Шапиро Я. М. Внешняя баллистика: учебник для Артиллерийской академии и вузов Наркомата вооружения / Вентцель Д. А., Шапиро Я. М.; Оборонгиз, 1939. Ч. 2. - 1939. - 251 с.

9. Боевое применение частей (подразделений) РКО. Системы вооружения РКО: этапы создания, современное состояние, перспективы развития. (По материалам открытой печати) : учеб. пособие для вузов / сост. Бордо Г. В. ; МГТУ им. Н. Э. Баумана. - 2-е изд., доп. - М. : SAVIN, 1999. - 142 с.

10. Зайдель А.Н. Элементарные оценки ошибок измерений. – Москва: Наука, 1965.

11. ГОСТ Р ИСО 16269-4-2017. Статистические методы. Статистическое представление данных. Часть 4. Выявление и обработка выбросов.

12. Александровская Л.Н. Математические основы риск-менеджмента технических систем. Т.1: Экспертные методы оценки в риск-менеджменте. Изд. АИР, - 2017. С. 238

13. Student. The probable error of a mean. // Biometrika. 1908. №6 (1). P.1-25

14. Королук В.С., Портенко Н.И., Скороход А.В., Турбин А.Ф. Справочник по теории вероятностей и математической статистике. – М.: Наука, 1985. – 640 с.

15. Bryc, Wlodzimerz. The Normal Distribution: Characterizations with Applications. – Springer-Verlag, 1995.

16. Орельсн Жерон Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем. Пер. с англ. - СПб.: ООО «Альфа-книга»: 2018. - 688 с.: ил. - Парал. тит. англ.

17. Х. Цзявэй, К. Мишлен, П.Цзянь. Преобразование и дискретизация данных. Data Mining: концепции и методы. Эльзевир. С. 111-118.

18. Дейт К. Дж. Введение в системы баз данных = Introduction to Database Systems. – 8-е изд. – М.: Вильямс, 2005. – 1328 с. – ISBN 5-8459-0788-8 (рус.) 0-321-19784-4 (англ.).

19. Кузнецов С. Д. Основы баз данных. – 2-е изд. – М.: Интернет-университет информационных технологий; БИНОМ. Лаборатория знаний, 2007. – 484 с. – ISBN 978-5-94774-736-2.

Статья поступила в редакцию 30.10.2020

Статья принята к публикации 11.12.2020