

Интеллектуальный анализ телеметрической информации для диагностики оборудования космического аппарата

Н.С. Абрамов, А.А. Талалаев, В.П. Фраленко

Аннотация. В работе предложены методы интеллектуального анализа телеметрической информации космического аппарата, решающие задачи прогнозирования и диагностики его подсистем. Для предобработки телеметрической информации используются нейронные сети различных конфигураций и модификация ZET-алгоритма. Описаны результаты кластеризации телеметрической информации нейронной сетью Кохонена. Показано, что разработанные методы способны решать задачи мониторинга и диагностики состояния подсистем космических аппаратов по телеметрическим данным.

Ключевые слова: космический аппарат, мониторинг, контроль, диагностика, прогнозирование, метод, нейронные сети, интеллектуальный анализ, система, телеметрические данные.

Введение

Одной из главных задач при построении ракетно-космической техники нового поколения является задача поддержки и продления жизненного цикла аппаратов, которая решается посредством создания автоматизированных систем мониторинга и прогнозирования состояния космических аппаратов (КА). Среди таких систем наиболее перспективными, на наш взгляд, являются системы, комплексно использующие интеллектуальные технологии [1-5]. Применение искусственных нейронных сетей (ИНС) и их комитетов хорошо зарекомендова-

ли себя при решении задач обработки телеметрии, мониторинга и диагностики сложных технических систем, поддержания работоспособности служебных и целевых систем, обработки информации и управления.

В работе рассматриваются методы [6-8], предназначенные для применения в разрабатываемой системе диагностики неисправностей. Описанные методы работают с потоком телеметрической информации (ТМИ), содержащем показания датчиков температуры, напряжения, силы тока, ориентации и др. данные соответствующих бортовых подсистем. Для предобработки и восстановления телеметрической

¹ Работа выполнена в рамках СЧ НИР шифр «Мониторинг-СГ-1.2.5.1» по Программе Союзного государства «Разработка космических и наземных средств обеспечения потребителей России и Беларуси информацией дистанционного зондирования Земли» и при частичной поддержке Российского фонда фундаментальных исследований (проект № 15-29-06945-офи_м «Развитие моделей, методов и программных средств обработки мультиспектральных снимков, видео-потоков и данных телеметрии для задач космического мониторинга арктической зоны»).

информации используются модификация ZET-алгоритма, часто используемого для работы с поврежденными массивами данных и аппарат ИНС: сеть прямого распространения, сеть векторного квантования и комплексированная нейронная сеть. Для диагностики состояния подсистем КА посредством анализа ТМИ используются ИНС прямого распространения и сеть Кохонена.

1. Предварительная обработка и восстановление телеметрической информации

В телеметрической информации, поступающей с борта КА, содержится множество поврежденных данных, эти проблемы могут быть вызваны как сбоями приемо-передающего оборудования, так и помехами при передаче. Для успешного решения задач контроля и диагностики поступающая телеметрическая информация должна пройти предварительную обработку. Далее рассмотрим предлагаемые алгоритмы восстановления данных на основе нейросетевого подхода и модифицированного ZET-алгоритма.

1.1. Нейросетевая предобработка входных данных

В потоках телеметрической информации, получаемой с борта КА, зачастую имеются пропуски значений показаний датчиков. В имеющихся доступных для анализа данных подобные значения закодированы с использованием специальных символов (Табл. 1).

Предлагаемый подход к восстановлению неизвестных или поврежденные значения основан на методах корреляционного анализа и аппарате искусственных нейронных сетей. Исходя из предположения, что неповрежденные данные в потоках телеметрии содержат корректные показания датчиков, можно выделить группы датчиков с сильной корреляционной связью. На основе известных прецедентов для датчиков подобной группы предлагается сформировать обучающую выборку и настроить нейронную сеть, функционирующую в режиме ассоциативной памяти.

Сеть прямого распространения (многослойный перцептрон) представляет собой полносвязную нейронную сеть. Типичная ИНС прямого

Табл. 1. Фрагмент файла телеметрии

14:04:03	14,2	0,26	0,19	0	--	0,08	--
14:03:03	--	0,45	0,19	0	0	0,06	0
14:02:03	14,0	0,45	0,19	0	0	0,06	0
13: -- :03	14,2	0,45	0,19	0	0	0,06	0
13:58: --	14,0	0,45	0,19	0	0	--	--
-- :57:03	--	0,45	0,19	0	0	--	0

распространения имеет входной слой, выходной слой и один или более скрытых слоев. Нейроны организованы в послонную структуру с прямой передачей сигнала, каждый нейрон сети пропускает взвешенную сумму своих входов через передаточную функцию и выдает выходное значение. Обучение подобных ИНС производится с использованием методов градиентного спуска, наиболее популярен метод обратного распространения ошибки и его модификации.

Предлагаемая комплексированная нейронная сеть на основе сети прямого распространения состоит из двух основных компонентов – описанной ранее сети прямого распространения и сети векторного квантования, связанных между собой таким образом, что выходы сети прямого распространения рассматриваются как входы сети векторного квантования.

Сеть векторного квантования (Learning Vector Quantization, LVQ) является одной из разновидностей слоя Кохонена [9]. Комплексированная ИНС обучается с учителем, также как и сеть прямого распространения. Процесс обучения можно разделить на два этапа: на первом этапе происходит обучение сети прямого распространения на основе заданной экспертом обучающей выборки, на втором этапе – формируется новая обучающая выборка. Обучение сети векторного квантования производится на основе выходных сигналов обученной сети прямого распространения.

Подготовка обучающей выборки для обучения сетей требует проведения предварительной обработки. В процессе подготовки можно выделить несколько основных этапов: выделение группы коррелирующих датчиков; выборка и нормализация данных; подготовка обучающей выборки для сети прямого распространения; подготовка обучающей выборки для сети векторного квантования.

Проводя анализ корреляций между показаниями известными датчиками малого космического аппарата (МКА) «Юбилейный» [10], было выявлено, что корреляции присутствуют между рядом температурных и рядом вольтамперных характеристик. Из всего множества датчиков выделены четыре группы:

- датчики "Sun,V" "Sun,A" "Sp3,A" "Sp2,A" "Sp1,A" "Bort,V";
- датчики "Plat1,C" "Plat2,C" "T8,C";
- датчики "Plat3,C" "Plat4,C" "DT1,C" "T1,C" "T2,C" "Tbck,C";
- датчики "Ux,V" "Uy,V" "Uz,V".

Для использования имеющихся данных в качестве обучающей выборки ИНС необходимо провести их нормализацию, отображая исходный диапазон значений каждого датчика $[X_{\min}, X_{\max}]$ в диапазон $[-1, 1]$, данная операция проводится для каждого из датчиков независимо (Табл. 2).

Исходная обучающая выборка строится на основе имеющейся базы прецедентов, выбираются все кортежи значений (показания датчиков, входящих в заданную группу и полученные в один момент времени). Данное множество расширяется множеством кортежей, содержащих шум. Для этого в обучающую выборку включаются кортежи, в которых показания отдельных датчиков закодированы как неизвестные значения (неизвестное значение для каждого датчика кодируется как $(X_{\max} - X_{\min}) / 2$, что соответствует нулю в нормализованном виде). Расширенная обучающая выборка (Табл. 3) используется для обучения сети прямого распространения.

Обучающая выборка для сети векторного квантования формируется автоматически – на основе выходных значений обученной сети прямого распространения, а исходная обучающая выборка в данном случае определяет коли-

Табл. 2. Нормализация показаний датчиков

	Исходные значения			Нормализованные значения		
	X	Y	Z	X'	Y'	Z'
	0,19	0	0	-1	-1	-1
	15,65	4,0	0,74	1	1	1
	15,65	2,96	0,27	1	0,48	-0,27
Min	0,19	0	0	-1	-1	-1
Max	15,65	4	0,74	1	1	1

Табл. 3. Расширение обучающей выборки

Исходная выборка (нормализованная)			Расширенная выборка (нормализованная)			Класс
X'	Y'	Z'	X'	Y'	Z'	
-1	-1	-1	-1	-1	-1	1
			0	-1	-1	
			-1	0	-1	
			-1	-1	0	
1	1	1	1	1	1	2
			0	1	1	
			1	0	1	
			1	1	0	
1	0,48	-0,27	1	0,48	-0,27	3
			0	0,48	-0,27	
			1	0	-0,27	
			1	0,48	0	

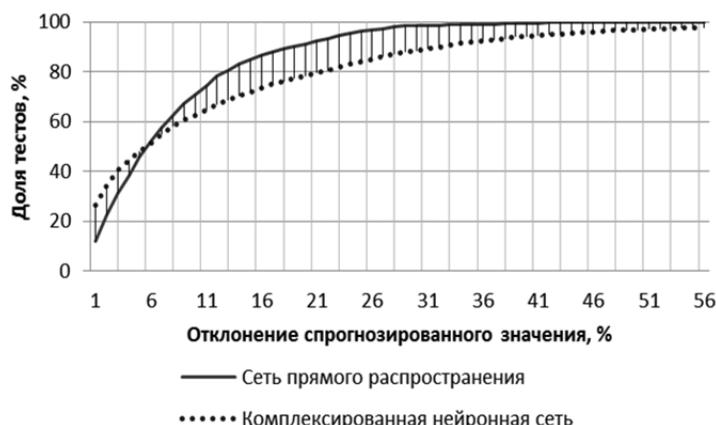


Рис. 1. Точность восстановления поврежденных данных (график с накоплением)

чество и задает стартовые веса нейронов, подлежащих настройке в процессе обучения сети.

Для обработки данных телеметрии используется сеть прямого распространения, имеющая один скрытый слой. Общая архитектура сети имеет следующий вид: входной слой — пять нейронов (задается количеством выбранных датчиков), скрытый слой — 500 нейронов, выходной слой — пять нейронов. Обучение ИНС проводится на основе расширенной обучающей выборки, построенной на основе показаний пяти датчиков. Сеть обучается с использованием алгоритма RPROP [11]. При этом используется подход, характерный для нейронных сетей, реализующих модель ассоциативной памяти (несмотря на то, что данная сеть не имеет обратных связей) — в качестве выходных сигналов ИНС требуется получить восстановленный вектор значений, характерный для заданного класса. В качестве активационных функций для каждого из нейронов ИНС выбран гиперболический тангенс.

Затем сеть прямого распространения была дополнена слоем сети векторного квантования. Количество нейронов в сети векторного квантования соответствует числу классов, определенных в исходной обучающей выборке, формирование обучающей выборки для сети векторного квантования происходит автоматически.

Для тестирования возможностей ИНС предложен следующий алгоритм:

- выбираем случайный вектор из исходной обучающей выборки;
- выбираем случайную позицию в векторе значений;

- определяем данную позицию как неизвестное значений, обнуляя ее;

- передаем модифицированный вектор на вход ИНС, восстанавливая неизвестное значение;
- оцениваем отклонение восстановленного значения от значения, представленного в векторе (выбранном на шаге 1).

Тестирование проводилось на показаниях группы из пяти датчиков: “Sun,V”, “Sun,A”, “Sp1,A”, “Sp2,A” и “Sp3,A”. Проведено пять независимых тестов, в каждом из которых проводилось обучение ИНС и тестировалась тысяча векторов с внесенными ошибками. Результаты тестирования представлены на Рис. 1.

Далее представлен алгоритм восстановления поврежденных данных телеметрии с МКА «Юбилейный». Можно выделить следующие основные этапы обработки:

- чтение оригинального файла телеметрии и подготовка к работе;
- восстановление части поврежденных данных с помощью оригинального метода на основе модифицированного ZET-алгоритма [12];
- восстановление ранее не обработанных повреждений с помощью специального интерполяционного алгоритма.

Исходные данные телеметрии сохранены в виде текстовых файлов с расширением “TMN”. Каждая отдельная запись представляется новой строкой, в которой через пробельные отступы записаны параметры, которые можно разделить на следующие основные группы:

- параметры бортовой электросети;
- температурные параметры оборудования;

- режимы работы оборудования (вкл./выкл., ориентация);

- командно-управляющая информация;
- отсчеты времени.

Предлагаемая модификация ZET-алгоритма отличается следующими особенностями:

- матрица компетентности формируется с использованием целых строк, отдельные признаки по информативности и другим критериям не отбираются;

- задается минимальное число компетентных строк – как сверху, так и снизу (например, при ограничении в одну строку, и сверху, и снизу должно быть не менее одной компетентной строки); верхним строкам соответствуют более поздние записи, а нижним – ранние;

- задается максимальное число компетентных строк – как сверху, так и снизу (например, не более двух компетентных строк);

- задается максимальная зона поиска компетентных строк – как сверху, так и снизу (например, не более четырех строк);

- если нужного количества компетентных строк в окрестности восстанавливаемой точки не обнаруживается, то ее восстановление осуществляется позже – с помощью специального интерполяционного алгоритма;

- если временной интервал между самой ранней и самой поздней компетентными строками больше заданного числа (например, больше 600 секунд), то восстановление точки откладывается;

- выбранные компетентные строки оцениваются по среднеквадратичному отклонению позиции (-1, -2, -3... и 1, 2, 3... соответственно) от позиции строки, содержащей повреждение;

- коэффициент компетенции для каждой из строк компетенции вычисляется как произведение коэффициента корреляции (для этой строки и строки с повреждением) и количества пар признаков (таких, что оба элемента пары не повреждены), деленного на общее число признаков минус один; если сумма всех коэффициентов компетенций больше нуля, то работа алгоритма продолжается;

- по завершении обработки матрица с картой ошибок обновляется, осуществляется обновление и списка с координатами поврежденных ячеек.

Для восстановления поврежденных ячеек, оставшихся после применения первого алгоритма, предлагается воспользоваться алгоритмом на основе интерполяционных многочленов Лагранжа [13]. На первом шаге восстановим оставшиеся поврежденные временные метки. Сначала введем нижнее ограничение p на количество используемых точек восстановления (ячеек с неповрежденными данными в окрестности восстанавливаемой точки). Например, в качестве такого ограничения можно взять три точки. Эти точки выбираем так, чтобы количество точек сверху было не более чем на k больше количества точек снизу (и наоборот). Например, k может быть взято равным единице. Минимальное число точек сверху и снизу также задается.

Точки для восстановления запоминаем в отдельном списке, добавляя в него на одной итерации как верхнюю точку, так и нижнюю. В качестве координаты x добавляемых точек записываем их отклонение от восстанавливаемой (-1, -2, -3, ... и 1, 2, 3, ... соответственно). В качестве координаты y используем соответствующие временные метки. Для исключения появления нежелательных погрешностей счета находится точка с минимальным значением метки времени, новые значения координаты y устанавливаются как разница найденной временной метки и старого значения. Таким образом, для восстановления поврежденной временной метки остается лишь передать в вычисленный интерполяционный полином координату x восстанавливаемой точки, то есть передать ноль; затем к полученному числу прибавляется минимальная метка времени.

Если временной интервал между самой ранней и самой поздней метками времени больше заданного числа (например, больше 600 секунд), то восстановление точки откладывается. Следует отметить, что не все точки восстанавливаются по описанному алгоритму ввиду наличия ограничений. В том числе, это касается точек, близких к границе исходных данных. Оставшиеся временные метки восстанавливаются с помощью линейной интерполяции (с помощью двух ближайших неповрежденных точек, без ограничения на размер окрестности поиска, причем приоритет отдается той паре

точек, у которой первая точка расположена выше поврежденной, а вторая – ниже, то есть симметрично).

Имея все временные метки, можно использовать их значения в качестве координаты x при интерполяции значений от аппаратуры датчиков (временных рядов). Для исключения погрешностей счета применяется подход с вычитанием значения минимальной временной метки. В качестве координаты y – неповрежденные значения от датчиков. В остальном алгоритм интерполяции не отличается от описанного выше. Нижнее ограничение количества точек равно трем. После получения интерполяционного полинома подставляем в него модифицированную временную метку, соответствующую строке с повреждением. Часть точек, для которых восстановление не удалось, восстанавливаем как и раньше с помощью линейной интерполяции.

2. Прогнозирование сбоя аппаратуры датчиков нейронной сетью прямого распространения

Для прогнозирования возникновения сбоя аппаратуры датчиков предлагается использовать динамически переобучающуюся искусственную нейронную сеть прямого распространения. Нейронная сеть имеет w входов (размер скользящего окна) и p выходов (количество выходных нейронов соответствует возможности ИНС прогнозировать поведение аппаратуры на p шагов вперед). Количество скрытых слоев и нейронов в них задается настройками. Наилучшие результаты показали нейронные сети с числом слоев от четырех и выше.

Предлагаемый подход базируется на том, что исходные значения, получаемые от датчиков, заменяются сначала приращениями, а затем приращения подвергаются нормированию в диапазон от -1 до 1 , совместимый с активационной функцией нейронной сети. Пусть имеется допустимый диапазон показаний датчика, например, от s_{\min} до s_{\max} . Допустимым считается изменение текущего значения с s_{\max} на s_{\min} и наоборот.

В первом случае максимальное приращение $\Delta_{\max_positive} = (s_{\max} - s_{\min})$, тогда минимальное при-

ращение $\Delta_{\min_negative} = -\Delta_{\max_positive}$. Благодаря такой симметрии можно осуществлять нормирование, при котором допустимые приращения будут преобразовываться в требуемый ограниченный диапазон. В частности, предлагается кодировать левую границу ограниченного диапазона как $-0,5$, а правую границу – как $0,5$. Для приведения какого-либо допустимого приращения Δ_{old} (в абсолютных единицах) в необходимый ограниченный диапазон требуется воспользоваться обратимой формулой $\Delta_{new} = \frac{\Delta_{old}}{2 \cdot \Delta_{\max_positive}}$.

Программа прогнозирования использует этот способ нормирования следующим образом: если в текущий момент мы оказались за пределом зоны допустимых значений (то есть текущее приращение относительно центра зоны $d(t)$, к примеру, равно $-0,6$ (имеем выход за нижнюю границу зоны), то при прогнозе приращения $+0,4$ показатели вернутся в норму, так как результат $d(t+1) = -0,6 + 0,4 = -0,2$, а это значение попадает в допустимый диапазон (выше нижней границы $-0,5$).

Аналогичным образом кодируются не только входные сигналы нейросети, но и выходные (используются при обучении с учителем). Однако если на входы ИНС не накладываются архитектурные ограничения, то выходы должны быть в пределах, диктуемых используемой активационной функцией. Реализация программы основывается на нейронной сети с активационной функцией типа сигмоид, область значений которой находится в диапазоне от -1 до 1 . Если при потенциально нормальных значениях данных (нормальных лишь при определенной начальной позиции) приращение укладывается в диапазон от $-0,5$ до $0,5$, то при аномальном поведении сигнала с датчика нормирование описанным способом может привести к выходу из диапазона -1 до 1 , что недопустимо. Ввиду того, что реализация программы (выполнена на основе библиотеки OpenCV) оперирует с числами с одинарной точностью, рекомендуется переход к диапазону $-0,95 \dots 0,95$. Это гарантирует обход документированных проблем, связанных с накоплением ошибки вычислений в библиотечных функциях OpenCV. Все нормированные значения, не попавшие в этот диапа-

зон, приравняются к соответствующей границе. Например, нормированное приращение $-1,1$ приравняется к приращению $-0,95$, а нормированное приращение $1,2$ – к соответствующему приращению $0,95$.

После обучения ИНС в дальнейшем не требуется полного обучения нейросети на новых данных (извлеченных со следующих позиций сканирующего окна), лишь дообучение. Обучение/дообучение осуществляется на одном единственном векторе приращений скользящего окна и на соответствующем векторе приращений для выходного слоя нейронов. Прогнозирование выхода за границы зоны допустимых значений осуществляется двумя независимыми алгоритмами.

Первый алгоритм использует непосредственно прогноз нейросети (на p шагов вперед), на вход подается не тот вектор, на котором происходило дообучение, а сдвинутое на один шаг вперед окно нормированных приращений. Осуществляется оценка всего вектора прогноза (с использованием информации о текущем положении относительно зоны допустимых значений). Если итоговое приращение приводит к выходу за границу зоны допустимых значений, то осуществляется уведомление о потенциально опасной ситуации.

Во втором алгоритме используется механизм рекурсивного прогнозирования. Каждая итерация использует сдвинутое на один шаг окно вектора смещений, последний элемент которого заменен на только что полученное прогнозное значение (в первом алгоритме мы получили необходимый прогноз приращения (назовем его стартовым), используемый для инициализации входного вектора; обычна ситуация, когда $p < w$, недостающие элементы входного вектора извлекаются из имеющегося сканирующего окна). Нейронная сеть возвращает p прогнозных значений (в соответствии с числом нейронов), однако наиболее информативным (и полезным) будем считать первый, он и используется для формирования следующего входного вектора. Выполнив рекурсивное прогнозирование на необходимое число шагов, следует оценить полученное итоговое относительно приращение относительно середины зоны допустимых значений (нуля). Как и в

предыдущем алгоритме, если итоговое приращение приводит к выходу за границу зоны допустимых значений, то осуществляется уведомление о потенциально опасной ситуации.

Представленный подход показал эффективность на имеющихся тестовых наборах данных. Наибольшая точность прогноза обеспечивается на плавно меняющихся показателях. Однако и при резкой смене характера поведения аппаратуры обеспечивается автоматическое обнаружение сбоев датчика, так как нехарактерная активность в соответствующий момент времени подается в нейросеть в процессе дообучения. Соответственно, на новой позиции окна нейронная сеть спрогнозирует выход за пределы допустимой зоны.

3. Использование комитетов классификаторов на основе корреляционного подхода в задаче диагностики

Диагностика показаний датчиков может быть осуществлена на основе анализа корреляционных связей между показаниями датчиков. Общая идея такого подхода заключается в оценке парных корреляций между датчиками, входящими в контролируруемую группу, и последующей обработке поступающих данных. Сохранение корреляционных связей при добавлении к выборке нового (диагностируемого) набора показаний сигнализирует о штатной работе, нарушение этих связей говорит о возникновении сбоев.

Пусть S – множество контролируемых датчиков $\{s_i\}, i = 1, \dots, n$, а показания каждого датчика, полученные в заданные дискретные моменты времени t , определяются функцией $x_i(t)$. Прецеденты, составляющие обучающую выборку, определяются множеством кортежей $V = \{(x_1(t), \dots, x_n(t))\}, t = 0, \dots, m$. Контролируемые показания датчиков получены в момент времени $t' = m + 1$ и представлены множеством из одного кортежа $V' = \{(x_1(t'), \dots, x_n(t'))\}$.

Для кортежей V по преобразованной формуле Пирсона вычислим коэффициент корреляции R_{ij} между показаниями датчиков s_i и s_j :

$$R_{ij} = \frac{m \sum_{t=0}^m (x_i(t)x_j(t)) - \sum_{t=0}^m (x_i(t)) \sum_{t=0}^m (x_j(t))}{\sqrt{(m \sum_{t=0}^m (x_i(t))^2 - (\sum_{t=0}^m (x_i(t)))^2)(m \sum_{t=0}^m (x_j(t))^2 - (\sum_{t=0}^m (x_j(t)))^2)}}$$

где $x_i(t)$ и $x_j(t)$ – значения признаков (показания датчиков s_i и s_j), m – общее число наблюдений. Аналогично вычислим R'_{ij} – коэффициент корреляции Пирсона для множества пар показаний датчиков s_i и s_j , входящих во множество $U = V \cup V'$ (для $t = 0, \dots, m+1$).

Оценка допустимого изменения коэффициентов корреляции R_{ij} и R'_{ij} с использованием введенной нами функции-эксперта $f(i, j)$ позволяет определить некорректные показания датчиков, присутствующие в V' . Для контроля показаний датчиков предлагается использовать взвешенный комитет классификаторов, поскольку нарушение корреляционной связи между парой датчиков s_i и s_j может свидетельствовать о сбое в показаниях любого из этих датчиков. Для принятия решения о наличии сбоя в показаниях конкретного датчика необходимо провести оценку всей выбранной группы датчиков. Предлагаемый взвешенный комитет учитывает то, что наибольшее влияние оказывают более сильные корреляционные связи, тогда как факт сохранения слабых корреляционных связей не гарантирует отсутствие сбоев.

Каждая функция-эксперт $f(i, j)$ является кусочно-постоянной и должна обладать следующими свойствами:

$$f(i, j) \begin{cases} \llcorner 0 \llcorner & \text{при } i \neq j, \text{ если изменение корреляции между датчиками } s_i \text{ и } s_j \text{ значимо} \\ \llcorner = 0 \llcorner & \text{при } i = j \\ \llcorner > 0 \llcorner & \text{при } i \neq j, \text{ если изменение корреляции между датчиками } s_i \text{ и } s_j \text{ не значимо} \end{cases}$$

Оценка ситуации с использованием комитета учитывает как решения каждого из экспертов, так и степень доверия к каждому эксперту, входящему в комитет. Общая оценка показаний датчика s_i с использованием взвешенного комитета классификации определяется формулой

$$W(i) = \sum_{j=1}^n f(i, j)g(i, j),$$

где n – количество функций-экспертов, $f(i, j)$ – осуществляет оценку нарушения корреляционных связей между показаниями датчиков s_i и s_j , $g(i, j)$ – весовой коэффициент, определяющий степень доверия к функции-эксперту.

Общее количество функций-экспертов, входящих в комитет, равно n^2 (на практике достаточно определить $\frac{n(n-1)}{2}$ функций-экспертов, т.к. $f(i, j) = f(j, i)$ при $i \neq j$ и $f(i, j) = 0$ при $i = j$), в голосовании по каждому датчику принимает участие n экспертов.

При решении рассматриваемой задачи использована пороговая функция оценки

$$f(i, i) = \begin{cases} -1, \text{ если } |R_{ij} - R'_{ij}| \leq \varepsilon_{ij} \\ +1, \text{ если } |R_{ij} - R'_{ij}| > \varepsilon_{ij} \end{cases},$$

где ε_{ij} – допустимое отклонение корреляционного коэффициента (величины заранее неизвестны). Отрицательные значения сигнализируют о сбое. Определим степень доверия к эксперту как квадратичную функцию $g(i, j) = R_{ij}^2$. Для обеспечения классификации сбоев в показаниях датчиков предлагается проводить настройку функций-экспертов с выбором ε_{ij} на основе данных обучающей выборки. Анализ данных, содержащихся в базе прецедентов, показывает, что коэффициент корреляции R'_{ij} может значительно измениться даже в случае добавления в множество U одного из элементов исходного множества V (характеризующего штатный режим работы), что может быть вызвано аномалиями в обучающей выборке. Понижая пороговое значение ε_{ij} , можно обеспечить заданную точность классификации

для штатного режима работы (нормы) и повысить точность классификации ошибок.

Алгоритм настройки функции-эксперта:

1. поиск значения ε_{ij} , обеспечивающего безошибочную классификацию штатного режима работы (сводится к задаче поиска максимального отклонения $\max(|R_{ij} - R'_{ij}|)$ при $V' \in V$);

2. поиск минимального значения $0 \leq \varepsilon_{ij} \leq \max(|R_{ij} - R'_{ij}|)$, при котором корректно классифицируется заданное количество элементов обучающей выборки.

Общий алгоритм предлагаемого метода контроля состоит из двух этапов.

Этап 1 (настройка функций-экспертов):

1. выбор группы коррелирующих датчиков;
2. извлечение информации из базы прецедентов (исключаем неполные или поврежденные записи);

3. вычисление корреляционных коэффициентов R_{ij} для каждой пары датчиков;

4. настройка функций-экспертов для всех возможных пар датчиков.

Этап 2 (тестирование и оценка корректности определения сбоя):

1. выбор случайного вектора из обучающей выборки;

2. выбор случайного датчика и генерация ошибки;

3. вычисление функций-экспертов на заданном векторе значений для оценки корреляционных связей;

4. определение сбоя с использованием взвешенного комитета;

5. сбор статистики относительно корректности определения сбоя.

В ходе тестирования генерация «некорректных» значений показаний датчика проводилась в различных диапазонах – как характерных для данного датчика, так и выходящих за установленные пределы. Диапазон возможных значений разбит на отрезки фиксированной длины, случайное значение показаний датчика генерировалось в заданных диапазонах с равновероятным законом распределения (\min – минимальное значение показаний датчика и \max – максимальное значение показаний датчика, присутствующие в базе прецедентов). Статистика собрана на основе обработки 100 тысяч тестовых векторов. Комитет построен на основе группы из пяти датчиков с сильными корреляционными связями. При настройке функции-эксперта на распознавание 99% показаний от пар датчиков комитет распознает 97,88% векторов «нормы». В Табл. 4 представлены результаты распознавания ситуации типа «сбой» при разных уровнях отклонения от типичных значений показаний датчиков.

Предложенный комитет функций-экспертов реагирует на значительные отклонения от типичных значений датчика (более $L = \max - \min$), определяя сбоящий датчик с вероятностью не менее 97% и обеспечивая высокую точность определения класса «нормы». Кроме того, использование предложенного подхода позволяет

Табл. 4. Результаты тестирования

Функция-эксперт Диапазон случайной величины	Настройка ε_{ij} для распознавания 100% «нормы»	Настройка ε_{ij} для распознавания 99% «нормы»
$[\min - L, \min - 2L]$	99,6%	97,1%
$[\min, \min - L]$	24,1%	51,6%
$[\min, \max]$	18,4%	47,2%
$[\max, \max + L]$	94,8%	95,7%
$[\max + L, \max + 2L]$	99,6%	97,1%

определить до 47% сбоев в том случае, когда некорректное значение находится в диапазоне типичных для датчика показаний.

4. Обработка телеметрической информации нейронной сетью Кохонена

Задачу обнаружения неисправности аппаратуры датчиков можно решить с помощью ИНС Кохонена [14]. Известно, что данный тип нейронных сетей хорошо справляется с разделением входной информации на различные классы. В реализации сети предлагается использовать два класса: в первом классе будут содержаться данные, которые соответствуют штатному режиму работы подсистем, во втором классе – данные, характерные для неисправных датчиков КА.

После проведенного корреляционного анализа нами была определена группа из пяти датчиков с сильной корреляцией: “Sun,V”, “Sun,A”, “Sp1,A”, “Sp2,A” и Sp3,A. Таким образом, входные данные ИНС представляют собой пятимерный вектор. В доступной нам базе телеметрической информации имеется свыше 350 уникальных входных векторов с показаниями датчиков, соответствующих нормальной работе некоторой подсистемы КА (назовем их «нормальные вектора»). Необходимо обучить нейронную сеть Кохонена, решающую задачу кластеризации двух групп векторов, характерных для противоположных случаев: «нормальная работа группы датчиков/подсистемы КА» и «сбой в одном или более датчике подсистемы КА» соответственно.

Сеть Кохонена – это однослойная сеть, нейроны которой соединены со всеми компонентами n -мерного входного вектора. Каждый нейрон описывается вектором весов, которые в процессе обучения сети корректируются. Обучение данного типа ИНС происходит без учителя и основывается на подаче на вход сети обучающей выборки. Поданный на вход сети вектор сравнивается с текущими весами каждого нейрона, нейрон-победитель определяется минимальным Евклидовым расстоянием между его весами и входным вектором.

Для успешного обучения ИНС Кохонена в обучающей выборке необходимо иметь различные данные, представляющие все классы: в качестве векторов, представляющих класс «неисправность», в исследованиях использовались искусственно поврежденные вектора показаний датчиков (назовем их «искаженные вектора»), компоненты которых брались с выходом за границы, определяющие нормальную работу датчиков.

Ниже описаны результаты экспериментов с различными конфигурациями сети (изменялось число нейронов в слое Кохонена, способ задания искаженных векторов и количество эпох обучения). Обучающая выборка содержит равное количество векторов обоих классов.

Первый тест проводился с 10 нейронами, 10000 эпохами обучения и 353 векторами каждого класса. Получены следующие результаты: полнота распознавания нормальных векторов: 90%; полнота распознавания искаженных векторов: 100%; точность распознавания ситуации: 100% (поскольку нормальные вектора не попали в кластер искаженных векторов, а искаженные вектора не попали в кластер нормальных); полнота распознавания ситуации: 95%.

Предыдущий тест показал, что большинство нейронов никогда не побеждали (или побеждали редко по сравнению с другими нейронами). Во втором тесте количество нейронов слоя Кохонена сокращено до пяти, а количество эпох обучения сокращено до 10. Результаты тестирования: полнота распознавания нормальных векторов: 96%; полнота распознавания искаженных векторов: 100%; точность распознавания ситуации: 100%; полнота распознавания ситуации: 98%. Увеличение количества эпох обучения до 10000 не дало ощутимого результата: изменилась лишь полнота распознавания нормальных векторов с 96% до 97%.

В третьем тесте слой Кохонена состоял из трех нейронов, диапазон показаний датчиков искаженных векторов: [max, 2max]. С такими данными сеть Кохонена не справилась и практически все вектора «притянулись» к одному кластеру. Эксперимент проводился для различного числа эпох (вплоть до 10000), результат был одинаков во всех случаях. Это объясняется

спецификой возбуждения нейронов посредством расстояния Евклида и определения победителя: чем ближе друг к другу вектора в обучающей выборке, тем ближе друг к другу формируются кластера и, как следствие, хуже качество распознавания.

Экспериментальные результаты показывают, что нейронная сеть Кохонена – это хороший инструмент для бинарной классификации данных телеметрии. Неоспоримыми преимуществами этой ИНС являются простота реализации и высокая скорость работы. Однако, специфика подхода, в частности, использование Евклидовой метрики и принципа «победитель забирает все», делает ИНС Кохонена очень чувствительной к входным данным.

В проведенных экспериментах выявлены следующие закономерности.

1. Нормирование входных данных сильно ухудшает результат работы кластеризации. Это происходит потому, что в результате нормирования векторов, нормальные и искаженные вектора становятся слишком близкими друг к другу.

2. С тремя нейронами в слое Кохонена хватает всего 10-100 эпох обучения. Это объясняется малой размерностью входного вектора и небольшой обучающей выборкой (около 700 уникальных векторов).

3. Сеть с двумя нейронами в слое Кохонена неспособна решить задачу в текущей постановке (в процессе обучения всегда побеждает один нейрон), для осуществления корректной кластеризации минимальное число нейронов – три. Это объясняется свойствами данной ИНС – необходимостью конкуренции нейронов. Использование сети с большим количеством нейронов приводит к тому, что после процесса обучения сети остается много «мертвых» нейронов, работает лишь два нейрона (кластер нормальных векторов и кластер искаженных).

Таким образом, использование ИНС Кохонена для решения задачи кластеризации и последующей классификации имеющихся данных может дать показатели точности и полноты распознавания более 90%, но для этого диапазон значений нештатной работы должен быть шире диапазона нормальной работы более чем в два раза.

Заключение

В данной работе описан комплекс методов восстановления данных телеметрии, контроля и диагностики подсистем КА посредством анализа ТМИ. В частности, предложены методы восстановления входных данных: метод на основе модифицированного ZET-алгоритма; специальный алгоритм на основе интерполяционного многочлена Лагранжа; нейронная сеть прямого распространения, функционирующая в режиме ассоциативной памяти. Предложен метод контроля показаний датчиков аппаратуры, который строится на корреляционном анализе данных; инструмент на основе динамически переобучающейся искусственной нейронной сети прямого распространения; особым образом настроенная ИНС Кохонена, неоспоримыми преимуществами которой являются простота реализации, скорость работы и отсутствие в процессе обучения учителя.

Результаты тестирования в задачах восстановления ТМИ и определения неисправности подсистем КА показали, что разработанные методы способны решать задачи мониторинга и диагностики состояния подсистем КА по телеметрическим данным, осуществлять классификацию обнаруженных неисправностей с высокими показателями точности и полноты.

Литература

1. Талалаев А.А., Тищенко И.П., Фраленко В.П., Хачунов В.М. Анализ эффективности применения искусственных нейронных сетей для решения задач распознавания, сжатия и прогнозирования // Искусственный интеллект и принятие решений, № 2, 2008, с.24-33.
2. Талалаев А.А., Фраленко В.П. Контроль и диагностика датчиков положения космического аппарата // Искусственный интеллект и принятие решений, № 3, 2009, с.49-52.
3. Емельянова Ю.Г., Константинов К.А., Погодин С.В., Талалаев А.А., Тищенко И.П., Фраленко В.П., Хачунов В.М. Нейросетевая система контроля датчиков углов ориентации и дальности космического аппарата // Программные системы: теория и приложения, № 1, 2010, с.45-59.
4. Ганченко В.В., Дудкин А.А., Инютин А.В. и др. Программная нейросетевая система контроля космической телеметрии // «Искусственный интеллект» № 4, 2013, с.502-511.
5. Воронцов В.А., Федоров Е.А. Разработка прототипа интеллектуальной системы оперативного мониторинга и технического состояния основных бортовых систем

- космического аппарата // «Труды МАИ». Выпуск № 82, 2015, с.1-25.
6. Абрамов Н.С., Заднепровский В.Ф., Талалаев А.А., Фраленко В.П. Применение искусственных нейронных сетей в задачах контроля и диагностики подсистем космических аппаратов // Современные проблемы науки и образования, № 3, 2014. URL: <http://www.science-education.ru/pdf/2014/3/296.pdf> (дата обращения: 12.11.2015).
 7. Абрамов Н.С., Ардентов А.А., Емельянова Ю.Г., Талалаев А.А., Фраленко В.П., Шишкин О.Г. Архитектура системы мониторинга и прогнозирования состояния космического аппарата // Программные системы: теория и приложения, № 2, 2015, с.85-99.
 8. Абрамов Н.С., Заднепровский В.Ф., Талалаев А.А., Фраленко В.П., Хачумов М.В. Перспективная система мониторинга и прогнозирования состояния космического аппарата на основе анализа интегрированной информации // Авиакосмическое приборостроение, № 6, 2015, с.33-48.
 9. Векторное квантование. URL: <http://dic.academic.ru/dic.nsf/ruwiki/836351> (дата обращения: 12.11.2015).
 10. Малый Космический Аппарат «Юбилейный». URL: http://sat.sibsau.ru/index.php?option=com_content&view=section&layout=blog&id=3&Itemid=2 (дата обращения: 12.11.2015).
 11. Riedmiller M. Braun H. A direct adaptive method for faster backpropagation learning: The RPROP algorithm. In Proceedings of the IEEE International Conference on Neural Networks 1993 (ICNN 93). San Francisco, 1993.
 12. Загоруйко Н.Г. Методы распознавания и их применение. – М.: Советское Радио, 1972. – 207 с.
 13. Тынкевич М.А. Численные методы анализа. – Кемерово, 2002. – 378 с.
 14. Kohonen T. Self-Organizing Maps (Third Extended Edition), ISBN 3-540-67921-9, New York, 2001. – 501 p.

Абрамов Николай Сергеевич. Научный сотрудник Исследовательского центра мультипроцессорных систем ИПС им. А.К. Айламазяна РАН. Окончил ЧОУ ВО «УГП имени А.К. Айламазяна» в 2010 году. Кандидат технических наук. Автор более 20 печатных работ. Область научных интересов: методы обработки изображений, системы компьютерного зрения, искусственный интеллект. E-mail: n-say@nsa.pereslavl.ru

Талалаев Александр Анатольевич. Старший научный сотрудник Исследовательского центра мультипроцессорных систем ИПС им. А.К. Айламазяна РАН. Окончил ЧОУ ВО «УГП имени А.К. Айламазяна» в 2006 году. Кандидат технических наук. Автор более 30 печатных работ. Область научных интересов: искусственный интеллект, машинная графика, распознавание образов, параллельные вычисления. E-mail: arts@arts.botik.ru

Фраленко Виталий Петрович. Старший научный сотрудник Исследовательского центра мультипроцессорных систем ИПС им. А.К. Айламазяна РАН. Окончил ЧОУ ВО «УГП имени А.К. Айламазяна» в 2006 году. Кандидат технических наук. Автор более 60 научных работ. Область научных интересов: искусственные нейронные сети, машинное обучение, прикладные системы, параллелизм вычислений, защита компьютерных сетей. E-mail: alarmod@pereslavl.ru