

НЕЙРОСЕТЕВАЯ СИСТЕМА МОНИТОРИНГА СОСТОЯНИЯ И ПОВЕДЕНИЯ ПОДСИСТЕМ КОСМИЧЕСКИХ АППАРАТОВ ПО ТЕЛЕМЕТРИЧЕСКИМ ДАННЫМ ДЛЯ НАЗЕМНОГО КОМАНДНО-ИЗМЕРИТЕЛЬНОГО КОМПЛЕКСА

А.А. Дудкин¹, В.В. Ганченко¹, Е.Е. Марушко¹, А.В. Инютин¹, А.А. Воронов¹,
С.А. Золотой², С.Н. Чарин²

¹Объединенный институт проблем информатики НАН Беларуси, Минск;

²УП «Геоинформационные системы», Минск, Беларусь

Описывается нейросетевая система мониторинга состояния подсистем космических аппаратов по телеметрическим данным для наземного командно-измерительного комплекса. Данная система обеспечивает контроль и прогнозирование состояния и работоспособности ряда подсистем белорусского космического аппарата на основе анализа спутниковой телеметрической информации. Подробно рассматривается реализованный в системе метод долгосрочного прогнозирования на основе ансамблей нейронных сетей.

Введение

Космическая телеметрия – это совокупность технологий, позволяющая производить дистанционный (удаленный) сбор информации о состоянии бортовых одсистем космических аппаратов (КА). Описание подсистем КА включает в себя список компонентов, их функции и связи, допустимые входные и выходные значения. Известны четыре метода мониторинга состояния подсистем КА по телеметрическим данным: адаптивный анализ ограничений с использованием относительной векторной регрессии, обнаружение аномалий в телеметрии с использованием метода главных компонентов, диагностика и определение аномалий с использованием динамических байесовых сетей (гибридный метод), визуализация телеметрии на основе обнаружения точек перехода.

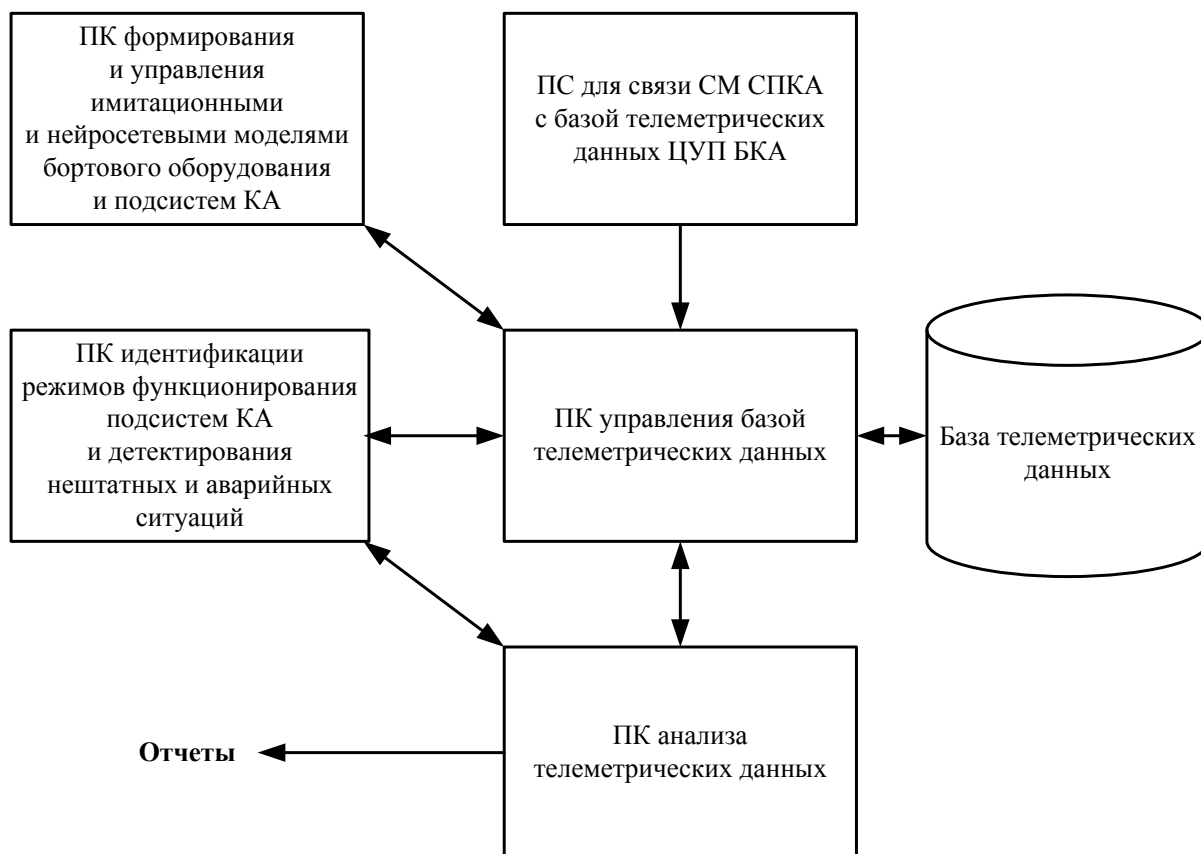
Надо отметить, что детерминированные алгоритмы не обеспечивают надежной идентификации нештатных режимов элементов и подсистем КА вследствие утраты той информации, которая содержится в нестационарных и флуктуационных составляющих диагностических сигналов. Использование нейронных сетей позволяет повысить достоверность принятия решений [1, 2].

1. Архитектура системы мониторинга состояния подсистем космических аппаратов по телеметрическим данным

Схема функционирования системы мониторинга состояния подсистем космических аппаратов (СМ СПКА) приведена на рисунке.

Функционирование СМ СПКА в общем виде можно представить следующей последовательностью шагов:

Шаг 1. Выгрузка данных из базы телеметрической информации центра управления полетом белорусского космического аппарата (ЦУП БКА) в базу системы посредством программных средств (ПС) для связи СМ СПКА с базой телеметрических данных ЦУП БКА и программного комплекса (ПК) управления базой телеметрических данных.



Функциональная структура СМ СПКА

Шаг 2. Формирование нейронных сетей идентификации режимов функционирования и детектирования нештатных и аварийных ситуаций посредством ПК анализа телеметрических данных.

Шаг 3. Формирование имитационных моделей и моделирование показаний датчиков в ПК формирования и управления имитационными моделями бортового оборудования и подсистем КА.

Шаг 4. Решение требуемой задачи контроля состояния подсистем КА (идентификации, детектирования и др.) на основе анализа моделированных и реальных данных из базы телеметрических данных с использованием ПК анализа телеметрических данных, функционирующего во взаимодействии с ПК идентификации режимов функционирования подсистем КА и детектирования нештатных и аварийных ситуаций.

Шаг 5. Построение ансамбля нейронных сетей (АНС) для краткосрочного и долгосрочного прогнозирования состояния подсистем КА. Решение требуемой задачи с использованием ПК прогнозирования.

Шаг 6. Дообучение нейронных сетей АНС, уточнение имитационных моделей.

Результатом СМ СПКА являются отчеты в формате, удобном для дальнейшего использования специалистом ЦУП БКА.

Функционирование структурных компонентов СМ СПКА осуществляется на базе единого вычислительного ядра, представляющего собой набор программных модулей, обеспечивающих реконфигурируемость процесса решения той или иной задачи. При этом конфигурация выполняемого процесса представляется в виде направленного графа, в узлах которого находятся вычислительные блоки, предназначенные для решения

конкретных узких задач (например, преобразования данных из одного формата в другой, ресемплирования по времени, отправки данных в БД и т. п.). Дуги такого графа показывают направление передачи данных.

2. Прогнозирование телеметрических параметров подсистем КА

Задача прогнозирования параметров подсистем КА является важной частью мониторинга. В СМ СПКА она решается с использованием ансамблей нейронных сетей. Далее в качестве примера приводится решение задачи прогнозирования для параметров системы электроснабжения (СЭС).

В состав СЭС входят модуль регулирования и распределения мощности, батарея солнечная и литий-ионная аккумуляторная батарея (АБ).

Батарея солнечная со временем деградирует под действием следующих факторов: метеорной эрозией, уменьшающей оптические свойства поверхности фотоэлектрических преобразователей; радиационного излучения, особенно при солнечных вспышках и при полете в радиационном поясе Земли; термических ударов из-за охлаждения конструкции на затененных участках орбиты и нагрева на освещенных (и наоборот). Литий-ионные АБ стареют с момента их производства. Происходит это из-за деградации силовых модулей в аккумуляторе под воздействием химических процессов и постоянных циклов перезарядки. Скорость деградации зависит не только от внешних факторов, но и от режимов эксплуатации. Таким образом, время эффективной работы СЭС ограничено и прогноз состояния позволяет проводить мониторинг и увеличивать ресурс системы.

Состояние СЭС описывается набором телеметрических данных: токами заряда и разряда батарей, напряжением батарей, напряжением шины питания и электрическими параметрами различных компонентов системы. Данный набор представляет собой многомерный временной ряд, а прогнозирование состояний СЭС сводится к решению задачи прогнозирования всего многомерного ряда или отдельных рядов. Задача в общем виде формулируется следующим образом [3, 4]: по известному текущему значению последовательности $y(k)$ и некоторой предыстории $y(k-1), y(k-2), \dots, y(k-m)$ дать оценку следующего значения $\hat{y}(k+1)$. Каждый элемент последовательности $y(k)$ представляет собой набор значений в момент k . Длина предыстории m , которая используется для прогнозирования, называется временным окном. При этом для задачи обучения с учителем формирование пар обучающих примеров «входной вектор, желаемый выходной вектор» осуществляется по принципу скользящего окна [4], т. е. берется отрезок временного ряда (окно) длиной m и из него формируется входной вектор. Значением желаемого выхода в обучающем примере будет следующее по порядку наблюдение. Затем окно сдвигается на одну позицию в направлении возрастания времени и процесс формирования следующей пары обучающей выборки повторяется.

Широкое распространение для решения задач прогнозирования находит нейросетевой подход, так как он позволяет моделировать зависимости между данными в результате обучения на примерах. При этом эффективность использования нейронных сетей зависит от архитектурных решений и методов обучения [3, 5].

В данной работе представлена нейросетевая модель на основе АНС для дольвременного прогнозирования телеметрических параметров СЭС. АНС – это набор нейронных сетей, принимающий решения путем оценки результатов работы отдельных нейронных сетей.

В предлагаемой модели выходное значение АНС формируется как взвешенная сумма выходов отдельных нейронных сетей. В качестве базового элемента АНС ис-

пользуется многослойный персептрон с одним скрытым слоем с нелинейной функцией активации «гиперболический тангенс». Размер скрытого слоя определяется поиском на интервале с использованием восьмикратной перекрестной проверки. Обучение одиночной нейронной сети осуществляется алгоритмом RPROP [6]. АНС включает 20 базовых элементов.

Для реализации долгосрочного прогнозирования в вычисляются интервальные оценочные параметры ТМИ каждого датчика. Были определены следующие параметры: минимальное значение на интервале; максимальное значение на интервале; среднее значение на интервале. Интервал вычисления параметра – 24 ч. Окно прогнозирования выбрано равным 90 отсчетам. Выполнялся прогноз значений параметров, которые могут быть получены через 30 дней.

Эксперимент показал, что наименьшая среднеквадратическая ошибка среднего значения параметров на интервале при прогнозировании ТМИ, формируемой датчиками СЭС, для напряжения АБ составляет 0,01, для напряжения шины питания – 0,008, для тока заряда АБ – 0,02.

Заключение

Разработана схема управления режимами и моделями СМ СПКА. Определены эффективные алгоритмы построения АНС для прогнозирования и идентификации нештатных ситуаций подсистем КА. Предложен метод долгосрочного прогнозирования телеметрической информации на основе взвешенного АНС, который показал низкую среднеквадратическую ошибку для параметров СЭС.

На текущий момент разработан экспериментальный образец который прошел опытную эксплуатацию и внедрен в ЦУП БКА. Планируется разработка рабочего образца системы с учетом апробирования системы мониторинга в ЦУП БКА на выборке большого размера.

Список литературы

1. Обзор стандартов и концепция построения средств мониторинга, контроля и диагностики космического аппарата / В.М. Хачумов [и др.] // Программные системы: теория и приложения. – 2015. – № 3(26). – С. 21–43.
2. Нейросетевая система контроля датчиков углов ориентации и дальности космического аппарата / Ю.Г. Емельянова [и др.] // Программные системы: теория и приложения. – 2010. – № 1(1). – С. 45–59.
3. Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals / Hao Quan [et al.] // IEEE Transactions on Neural Networks and Learning Systems. – Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals. – 2013. – Vol. 25, iss. 2. – P. 303–315.
4. Лысяк, А.С. Прогнозирование многомерных временных рядов / А.С. Лысяк, Б.Я. Рябко // Вестник СибГУТИ. – 2014. – № 4. – С. 75–88.
5. Comparison of the ARMA, ARIMA, and the autoregressive artificial neural network models in forecasting the monthly inflow of Dez dam reservoir / M. Valipour [et al.] // J. of Hydrology 476(2013). – P. 433–441.
6. Riedmiller, M. A direct adaptive method for faster backpropagation learning: The RPROP algorithm / M. Riedmiller, H. Braun // In Proc. of the IEEE Intern. Conf. on Neural Networks (ICNN). – San Francisco, 1993. – P. 586–591.