

АНАЛИЗ СТРУКТУРНОЙ НАДЕЖНОСТИ КОСМИЧЕСКИХ АППАРАТОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

STRUCTURAL RELIABILITY ANALYSIS OF SPACE VEHICLES USING NEURAL NETWORKS

**P. Pomortsev
D. Kireev
R. Lesnichenko
M. Lesnichenko**

Summary. Predicting the service life of spacecraft is an urgent problem due to the complexity of designs and inaccessibility. Before the launch of the mission, the spacecraft undergoes ground tests and effective training. However, many missions experience temporary or permanent failures resulting in failure. Although there is no perfect system that can prevent any failure, analysis of past failures shows that adequate testing, redundancy and flexibility are the keys to a reliable spacecraft failure recovery system. It was revealed that the causes of failures have a different physical nature, among which an important place is occupied by mechanical problems associated with the elasto-elastic properties of the materials of the supporting structures. To analyze the mechanical reliability of structural elements of space technology, it is proposed to use neural networks as a modern apparatus for analysis and modeling with a large amount of input data. Neural networks allow you to effectively analyze a large amount of data and obtain fairly accurate reliability estimates. The backpropagation neural network algorithm has been successfully used to obtain rough estimates of critical load factors and has shown significant reliability with respect to training set selection and network architecture in predicting failure probability.

Keywords: neural network, reliability, spacecraft, mechanical failure, error, modeling.

Поморцев Павел Михайлович

Канд. тех. наук, доцент
Институт подготовки кадров машиностроения
и приборостроения
г. Королев
kaf34@yandex.ru

Киреев Дмитрий Геннадьевич

Канд. тех. наук
Институт подготовки кадров машиностроения
и приборостроения
г. Королев
kaf34@yandex.ru

Лесниченко Роман Иванович

Канд. тех. наук
Институт подготовки кадров машиностроения
и приборостроения
г. Королев
kaf34@yandex.ru

Лесниченко Максим Романович

Московский государственный технический
университет имени Н.Э. Баумана
г. Москва
kaf34@yandex.ru

Аннотация. Прогнозирование срока службы космических аппаратов является актуальной проблемой из-за сложности конструкций и труднодоступности. Перед запуском миссии космический аппарат проходит наземные испытания и эффективную подготовку. Однако, многие миссии испытывают временные или постоянные неудачи, что приводит к провалу. Хотя не существует совершенной системы, которая могла бы предотвратить любой сбой, анализ неисправностей прошлых лет показывает, что адекватное тестирование, резервирование и гибкость являются ключом к надежной системе восстановления после сбоев космического аппарата. Выявлено, что причины отказов имеют различную физическую природу, среди которых важное место занимают механические проблемы, связанные с эластичными свойствами материалов несущих конструкций. Для анализа механической надежности элементов конструкций космической техники предложено использовать нейросети, как современный аппарат анализа и моделирования с большим количеством входных данных. Нейросети позволяют эффективно анализировать большой объем данных и получать достаточно точные оценки надежности. Алгоритм нейронной сети обратного распространения был успешно использован для получения приблизительных оценок факторов критической нагрузки и показал значительную надежность в отношении выбора обучающего набора и сетевой архитектуры при прогнозировании вероятности отказа.

Ключевые слова: нейросеть, надежность, космический аппарат, механический отказ, погрешность, моделирование.

Введение

Теория и методы обеспечения надежности конструкций значительно развились за последние годы и были задокументированы в большом числе публикаций [1, 2]. Эти достижения в теории надежности конструкций и достижение более точной количественной оценки неопределенностей, связанных со структурными нагрузками и сопротивлениями, стимулировали интерес к вероятностной обработке конструкций. Надежность конструкции или вероятность ее отказа является важным фактором в процедура проектирования, поскольку она исследует вероятность того, что конструкция успешно выполнит свои проектные требования. Анализ надежности приводит к мерам безопасности, которые инженер-проектировщик должен принимать во внимание из-за вышеупомянутых неопределенностей.

В связи с рядом отказов и существенных неисправностей, отмеченных на ряде современных космических аппаратов (КА), аналитики считают, что нерешенные проблемы надежности являются реальным фактором, влияющим на развитие спутниковой отрасли [3]. На рис. 1 приведён анализ количества отказов для отечественной и зарубежной техники, а также сравнение гарантийного и фактического сроков службы космических станций.

Подробный анализ причин отказов в модулях, запущенных КА приведен в работах [4–6]. Распределение отказов в зависимости от физической природы показано на рис. 2.

Из рис. 2 видно, что механические отказы занимают второе место по частоте после электрических. В данной работе авторами предлагается исследовать надежность конструкций КА с использованием нейронных сетей, позволяющих провести интеллектуальную обработку данных.

Методы

Методы надежности первого и второго порядка, разработанные для оценки надежности конструкции [7] приводят к формулировкам, требующим предварительного знания только средних значений и дисперсий составляющих случайных величин и определения дифференцируемой функции отказа. Для мелкомасштабных задач такого рода методы оказываются очень эффективными, но для крупномасштабных задач и / или большого количества случайных величин методы моделирования методом Монте-Карло имеют преимущество.


Использование методов искусственного интеллекта, таких как нейронные сети (НС) были изучены ранее

в контексте оптимального проектирования структурных систем [8]. Основное преимущество правильно обученной НС заключается в том, что для получения приемлемого приближенного решения требуются тривиальные вычислительные усилия. Такие приближения полезны в ситуациях, когда фактические вычисления отклика требуют больших затрат ЦП и требуется быстрая оценка. Структурные нагрузки и свойства материала могут рассматриваться как зависящие от времени или независимые, в то время как область отказа может рассматриваться как временной вариант или инвариант. В настоящем исследовании проводится инвариантный по времени анализ структурной надежности в сочетании с НС. Сначала НС обучается, используя доступную информацию, полученную в результате выбранных эластопластических анализов [9, 10]. Данные анализа предельного состояния были обработаны для получения входных и выходных пар, которые использовались для создания обученной НС, которая затем используется для прогнозирования критического коэффициента нагрузки из-за различных наборов базовых случайных величин. После прогнозирования критических коэффициентов нагрузки вероятность отказа рассчитывается с помощью метода Монте Карло.


Базовая модель обрабатываемого элемента показана на рис. 3. Нейронная сеть состоит из нескольких элементов обработки, связанных вместе. В алгоритме обратного распространения (ОР) обучение выполняется, когда набор входных обучающих шаблонов распространяется по сети, состоящей из входного слоя, одного или более скрытых слоев и выходного слоя, как показано на рис. 4. Каждый слой имеет соответствующие блоки (элементы обработки, нейроны или узлы) и весовые связи. Единый шаблон обучения — это вектор строк ввода-вывода значений ввода-вывода во всей матрице обучающего набора ввода-вывода. Входные сигналы x_i , $i = 1, 2, \dots, n$, принимаются входным слоем; в модели входные сигналы умножаются на веса соединений $w_{p, ij}$.

В исследуемом случае основная цель состоит в том, чтобы исследовать способность НС прогнозировать нагрузку на разрушение с помощью алгоритма обратного распространения. Эта цель включает в себя следующие задачи: 1) выбрать надлежащий обучающий набор; 2) найти подходящую сетевую архитектуру; 3) определить соответствующие значения характерных параметров, таких как скорость обучения и импульсная характеристика.


Выходные данные сигмоидной функции, используемой в обычном алгоритме, находятся в диапазоне от 0 до 1. Таким образом, для того, чтобы получить значимые результаты, выходные значения шаблонов обуче-



а



б



в

Рис. 1. а) отказы зарубежных космических аппаратов; б) гарантийный и фактический сроки активного существования (САС) отечественных КА; в) сравнение гарантийного САС и до закрытия станции.

Источник: скомпилировано авторами



Рис. 2. Типы причин отказов КА. Источник: скомпилировано авторами.

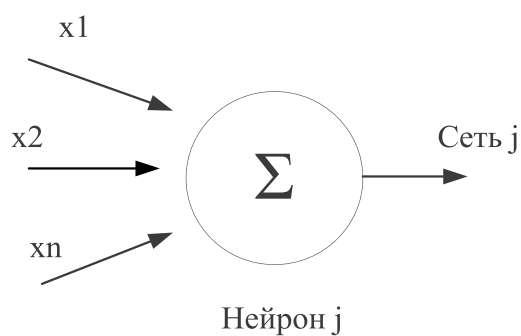


Рис. 3. Базовая модель обрабатывающего элемента

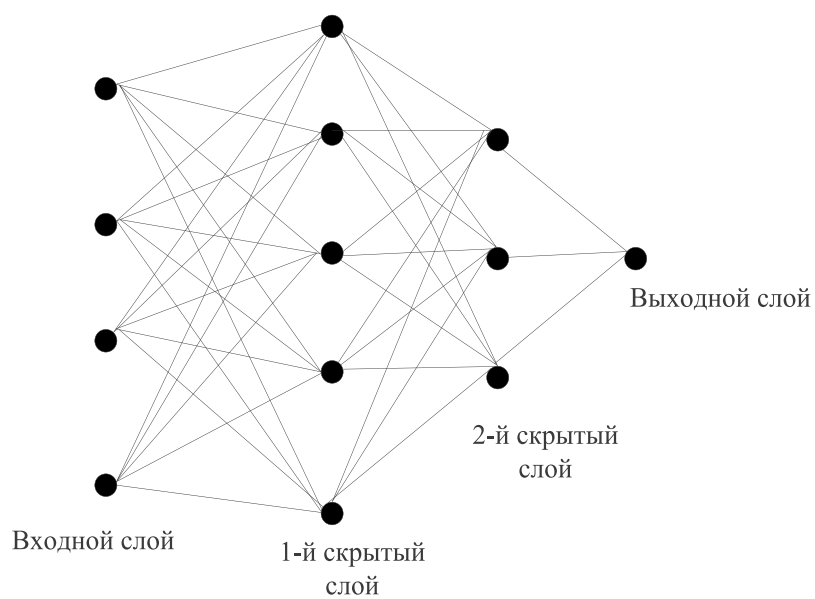


Рис. 4. Конфигурация НС

ния должны быть нормализованы в том же диапазоне. По мере обучения сети веса могут быть скорректированы до очень больших значений. Это может заставить все или большинство нейронов работать при больших выходных значениях в области, где производная функции активации очень мала. Поскольку коррекция весов зависит от производной сигмоидной функции, сеть может фактически остановиться. Инициализация весов небольшими случайными значениями помогла бы избежать этой ситуации, однако более целесообразно нормализовать входные шаблоны, чтобы они также были между 0 и 1.

Обычно существует два типа сетей, а именно полностью подключенные сети и сети с шаблоном подключения [11–13]. В полностью подключенной сети, как показано на рис. 4, каждое устройство в слое подключено ко всем устройствам предыдущего и следующего уровней. Этот тип сетевой архитектуры широко используется. Альтернативно, может быть создана некоторая локальная ассоциативность между блоками или количество соединений может быть уменьшено, создавая шаблонно связанную сеть. Количество нейронов, которые будут использоваться в скрытых слоях, неизвестно заранее и обычно оценивается методом проб и ошибок. На первом этапе обучения удобно постепенно увеличивать количество скрытых слоев, а затем, после достижения желаемой сходимости, попытаться удалить некоторые из них, чтобы найти минимальный размер сети, который выполняет желаемую задачу.

В этой работе используется полностью подключенная сеть. Количество выполняемых обычных вычислений пошагового анализа пределов находится в диапазоне от 20 до 60, в то время как от 10 до 20 из них выбираются для получения пар (входы-выходы) для обучения НС. Этот выбор основан на требовании, чтобы в процедуре обучения был представлен весь спектр возможных результатов. Центральные точки внутри интервалов используются в качестве входных данных для анализа предельного состояния.

Базовая конфигурация NN, используемая в этом исследовании, выбрана так, чтобы иметь один скрытый слой. Тесты, проведенные для более чем одного скрытого слоя, не показали существенного улучшения полученных результатов. На основе этой конфигурации тестируются различные архитектуры НС, чтобы найти наиболее подходящую в условия наименьшей ошибки прогнозирования. Это делается либо путем прямого сравнения прогнозируемых с «точными» результатами, полученными с помощью предельного упруго-пластического анализа, либо с помощью среднеквадратичной ошибки, которая задается как

$$e_{\text{ср.кв.}} = \sqrt{\frac{1}{N_p N_{\text{вых}}} \sum_{N_p} \sum_{i=1}^{N_{\text{вых}}} (t_i - r_i)^2},$$

где N_p — общее количество пар ввода-вывода в обучающем наборе, а $N_{\text{вых}}$ — количество выходных единиц; t_i и r_i — целевой и наблюдаемый выходы для узла i выходного слоя.

Среднеквадратичная ошибка дает меру разницы между прогнозируемыми значениями в каждом цикле НС и «точными» значениями. случайных величин. Затем результаты обрабатываются с помощью метода Монте Карло для вычисления вероятности отказа.

Результаты

При анализе надежности упругопластических конструкций с использованием метода Монте Карло вычисленные коэффициенты критической нагрузки сравниваются с соответствующей внешней нагрузкой, что приводит к вычислению вероятности разрушения конструкции. Путем аппроксимации «точного» решения с помощью нейросетевого моделирования.

Рассмотрим несущую конструкцию. Пусть единичная нагрузка прикладывается к верхней части. Предел текучести считается случайной величиной с заданной функцией плотности вероятности. Когда внешняя нагрузка меньше критического коэффициента нагрузки, $Z(X)$, от Eq. (5) принимает значение 1, в противном случае оно становится 0. Тип функций плотности вероятности (PDF), средние значения (μ) и стандартные отклонения (σ) для всех переменных представлены в таблице 1. Предполагается нормальное распределение для функции выборки важности $g(x)$ нагрузки. Предполагается, что среднее значение $g(x)$ соответствует нагрузке на отказ, когда все остальные случайные величины сохраняются на уровне их средних значений. То свойства функций плотности вероятности IS показаны в таблице 2 для всех тестовых случаев.

В первом тестовом примере ($i=1, j=7, k=1$, где i — количество входных нейронов, j — количество выходных нейронов, k — количество слоев) были использованы двадцать значений предела текучести в качестве входных переменных для предельного упругопластического анализа. Десять из них были выбраны вместе с соответствующими им «точными» коэффициентами критической нагрузки, полученными в результате предельного упругопластического анализа в качестве обучающего набора. Остальные «точные» пары используются для проверки точности НС предсказания. Для тестовых случаев 2 ($i=2, j=6, k=1$) и 3 ($i=3, j=7, k=1$) применяется аналогичная процедура. В этих случаях было обработано 30 и 60 комбинаций 2 и 3 основных




Рис. 5. Зависимость вероятности отказа от числа симуляций для трех типов НС

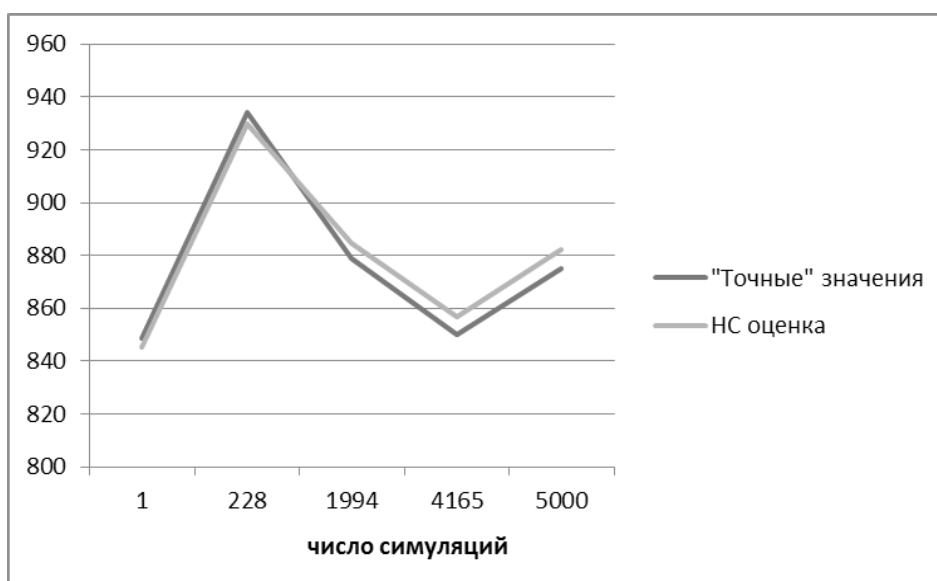


Рис. 6. Зависимость коэффициента критической нагрузки от числа симуляций.

случайных величин, в то время как 13 и 19 из них были окончательно отобраны вместе с соответствующими им коэффициентами критической нагрузки для целей обучения, соответственно. Результаты для различного количества симуляций представлены на рис. 5.

Из рис. 5 можно отметить, что в случае базового моделирования максимальная разница прогнозируемой вероятности отказа по отношению к «точной» составляет 30%. На рис. 6 показано сравнение между «точ-

ными» и прогнозируемыми значениями коэффициента критической нагрузки для пяти случайно выбранных симуляций.

Результаты показывают, что максимальная погрешность составляет всего 1,5%. Это связано с тем, что вероятность отказа демонстрирует высокую чувствительность по отношению к слегка измененному (из-за нейросетевого приближения) пространству выборок упругих сопротивлений.

Заключение

В данной статье представлено применение нейронных сетей для анализа надежности сложных структурных систем КА, в которых отказ системы происходит из-за пластического коллапса. Приблизительные концепции, присущие анализу надежности, и трудоемкие требования к повторным анализам, связанным с моделированием методом Монте-Карло, побудили к использованию нейронных сетей.

Использование нейронных сетей позволяет практически устранить любые ограничения на масштаб проблемы и размер выборки, используемой для моделирования методом Монте-Карло, при условии, что прогнозируемые критические коэффициенты нагрузки, соответствующие различным моделям, находятся в пределах допустимых допусков.

Алгоритм нейронной сети обратного распространения успешно используется для получения приблизительных оценок факторов критической нагрузки, независимо от размера или сложности проблемы, что приводит к очень близким предсказаниям вероятности отказа. Более того, для больших и сложных структурных систем, которые выдерживают большую часть нагрузки, выходящей за пределы их упругого состояния, нейросетевой прогноз представляется более точным. Также был сделан вывод, что, настоящее приложение показало значительную надежность в отношении выбора обучающего набора и сетевой архитектуры при прогнозировании вероятности отказа.

Таким образом, представленная методология может быть реализована для точного прогнозирования вероятности отказа больших и сложных конструкций КА за малую долю вычислительного времени.

ЛИТЕРАТУРА

1. Комков М.А. и др. Технология производства и диагностика качества композитных конструкций ракетно-космической техники. Обеспечение качества производства композитных конструкций. — 2021.
2. Гребенюк Л.С. и др. Обеспечение надежности ракетных двигателей малой тяги и их элементной базы для двигательных установок космических аппаратов длительного функционирования //Двойные технологии. — 2005. — № 3. — С. 58–61.
3. Патраев Валерий Елисеевич, Трифанов Иван Васильевич Анализ показателей качества и надежности при эксплуатации современных космических аппаратов // Сибирский аэрокосмический журнал. 2010. № 2.
4. Tafazoli M. A study of on-orbit spacecraft failures //Acta Astronautica. — 2009. — Т. 64. — № 2–3. — С. 195–205. DOI: 10.1016/j.actaastro.2008.07.019
5. Wright M.C., Long V.L., McDanel S.J. The evolution of failure analysis at NASA's Kennedy Space Center and lessons learned //Handbook of Materials Failure Analysis with Case Studies from the Aerospace and Automotive Industries. — Butterworth-Heinemann, 2016. — С. 57–73.
6. Biswal M.M., Annavarapu R.N. A Study on Mars Probe Failures //AIAA Scitech 2021 Forum. — 2021. — С. 1158.
7. Лабинский А.Ю. К вопросу использования нечеткой логики для расчета надежности элементов систем //Природные и техногенные риски (физико-математические и прикладные аспекты). — 2016. — № 4. — С. 5–11.
8. Миронов Д.Н., Гончаренко В.П. Обучение нейронной сети сложной механической системы для определения вероятности ее безотказной работы. — 2020.
9. Кахраманов Н.Т. и др. Влияние технологических параметров литья под давлением на физико-механические свойства динамических эластопластов на основе полиолефинов и бутадиен-нитрильного каучука //Kimya Problemleri. — 2018. — № 3. — С. 420–428.
10. Кахраманов Н.Т., Гулиев А.Д., Аллахвердиева Х.В. Состояние проблемы получения и исследования структуры и свойств нанокompозитов на основе полиолефинов и минеральных наполнителей //Пластические массы. — 2022. — Т. 1. — № 11–12. — С. 46–52.
11. Zhang Y. et al. On the learnability of fully-connected neural networks //Artificial Intelligence and Statistics. — PMLR, 2017. — С. 83–91.
12. Ganju K. et al. Property inference attacks on fully connected neural networks using permutation invariant representations //Proceedings of the 2018 ACM SIGSAC conference on computer and communications security. — 2018. — С. 619–633.
13. Lu Z., Liu D. A new synthesis procedure for a class of cellular neural networks with space-invariant cloning template //IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing. — 1998. — Т. 45. — № 12. — С. 1601–1605.

© Поморцев Павел Михайлович (kaf34@yandex.ru), Киреев Дмитрий Геннадьевич (kaf34@yandex.ru),

Лесниченко Роман Иванович (kaf34@yandex.ru), Лесниченко Максим Романович (kaf34@yandex.ru).

Журнал «Современная наука: актуальные проблемы теории и практики»