

В.Л. ЯКИМОВ, Г.Н. МАЛЬЦЕВ  
**ГИБРИДНЫЕ СЕТЕВЫЕ СТРУКТУРЫ И ИХ  
ИСПОЛЬЗОВАНИЕ ПРИ ДИАГНОСТИРОВАНИИ СЛОЖНЫХ  
ТЕХНИЧЕСКИХ СИСТЕМ**

*Якимов В.Л., Мальцев Г.Н. Гибридные сетевые структуры и их использование при диагностировании сложных технических систем.*

**Аннотация.** Предложен подход к техническому диагностированию сложных технических систем по результатам обработки телеметрической информации внешней системой контроля и диагностирования с использованием гибридных сетевых структур. Рассмотрен принцип построения диагностических комплексов сложных технических систем, обеспечивающий автоматизацию процесса технического диагностирования и основанный на использовании при обработке телеметрической информации моделей в виде гибридных сетевых структур, включающих многослойные нейронные сети и дискретные байесовские сети со стохастическим обучением. Разработаны модель изменения параметров технического состояния сложных технических систем на основе многослойных нейронных сетей, позволяющая сформировать вероятностную оценку отнесения текущей ситуации функционирования сложной технической системы к множеству рассмотренных ситуаций функционирования по отдельным телеметрируемым параметрам, и многоуровневая иерархическая модель технического диагностирования сложных технических систем на основе дискретной байесовской сети со стохастическим обучением, позволяющая агрегировать полученную от нейросетевых моделей информацию и распознавать текущую ситуацию функционирования сложной технической системы. В условиях нештатных ситуаций функционирования сложной технической системы по результатам обработки телеметрической информации локализуются неисправные функциональные узлы и формируется объяснение причины возникновения нештатной ситуации. Детализированы этапы реализации технического диагностирования сложных технических систем с использованием предложенных гибридных сетевых структур при обработке телеметрической информации. Представлен пример использования разработанного подхода к решению задач технического диагностирования бортовой системы космического аппарата. Показаны преимущества предлагаемого подхода к техническому диагностированию сложных технических систем в сравнении с традиционным подходом, основанном на анализе принадлежности значений телеметрируемых параметров заданным допускам.

**Ключевые слова:** сложная техническая система, техническое диагностирование, гибридная сетевая структура, байесовская сеть, стохастическое обучение.

**1. Введение.** В различных сферах деятельности в процессе эксплуатации сложных технических систем (СТС) широко используется принцип ситуационного управления [1]. При этом принципе управление СТС осуществляется с учетом текущей ситуации функционирования, определяемой условиями применения СТС, техническим состоянием и функциональными возможностями. Принимаемые решения по управлению и применению СТС по назначению в значительной степени определяются результатами технического диагностирования, характеризующими текущее

техническое и функциональное состояния СТС [2, 3]. Отсюда следует важность задачи технического диагностирования СТС, дающего необходимую информацию для обоснованного принятия решений по управлению и применению СТС.

Особенностью процесса технического диагностирования современных СТС является распределение задач диагностирования между встроенными и внешними средствами контроля и диагностирования. Также необходимо наличие баз данных с набором типовых ситуаций функционирования СТС и их признаков, формируемых на основе принимаемой телеметрической информации (ТМИ). Это характерно, в частности, для технического диагностирования находящихся на орбите космических аппаратов (КА) [2–6]. Наличие баз данных ситуаций функционирования СТС позволяет выявлять и устранять (парировать) рассмотренные в них нештатные ситуации с помощью встроенных средств контроля, технического диагностирования и восстановления работоспособного состояния СТС. В то же время при возникновении нештатных ситуаций, не рассмотренных в базах данных СТС, распознавание текущей ситуации функционирования СТС осуществляется внешней системой контроля технического состояния и диагностирования СТС по результатам обработки ТМИ. Восстановление ее работоспособного состояния также осуществляется внешней системой управления.

С использованием внешних средств технического диагностирования СТС выявляются отказы и нештатные ситуации, отсутствующие в базе данных, а также ситуации функционирования, характеризующиеся существенной априорной неопределенностью значений временных рядов телеметрируемых параметров (ТМП) и сложностью выявления причины их возникновения, необходимостью проведения углубленного анализа всей имеющейся диагностической информации. У разработчиков КА подобного рода ситуации функционирования получили название «тяжелых» отказов [4, 6]. Возможности распознавания таких ситуаций функционирования СТС на основе традиционно используемого при контроле их технического состояния допускового контроля ограничены. Различные ситуации функционирования СТС допуска на значения отдельных ТМП могут пересекаться. Отличительным признаком подобных ситуаций функционирования СТС может быть характер изменения отдельных ТМП, а не область определения их значений. Поэтому в основу технического диагностирования СТС, для которых характерны такие ситуации функционирования, должно быть положено диагностирование с использованием моделей изменения их ТМП. При

этом допуски могут быть использованы для контроля работоспособности СТС и задаваться как для отдельных ТМП, так и для обобщенных параметров технического состояния, определяемых по совокупности ТМП.

В настоящее время для большинства СТС задачи углубленного анализа полных потоков ТМИ решаются в отложенном режиме в течение достаточно продолжительного периода времени. Так, при техническом диагностировании находящихся на орбите КА для углубленного анализа таких ситуаций функционирования используются принятые с КА полные потоки ТМИ. Привлекаются эксперты и разработчики бортовой аппаратуры. Космический аппарат на время анализа технического состояния и нештатной ситуации функционирования бортовой аппаратуры переводится в специальный дежурный режим. Поэтому автоматизация процесса обработки полных потоков ТМИ о техническом состоянии СТС и повышение оперативности проведения углубленного анализа ситуаций их функционирования имеет важное значение для совершенствования диагностических комплексов СТС. Она позволяет оперативно выявлять и парировать нештатные ситуации и реализовать перспективные схемы ситуационного и проактивного управления применением СТС [7–10].

В статье рассмотрен подход к техническому диагностированию СТС по результатам обработки ТМИ внешней системой контроля и диагностирования с использованием моделей в виде гибридных сетевых структур, включающих многослойные нейронные сети и дискретные байесовские сети со стохастическим обучением. Многослойные нейронные сети, реализующие вывод о ситуациях функционирования аппаратных модулей и подсистем СТС по отдельным ТМП, являются иерархически связанными между собой моделями изменения и обработки ТМИ. Дискретные байесовские сети со стохастическим обучением, реализующие вывод о ситуациях функционирования СТС в целом, являются моделью распознавания текущей ситуации функционирования СТС.

**2. Общая характеристика подхода к техническому диагностированию СТС по результатам обработки ТМИ с использованием моделей в виде гибридных сетевых структур.** Предлагаемый подход реализует идеи технического диагностирования СТС. Он основан на моделях, и их многомодельном описании. Этот подход в настоящее время получает широкое распространение при решении задач технического диагностирования и управления СТС [11–14]. При этом для описания процессов функционирования и

технического диагностирования СТС используется широкий спектр математических моделей: вероятностные модели, производственные модели, модели на основе различных автоматов, сетей и другие модели [12, 15–20]. Выбранные типы моделей – многослойные нейронные сети и дискретные байесовские сети – хорошо согласуются с задачей технического диагностирования СТС. Эти СТС имеют многоуровневую иерархическую структуру и сложный характер зависимости между параметрами, отражающие техническое состояние и функциональные возможности систем. Модели их объединяются в агрегированные гибридные сетевые структуры.

Применение моделей изменения ТМП СТС на основе многослойных нейронных сетей позволяет обеспечить: высокую достоверность распознавания ситуаций функционирования аппаратных модулей и подсистем СТС в условиях значительной неопределенности значений и существенно нелинейного характера ТМП; возможность обработки разнородной (не только телеметрической) информации о ситуациях функционирования СТС; распараллеливание процессов обработки полных потоков ТМИ для достижения высокой оперативности ее углубленного анализа [21-24]. Модели диагностирования СТС на основе дискретной байесовской сети позволяет объяснить полученные результаты распознавания ситуаций функционирования СТС и определить наиболее вероятные причины возникновения ранее не рассмотренных нештатных ситуаций, что очень важно для формирования баз данных систем поддержки принятия решения по управлению СТС [25].

Существенной особенностью рассматриваемых гибридных моделей в виде сетевых структур с точки зрения их использования при техническом диагностировании СТС является возможность решать в рамках одной агрегированной модели не только задачи контроля технического состояния и диагностирования СТС, но и задачу выявления негативных тенденций изменения технического состояния СТС. Она в отличие от задачи экстраполяции временных рядов ТМП СТС, является востребованной на практике, но достаточно слабо освещена в литературе [33]. При этом предлагаемая реализация дискретной байесовской сети имеет отличия от общепринятых реализаций, рассматриваемых в большинстве источников [26-32]. Она предполагает совместную обработку двух видов информации об одних и тех же ситуациях функционирования СТС, получаемую на основе знаний экспертов и по результатам обработки ТМИ. Это нашло отражение в ее архитектуре и функционировании и потребовало разработки оригинального стохастического подхода к обучению сети

на основе дискретно-событийного имитационного моделирования. В доступных источниках примеры реализации таких сетей и подробное описание их функционирования практически отсутствуют, а подходы к согласованию разнородных данных в байесовских сетях рассмотрены в незначительной степени [30].

Подход к техническому диагностированию СТС по результатам обработки ТМИ с применением моделей в виде гибридных сетевых структур основан на следующей процедуре. Это преобразование исходных значений разнородных ТМП во множество однородных вторичных признаков с использованием множества нелинейных моделей  $\{M_{v,p}\}$ , характеризующих изменение различных ТМП в различных ситуациях функционирования СТС. Признаками технического состояния СТС являются вероятности отнесения текущей динамической реализации  $v$ -ых ТМП в  $p$ -ых ситуациях функционирования к моделям  $\{M_{v,p}\}$ . Данные вероятности, как признаки технических состояний, связываются между собой в рамках агрегированной модели  $M_{\Sigma}$ , отражающей многоуровневые иерархические взаимосвязи параметров СТС. Результатом технического диагностирования является распознавание ситуаций функционирования СТС. Модели  $\{M_{v,p}\}$  и  $M_{\Sigma}$  создаются на этапе проектирования СТС и корректируются на последующих этапах их жизненного цикла. Так, нештатная ситуация, выявленная внешней системой контроля и диагностирования и отработанная внешней системой управления, добавляется в базу данных ситуаций функционирования СТС.

Реализация принципов технического диагностирования СТС, основанного на моделях, и их многомодельное описание являются наиболее продуктивными при автоматизированном решении задач обработки полных потоков ТМИ о техническом состоянии СТС в условиях априорной неопределенности. Как показывает практика, включение нелинейных моделей в механизмы определения технического состояния анализируемой СТС и распознавания нештатных ситуаций ее функционирования позволяет получать правильные решения в сложных условиях функционирования СТС, когда алгоритмы только на основе логических правил и допусков недостаточно эффективны [11].

Достоинством предлагаемого подхода к построению моделей технического диагностирования СТС с использованием гибридных сетевых структур является возможность повышения достоверности решения задачи распознавания текущей ситуации функционирования СТС. Это делается за счет:

- формирования пространства однородных вторичных признаков (в том числе нелинейных), в котором задача обучения модели распознавания ситуации функционирования СТС будет решаться быстрее. При заданном времени обучения будет достигаться более высокая достоверность их распознавания;

- расширения пространства диагностических признаков при увеличении количества ситуаций функционирования СТС на каждом уровне агрегированной модели  $M_{\Sigma}$ ;

- обеспечения инвариантности вторичных признаков к режимам работы и условиям функционирования СТС;

- возможности достижения низкой чувствительности вторичных признаков к различного рода возмущениям во временных рядах ТМП за счет их фильтрации с использованием моделей  $\{M_{v,p}\}$ .

Гибридный характер используемых моделей технического диагностирования СТС определяется объединением в них моделей двух типов: многослойных нейронных сетей и дискретных байесовских сетей. Сетевой характер используемых моделей обусловлен многоуровневой иерархической структурой СТС и присущей им структурной сложностью на каждом уровне представления. При этом сами гибридные сетевые модели имеют два уровня описания ситуаций функционирования СТС: нижний уровень для ситуаций функционирования аппаратных модулей и подсистем СТС по отдельным ТМП и верхний уровень для ситуаций функционирования СТС в целом по всему анализируемому потоку ТМИ. Выполним формализованное описание гибридных сетевых моделей технического диагностирования СТС, начиная с верхнего уровня, на котором осуществляется принятие решения о техническом состоянии СТС и распознавание текущей ситуации ее функционирования.

**3. Формализованное описание процесса технического диагностирования СТС по результатам обработки ТМИ с использованием дискретных байесовских сетей.** В общем случае агрегирование информации от динамических моделей изменения ТМП  $\{M_{v,p}\}$  при оценке технического состояния СТС может быть реализовано различными способами [13–21]. Математические модели дискретных байесовских сетей [11, 24–30] позволяют:

- реализовать агрегированную модель  $M_{\Sigma}$  технического диагностирования СТС и распознавания ее текущей ситуации функционирования по результатам обработки совокупности ТМП, образующих полный поток ТМИ;

- насытить модель  $M_{\Sigma}$  имеющимися экспертными знаниями о

функционировании СТС и объяснить полученные результаты распознавания ситуаций функционирования СТС.

Важными достоинствами дискретных байесовских сетей при решении задач технического диагностирования СТС являются математически доказанные свойства непротиворечивости вывода, возможность его в условиях неполного вектора диагностических признаков, осуществимость работы с задачами большой размерности, многообразие подходов к их обучению и применению [11, 21–30]. Кроме того, использование диагностических моделей на основе дискретных байесовских сетей позволяет выполнить требование к автоматизации процессов обработки ТМИ и технического диагностирования СТС в интересах поддержки принятия решений по управлению СТС. В соответствии с ними по результатам распознавания ситуаций функционирования СТС требуется формирование вариантов принятия решений по управлению СТС и предъявление лицу, принимающему решение, объяснения полученных результатов [11]. Именно поэтому использование дискретных байесовских сетей является одним из наиболее адекватных подходов для реализации диагностических моделей СТС, позволяющим реализовать логико-вероятностные рассуждения и сформировать на основе базы данных СТС обоснованный вывод о текущей ситуации ее функционирования.

Структурная схема модели распознавания ситуаций функционирования СТС на основе дискретной байесовской сети, реализующая рассматриваемый подход к техническому диагностированию СТС, представлена на рисунке 1. Модель отражает иерархическую структуру СТС и пути развития ситуаций функционирования между уровнями ее иерархии. Модель представляет собой направленный граф, без циклов. Дуги графа отображают причинно-следственные связи между переменными, благодаря чему дискретные байесовские сети также называют причинно-следственными сетями. Структура предлагаемой многоуровневой иерархической модели  $M_{\Sigma}$  содержит пять уровней иерархии: отдельных ТМП, аппаратных модулей, подсистем, функциональных систем и СТС в целом. Такая декомпозиция структуры СТС позволяет описать широкий класс СТС различного назначения.

Количество уровней иерархии модели  $M_{\Sigma}$  было выбрано на основе изучения типовых структур СТС и известных подходов к такому делению [3], а также анализа сообщений о неисправностях в СТС различного назначения. Для описания процесса принятия

решения по управлению СТС дискретная байесовская сеть может быть дополнена шестым уровнем с вершинами, характеризующими обобщенные состояния СТС. В качестве них выступают состояния: штатное функционирование СТС, нештатные ситуации (частично-работоспособное состояние СТС и др.) [2, 4, 6]. Количество уровней иерархии может варьироваться, в зависимости от требуемой степени детализации при локализации неисправных функциональных узлов СТС.

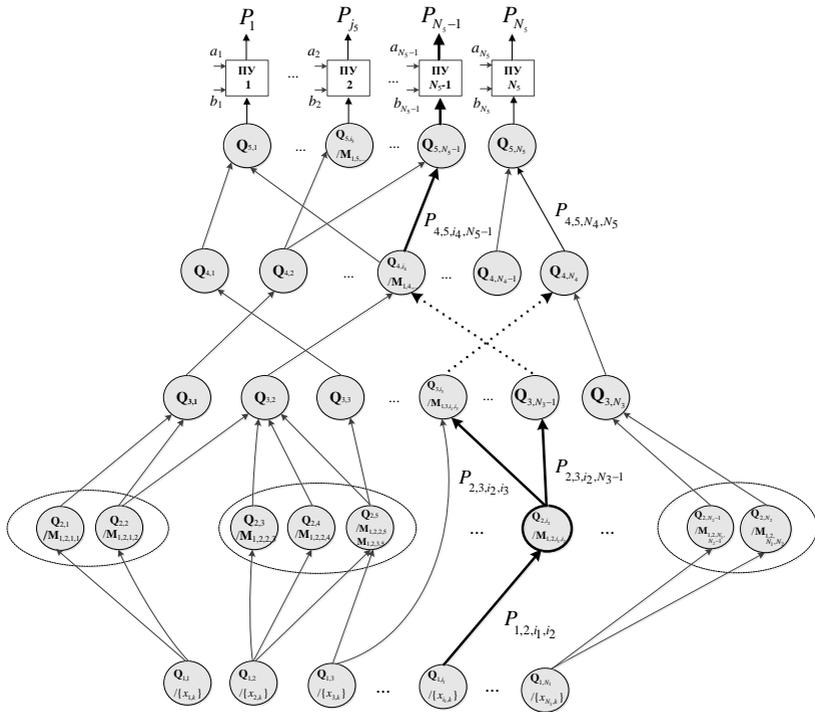


Рис. 1. Структурная схема модели распознавания ситуаций функционирования СТС на основе дискретной байесовской сети

Множество значений всех учитываемых при техническом диагностировании ТМП определяет множество начальных состояний модели. На каждом последующем уровне (аппаратных модулей, подсистем и функциональных систем) имеет место конечное число типовых штатных ситуаций функционирования и нештатных ситуаций. Выходным результатом является одна из возможных

ситуаций функционирования на уровне СТС, определяющих множество поглощающих состояний модели, число которых может быть значительным и составлять несколько сотен ситуаций.

Введем следующие обозначения:

$N_l$  – количество ситуаций функционирования на каждом  $l$ -ом уровне (количество вершин), где  $l=1...5$  – номер уровня;

$N_1$  – количество начальных состояний;

$N_5$  – количество поглощающих состояний;

$\{Q_{l,i} | \{x_{l,i}\}\}$  – множество вершин  $\{Q_{l,i}\}$  уровня дискретной байесовской сети с номером  $l=1$ , соответствующих динамическим реализациям  $i$ -ых ТМП и представляющих собой множество значений  $\{x_{l,i}\}$ ;

$\{Q_{l,i}\}$  – множество вершин уровня дискретной байесовской сети с номером  $l$ , характеризующих штатные ситуации функционирования и нештатные ситуации в элементах СТС различного уровня иерархии ( $l=2,3,4$ ) и СТС в целом ( $l=5$ );

$\{P_{l-1,l}\}$  – множество матриц вероятностных переходов между смежными уровнями, начиная со второго, характеризующих причинно-следственные связи между ситуациями функционирования;

$\{P_{1 \times l}^*\}$  – множество матриц переходов между первым уровнем и остальными уровнями, начиная со второго, отражающих условные вероятности возникновения ситуаций функционирования по результатам соотнесения значений ТМП и нейросетевых динамических моделей их изменения  $M_{1,l,i,i}$ ;

$P_l^*$  – вектора вероятностей достижения вершин каждого уровня с номерами  $l=1...5$ .

Поглощающие вершины на пятом уровне дискретной байесовской сети соответствуют множеству рассмотренных ситуаций функционирования СТС, которое, в общем случае, включает штатные ситуации функционирования СТС и рассмотренные нештатные ситуации из базы данных СТС.

Первый уровень модели связан со всеми остальными уровнями через разреженные матрицы вероятностей переходов  $P_{1 \times l}^*$ :

$$P_{1 \times l}^* = \begin{pmatrix} P_{1,l,1,1} & P_{1,l,1,2} & \dots & P_{1,l,1,N_l} \\ P_{1,l,2,1} & P_{1,l,2,2} & \dots & P_{1,l,2,N_l} \\ \dots & \dots & \dots & \dots \\ P_{1,l,N_1} & P_{1,l,N_1,2} & \dots & P_{1,l,N_1,N_l} \end{pmatrix}, \quad 2 \leq l \leq 5. \quad (1)$$

Элементы матрицы вероятностей переходов  $\mathbf{P}_{l \times l}^*$  вида (1) определяются по результатам обработки ТМП с использованием динамических моделей их изменения  $\mathbf{M}_{1,l,i_j,i_j}$ .

Смежные уровни, начиная со второго, связаны между собой разреженными матрицами вероятностей переходов  $\mathbf{P}_{l-1 \times l}$ :

$$\mathbf{P}_{l-1 \times l} = \begin{pmatrix} P_{l-1,l,1,1} & P_{l-1,l,1,2} & \dots & P_{l-1,l,1,N_l} \\ P_{l-1,l,2,1} & P_{l-1,l,2,2} & \dots & P_{l-1,l,2,N_l} \\ \dots & \dots & \dots & \dots \\ P_{l-1,l,N_{l-1},1} & P_{l-1,l,N_{l-1},2} & \dots & P_{l-1,l,N_{l-1},N_l} \end{pmatrix}, 3 \leq l \leq 5. \quad (2)$$

Матрицы  $\mathbf{P}_{l \times l}^*$  отличаются от матриц  $\mathbf{P}_{l-1 \times l}$  тем, что они содержат вероятности отнесения представленных на первом уровне  $i_1$ -ых ТМП к  $i_l$ -ым ситуациям функционирования СТС на более высоком  $l$ -ом уровне иерархии через модели  $\mathbf{M}_{1,l,i_j,i_j}$ .

Начальные значения элементов матрицы вероятностей переходов  $\mathbf{P}_{l-1 \times l}$  вида (2) определяются на основе экспертных знаний разработчиков СТС через модельные временные ряды ТМП в различных ситуациях функционирования СТС, а также на основе статистики отказов СТС по результатам сообщений о неисправностях и испытаний однотипных СТС [6, 32, 33]. В процессе обучения байесовской сети на реальных данных ТМИ о функционировании СТС матрицы  $\mathbf{P}_{l-1 \times l}$  подлежат коррекции.

Вектора  $\mathbf{P}_l^* = [P_{l,i_j}^*]$  характеризуют вероятности появления  $i_l$ -ых ситуаций функционирования СТС на каждом  $l$ -ом уровне иерархии. При этом справедливы следующие соотношения:

$$\begin{cases} \mathbf{P}_5^* = \mathbf{P}_4^* \mathbf{P}_{4 \times 5} \\ \mathbf{P}_4^* = \mathbf{P}_3^* \mathbf{P}_{3 \times 4} \\ \mathbf{P}_3^* = \mathbf{P}_2^* \mathbf{P}_{2 \times 3} \end{cases}, \begin{cases} \mathbf{P}_5^* = \mathbf{P}_1^* \mathbf{P}_{1 \times 5}^* \\ \mathbf{P}_4^* = \mathbf{P}_1^* \mathbf{P}_{1 \times 4}^* \\ \mathbf{P}_3^* = \mathbf{P}_1^* \mathbf{P}_{1 \times 3}^* \\ \mathbf{P}_2^* = \mathbf{P}_1^* \mathbf{P}_{1 \times 2}^* \end{cases}. \quad (3)$$

Соотношения (3) описывают различные варианты взаимосвязи ТМП и ситуаций функционирования СТС на различных уровнях ее иерархической структуры и являются основой агрегирования

разнородной информации, полученной по результатам обработки ТМП и знаний экспертов. Они предполагают равенство вероятностей достижения одних и тех же узлов дискретной байесовской сети прямым способом – с первого уровня на  $l$ -ый уровень – вследствие наличия ТМП, непосредственно связанных с соответствующими ситуациями функционирования СТС, и опосредованно – через узлы дискретной байесовской сети меньшего уровня иерархии – при наличии ТМП, характеризующих ситуации функционирования СТС косвенным образом.

С учетом обобщения соотношений (3) получим ограничения на значения вероятностей возникновения ситуаций функционирования на каждом уровне иерархии представления СТС в виде равенств:

$$\begin{cases} \mathbf{P}_{l_1}^* = \mathbf{P}_{l_1-1}^* \mathbf{P}_{l_1-1 \times l_1}, & 3 \leq l_1 \leq 5 \\ \mathbf{P}_{l_2}^* = \mathbf{P}_1^* \mathbf{P}_{1 \times l_2}^*, & 2 \leq l_2 \leq 5 \end{cases}, \quad (4)$$

где  $l_1$  и  $l_2$  – номера уровней иерархии.

В процессе обучения модели распознавания ситуаций функционирования СТС на основе дискретной байесовской сети необходимо обеспечить максимальное значение апостериорных вероятностей возникновения заданных  $j_l$ -ых ситуаций функционирования СТС на выходе каждого  $l$ -го уровня иерархии:

$$\begin{cases} P_{l,j_l}^*(\mathbf{P}_{l-1 \times l_1}^*, \mathbf{P}_{1 \times l_2}^*) = 1 - \sum_{\substack{i=1, \\ i \neq j_l}}^{N_l} P_{l,i}(\mathbf{P}_{l-1 \times l_1}^*, \mathbf{P}_{1 \times l_2}^*) \prod_{\substack{r=1, \\ r \neq i}}^{N_l} (1 - P_{l,r}(\mathbf{P}_{l-1 \times l_1}^*, \mathbf{P}_{1 \times l_2}^*)) \\ \{\mathbf{P}_{l-1 \times l_1}^*, \mathbf{P}_{1 \times l_2}^*\}_{opt} = \arg \max_{\mathbf{P}_{l-1 \times l_1}^*, \mathbf{P}_{1 \times l_2}^*} P_{l,j_l}^* \end{cases}, \quad (5)$$

где  $\{\mathbf{P}_{l-1 \times l_1}^*, \mathbf{P}_{1 \times l_2}^*\}_{opt}$  – скорректированные матрицы вероятностей переходов, позволяющие получить максимальное значение апостериорной вероятности на выходе каждого  $l$ -го уровня агрегированной модели.

Для принятия решений при техническом диагностировании СТС внешней подсистемой технического диагностирования наиболее предпочтительным является критерий Вальда. Это обусловлено особенностью процесса отработки и анализа «тяжелых» отказов СТС, характеризующегося непрерывным «исследованием» неисправной СТС и получением внешней подсистемой технического

диагностирования дополнительной ТМИ для оценки ее технического состояния. В этой связи критерий Вальда можно считать критерием, наиболее адекватным существующим особенностям процесса диагностирования СТС. Это согласуется с оценками экспертов по техническому диагностированию СТС и находит свое выражение в широком использовании данного критерия при техническом диагностировании КА [34].

Для реализации принятия решений по критерию Вальда в агрегированной модели, представленной на рисунке 1, на выходе пятого уровня модели используется  $N_5$  пороговых устройств, на которые поступают условные вероятности возникновения соответствующих РС из базы данных СТС. В каждое  $i_5$ -ое пороговое устройство вводятся два порога  $a_{i_5}$  и  $b_{i_5}$ , которые обеспечивают заданный уровень ошибок первого и второго рода при распознавании соответствующей ситуации функционирования СТС. В зависимости от значения вероятностей  $P_{i_5,k}$  на выходе пятого уровня по факту пересечения нижнего или верхнего порога, принимается решение об  $i_5$ -ой ситуации функционирования СТС. После того, как по всем возможным  $i_5$ -ым альтернативам получены значения условных вероятностей  $P_{i_5,k}$ , осуществляется принятие решения в пользу одной или нескольких наиболее вероятных согласно критерию максимума апостериорной вероятности ситуаций функционирования СТС.

Использование критерия Вальда расширяет перечень настраиваемых параметров пятого уровня агрегированной модели развития ситуаций функционирования СТС параметрами пороговых устройств  $a_1, \dots, a_{N_5}, b_1, \dots, b_{N_5}$ . При этом решение на выходе пятого уровня по всем альтернативам не будет сформировано до тех пор, пока не будет решения по каждой альтернативе на основе критерия Вальда. Поскольку матрицы (1) и (2) являются сильно разреженными и имеются ограничения на значения вероятностей каждого уровня иерархии в виде равенств (4), то существует нелинейная зависимость апостериорной вероятности принятия решения в пользу  $i_5$ -ой ситуации функционирования от установленных пороговых значений. Становится возможной структурная оптимизация уровня подсистем агрегированной модели. При этом наиболее адекватными методами настройки элементов матриц (2) и коррекции элементов матриц (1) являются методы стохастической оптимизации [35,36].

Стохастическое обучение дискретной байесовской сети представляет собой процедуру «обучения с учителем» и включает два взаимосвязанных процесса. Это процесс оптимизации элементов

матриц (2) и коррекции матриц (1) по критерию максимума апостериорной вероятности на выходе каждого уровня СТС, а также процесс коррекции матриц (2) через обратную связь и матрицы (1), полученные в результате обработки ТМП. Результатом процесса обучения является агрегирование экспертной информации и результатов обработки ТМП в виде обновленных матриц (1) и (2), а также новые приобретенные возможности по распознаванию типовых ситуаций функционирования из базы данных СТС и локализации неисправных аппаратных модулей. Уточненные экспертные знания в виде матриц (2) могут быть использованы для решения задачи диагностирования СТС при отсутствии отдельных ТМП или при наличии значительных пропусков значений во временных рядах ТМП. Для обучения используются ситуации функционирования элементов СТС на каждом уровне сети и матрицы вторичных вероятностных признаков (1), полученные в ходе обработки ТМП, содержимое которых в процессе обучения лишь незначительно корректируется.

Решение задачи (5) осуществляется, исходя из целевой функции:

$$E_1(\mathbf{P}_{1 \times l_1}, \mathbf{P}_{1 \times l_2}^*, a_1 \dots a_{N_5}, b_1 \dots b_{N_5}) = \frac{\sum_{l=2}^5 \sum_{j_l=1}^{N_l} |P_{l,j_l}^*(\mathbf{P}_{1 \times l_1}) - P_{l,j_l}^*(\mathbf{P}_{1 \times l_2}^*)|}{\sum_{l=2}^5 \sum_{j_l=1}^{N_l} P_{l,j_l}^*}. \quad (6)$$

В выражении (6) для целевой функции  $E_1$  числитель определяет сумму всех невязок между апостериорными значениями вероятностей на выходе каждого уровня иерархии, полученных на основе экспертных оценок вероятностей переходов, и оценок соответствующих вероятностей, полученных по результатам обработки ТМП. Знаменатель представляет собой сумму всех апостериорных вероятностей возникновения  $j_l$ -ых ситуаций функционирования СТС на выходе каждого  $l$ -го уровня иерархии дискретной байесовской сети, связанных с анализируемой рассмотренной ситуацией функционирования из базы данных СТС.

Целевая функция  $E_1$ , определяемая выражением (6), позволяет выполнить условие максимизации апостериорной вероятности правильного распознавания ситуаций функционирования СТС при ограничениях в виде равенств (4) с учетом использования критерия Вальда:

$$\left( \mathbf{P}_{1-1 \times l_1}, \mathbf{P}_{1 \times l_2}^* \right)_{opt} = \arg \min_{\substack{\mathbf{P}_{1-1 \times l_1}, \mathbf{P}_{1 \times l_2}^* \\ a_1 \dots a_{N_5}, \\ b_1 \dots b_{N_5}}} E_1(\mathbf{P}_{1-1 \times l_1}, \mathbf{P}_{1 \times l_2}^*) \left. \begin{array}{l} \mathbf{P}_{1 \times l_2}^* \in [P_{1 \times l_2, \min}, P_{1 \times l_2, \max}] \\ \mathbf{P}_{1-1 \times l_1} \in [P_{1-1 \times l_1, \min}, P_{1-1 \times l_1, \max}] \\ 3 \leq l_1 \leq 5, 2 \leq l_2 \leq 5, \end{array} \right\} \quad (7)$$

Задача (7) решается при заданных допусках  $[P_{1 \times l_2, \min}, P_{1 \times l_2, \max}]$ ,  $[P_{1-1 \times l_1, \min}, P_{1-1 \times l_1, \max}]$  на значения варьируемых вероятностей переходов дискретной байесовской сети, определяемых разработчиками по результатам моделирования, проведения различного рода испытаний и эксплуатации СТС. При этом интервал допустимых вторичных вероятностных признаков  $[P_{1 \times l_2, \min}, P_{1 \times l_2, \max}]$  значительно меньше, чем интервал  $[P_{1-1 \times l_1, \min}, P_{1-1 \times l_1, \max}]$ .

Результатом решения задачи оптимизации (6) является уточненный набор вероятностей межуровневых переходов дискретной байесовской сети и переходов с первого уровня на остальные уровни. Для оценки качества решения задачи технического диагностирования, распознавания ситуаций функционирования СТС, используется показатель достоверности принятия решения в пользу  $j_5$ -ой ситуации  $D_{j_5}$ , определяемой на основе полной группы возможных решений на выходе пятого уровня дискретной байесовской сети:

$$D_{j_5} = 1 - \sum_{\substack{\xi=1, \\ \xi \neq j_5}}^{N_5} P_{\xi} \prod_{\substack{r=1, \\ r \neq \xi}}^{N_5} (1 - P_r). \quad (8)$$

Значение показателя достоверности диагностирования СТС  $D_{j_5}$  для внешней системы контроля и диагностирования должно быть выше значения показателя достоверности диагностирования СТС встроенной системой контроля, которое задается в эксплуатационно-технической документации на СТС. Достаточность достижения требуемой достоверности диагностирования СТС можно определить через заданную надежность функционирования СТС, которая также определена нормативными документами [6].

Важным достоинством предлагаемого подхода является возможность обучения дискретной байесовской сети на типовых

значениях вероятностей переходов  $\mathbf{P}_{l-1 \times l_1}$  и  $\mathbf{P}_{1 \times l_2}^*$  из заданных допусков  $\left[ P_{l \times l_2, \min}, P_{l \times l_2, \max} \right]$  и  $\left[ P_{l_1-1 \times l_1, \min}, P_{l_1-1 \times l_1, \max} \right]$ , определяемых экспертами, даже в отсутствии реальной ТМИ. Это важно на начальном этапе применения диагностической модели и эксплуатации СТС. Для практической реализации стохастического обучения рассмотренной дискретной байесовской сети в модели использован рандомизированный алгоритм стохастической аппроксимации, который применяется при решении задач многопараметрической оптимизации с большим количеством настраиваемых параметров и сильно разреженными матрицами настраиваемых параметров (матрицы  $\mathbf{P}_{l_1-1 \times l_1}$  и  $\mathbf{P}_{1 \times l_2}^*$ ) [35,36].

Полученные с помощью модели дискретной байесовской сети вероятности достижения вершин на каждом уровне иерархии  $\mathbf{P}_l^*$  можно рассматривать как обобщенные параметры состояния аппаратных модулей и подсистем СТС. Их можно использовать для решения задачи локализации проблемных функциональных узлов СТС, функционирование которых с наибольшей вероятностью отличается от штатного. С этой целью необходимо проанализировать вероятность достижения вершины графа состояний на каждом уровне иерархии и соотнести эту вероятность с вероятностью достижения вершины, характеризующей штатное функционирование данного элемента СТС. При этом на каждом уровне иерархии решается задача поиска множества  $\{j_{l,nc}, P_{l,j_{l,nc}}^*\}$  номеров вершин, соответствующих нештатным ситуациям функционирования СТС, и вероятностей их достижения

$$P_{l,j_{l,nc}}^* = \arg \max_{P_{l,j_l}^*} E_{2,l,j_l} (P_{l,j_l}^*, P_{l,j_l,шф}^*), \forall j_l, \quad (9)$$

с максимизацией целевой функции

$$E_{2,l,j_l} = (P_{l,j_l}^* - P_{l,j_l,шф}^*) / P_{l,j_l,шф}^*. \quad (10)$$

В выражения (9) и (10) входят следующие вероятности:  $P_{l,j_l,шф}^*$  – вероятность достижения  $j_l$ -ой вершины сети на уровне  $l$ , характеризующая ситуацию штатного функционирования СТС,  $P_{l,j_l}^*$  –

вероятность достижения  $j_l$ -ой вершины сети на уровне  $l$ , характеризующая текущую ситуацию функционирования СТС,  $P_{l,j_l,nc}^*$  – вероятность достижения  $j_l$ -ой вершины сети на уровне  $l$ , характеризующая ситуацию нештатного функционирования СТС.

Для нормально функционирующих СТС решение задачи (9) и анализ изменения обобщенных параметров  $P_{l,j_l,nc}^*$  во времени по результатам нескольких процедур технического диагностирования позволит выявить негативные тенденции в изменении технического состояния СТС и своевременно их парировать.

Представленное формализованное описание процесса технического диагностирования СТС по результатам обработки полных потоков ТМИ отражает направление совершенствования методов углубленного анализа технического состояния СТС, направленное на повышение достоверности их диагностирования и, тем самым, поддержание требуемой надежности функционирования. Не менее важным направлением обеспечения требуемой надежности функционирования СТС является автоматизация рассмотренного процесса технического диагностирования СТС и достижение требуемой оперативности углубленного анализа, определяемой периодичностью съема и обработки полных потоков ТМИ и временем принятия решения по управлению СТС.

**4. Формализованное описание нелинейных динамических моделей изменения ТМП СТС с использованием искусственных нейронных сетей.** Математический аппарат искусственных нейронных сетей позволяет реализовать нелинейные динамические модели изменения ТМП  $\{M_{v,p}\}$  в широком диапазоне ситуаций функционирования аппаратных модулей и подсистем СТС. Их использование дает возможность повысить достоверность распознавания ситуаций функционирования СТС в условиях значительной неопределенности значений и существенно нелинейного характера изменения ТМП при возникновении нештатных ситуаций. При этом, как показывает теория и практика применения искусственных нейронных сетей для решения задач обработки временных рядов ТМП, достаточным является использование классических нейронных сетей с двумя скрытыми слоями [21, 24].

В простейшем случае модели изменения ТМП  $\{M_{1,l,i_1,i_l}\}$  могут быть заданы набором допусков  $[D_{n,i_1,i_l}; D_{v,i_1,i_l}]$ , в пределах которых изменяются  $i_1$ -ые ТМП в  $i_l$ -ых ситуациях функционирования аппаратных модулей и подсистем СТС. В предположении гауссовской

статистики значений ТМП, вероятность  $P_{1,l,i_1,i_l}$  отнесения  $i_1$ -го ТМП к  $i_l$ -ой ситуации функционирования определяется выражением:

$$P_{1,l,i_1,i_l} = \Phi\left(\frac{D_{в,i_1,i_l} - \bar{x}_{i_1}}{\sigma_{i_1}}\right) - \Phi\left(\frac{D_{н,i_1,i_l} - \bar{x}_{i_1}}{\sigma_{i_1}}\right), \quad (11)$$

где  $\bar{x}_{i_1}$  – математическое ожидание  $i_1$ -го анализируемого ТМП;  $\sigma_{i_1}$  – среднеквадратическое отклонение значений  $i_1$ -го анализируемого ТМП от математического ожидания  $\bar{x}_{i_1}$ ;  $[D_{н,i_1,i_l}; D_{в,i_1,i_l}]$  – доверительный интервал (допуск) на значения  $i_1$ -го ТМП в  $i_l$ -ой ситуации функционирования аппаратных модулей и подсистем СТС, определяемый в соответствии со статистическими критериями с доверительной вероятностью  $P_{\text{дов}}$  через модельные значения среднеквадратического отклонения  $\sigma_{i_1,i_l}$  и математического ожидания  $\bar{x}_{i_1,i_l}$   $i_1$ -го ТМП в  $i_l$ -ой ситуации функционирования;  $D_{н,i_1,i_l}$ ,  $D_{в,i_1,i_l}$  – нижняя и верхняя границы допуска на значения  $i_1$ -го ТМП в  $i_l$ -ой ситуации функционирования соответственно;

$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_0^x \exp\left(-\frac{x^2}{2}\right) dx$  – функция Лапласа. Величина  $P_{\text{дов}}$

определяется исходя из требуемых достоверности контроля технического состояния и надежности функционирования СТС [37].

В качестве моделей  $\{M_{1,l,i_1,i_l}\}$  также могут быть использованы нелинейные динамические модели изменения ТМП в проекциях их фазового пространства с реализацией парциальной нелинейной фильтрации [38]. В данной статье для разработки нелинейных моделей  $\{M_{1,l,i_1,i_l}\}$  используются искусственные нейронные сети.

Структурная схема нейросетевой модели изменения ТМП в виде многослойной нейронной сети представлена на рисунке 2.

Входной вектор  $X_{1,l,i_1,i_l,\varphi}$  нейронной сети содержит значения дискретных отсчетов  $i_1$ -ых ТМП в  $i_l$ -ых ситуациях функционирования СТС в пределах  $\varphi$ -го «окна наблюдения» длины  $L$  дискретных отсчетов:

$$X_{1,l,i_1,i_l,\varphi} = [x_{1,l,i_1,i_l,k}, x_{1,l,i_1,i_l,k-1}, \dots, x_{1,l,i_1,i_l,k-L+1}].$$

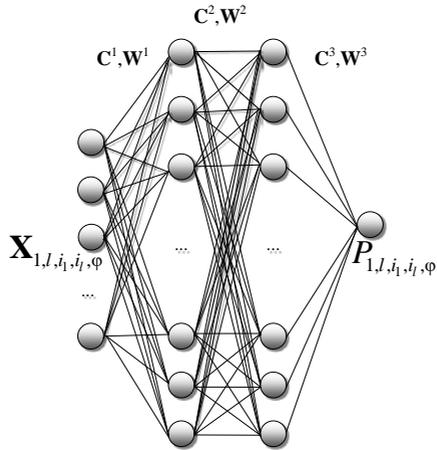


Рис. 2. Структурная схема нейросетевой модели изменения ТМП в заданной ситуации функционирования СТС

Каждый слой нейронной сети характеризуется матрицей весовых коэффициентов  $\mathbf{W}^\mu$  и вектором смещений  $\mathbf{C}^\mu$ , где  $\mu$  – номер слоя,  $\mu=1\dots3$ . Выход сети имеет единичную размерность. Значение его, в ряде случаев, можно трактовать как условную вероятность отнесения текущего  $\varphi$ -го участка временной реализации  $i_l$ -го ТМП к  $i_l$ -ой ситуации функционирования аппаратных модулей и подсистем СТС  $P_{1,l,i_l,i_l,\varphi}$ . Функционирование представленной многослойной нейронной сети включает этапы обучения и применения.

На этапе обучения многослойных нейронных сетей минимизируется среднеквадратическая ошибка

$$E_{1,l,i_l,i_l} = \sum_{\varphi} \left( P_{1,l,i_l,i_l,\varphi} - P_{1,l,i_l,i_l,\text{зад}} \right)^2, \quad (12)$$

где  $P_{1,l,i_l,i_l,\text{зад}}$ ,  $P_{1,l,i_l,i_l,\varphi}$  – заданное и текущее значения вероятностей на выходе многослойной нейронной сети. Вероятности  $P_{1,l,i_l,i_l,\text{зад}}$  принимают единичное значение «1» – при предъявлении сети на этапе обучения  $\varphi$ -ых участков множества реализаций ТМП, соответствующих  $i_l$ -ой ситуации функционирования аппаратного модуля или подсистемы СТС. Нулевое значение «0» – они имеют при предъявлении сети на этапе обучения  $\varphi$ -ых участков множества

реализаций ТМП всех остальных ситуаций функционирования данного аппаратного модуля или подсистемы СТС, а также множества произвольных случайных реализаций, формируемых в пределах телеметрической шкалы на этапе обучения многослойной сети. Для обучения модели используется алгоритм наискорейшего спуска или алгоритм Левенберга-Марквардта [24].

На этапе применения многослойных нейронных сетей определяется выходное значение вероятности  $P_{1,l,i_1,i_l,\varphi}$ :

$$P_{1,l,i_1,i_l,\varphi} = \mathbf{f}\left(\mathbf{f}\left(\mathbf{f}\left(\mathbf{X}_{i_1,i_l,\varphi} \mathbf{W}^1 + \mathbf{C}^1\right) \mathbf{W}^2 + \mathbf{C}^2\right) \mathbf{W}^3 + \mathbf{C}^3\right), \quad (13)$$

где  $\mathbf{f}(\cdot)$  – нелинейный функционал преобразования вектора выходных значений каждого слоя, основанный на логистической функции активации. Для принятия решения о текущей ситуации функционирования аппаратного модуля или подсистемы СТС по  $i_1$ -ым ТМП с использованием нейросетевых моделей  $\{\mathbf{M}_{1,l,i_1,i_l}\}$  необходимо осуществить:

- перемещение «окна наблюдения» в пределах реализации каждого  $i_1$ -го ТМП по временной шкале;
- распознавание анализируемого  $\varphi$ -го участка временных рядов ТМП;
- накопление полученных результатов распознавания в пределах всей анализируемой временной реализации ТМП;
- нормализацию полученной суммы и получение вероятностей отнесения всей реализации  $i_1$ -го ТМП к каждой  $i_l$ -ой ситуации функционирования:

$$P_{1,l,i_1,i_l} = \frac{\sum_{\varphi} P_{1,l,i_1,i_l,\varphi}}{\sum_{i_l} \sum_{\varphi} P_{1,l,i_1,i_l,\varphi}}. \quad (14)$$

Полученные в результате моделирования вероятности  $P_{1,l,i_1,i_l}$  образуют матрицы вероятностей переходов многоуровневой иерархической модели на основе дискретной байесовской сети  $\mathbf{P}_{1 \times l}^*$  (1).

**5. Основные этапы реализации и результаты применения подхода к техническому диагностированию СТС с использованием моделей в виде гибридных сетевых структур.** Практическая

реализация предлагаемого подхода к техническому диагностированию СТС с использованием моделей в виде гибридных сетевых структур включает два этапа: обучение диагностического комплекса и его применение по назначению для технического диагностирования СТС.

На этапе обучения диагностического комплекса выполняются следующие шаги:

1. Получение статистической базы динамических реализаций  $i_1$ -ых ТМП в виде множества их значений  $\{x_{1,i_1}\}$  в  $i_1$ -ых ситуациях функционирования аппаратных модулей и подсистем СТС, а также реализаций ТМП, сформированных на основе знаний экспертов в области функционирования данной СТС. Разбиение экспертом всех данных полученной базы на три выборки: обучающую, проверочную и тестовую.

2. Формирование множества моделей изменения  $i_1$ -ых ТМП в  $i_1$ -ых ситуациях функционирования аппаратных модулей и подсистем СТС  $\{M_{1,l,i_1,i_1}\}$  на основе полученных реализаций ТМП  $\{x_{1,i_1}\}$  с использованием многослойных нейронных сетей и целевой функции (12).

3. Сопоставление реализаций ТМП  $\{x_{1,i_1}\}$  из обучающей, проверочной и тестовой выборок с полученными моделями их изменения  $\{M_{1,l,i_1,i_1}\}$  и формирование результатов данного сопоставления в виде множеств вторичных вероятностных признаков  $\{P_{1,l,i_1,i_1}\}_o$ ,  $\{P_{1,l,i_1,i_1}\}_n$  и  $\{P_{1,l,i_1,i_1}\}_t$  согласно (13) и (14).

4. Формирование структуры многоуровневой иерархической модели  $M_2$  на основе информации о взаимосвязях между ситуациями функционирования СТС на различных иерархических уровнях ее представления в виде дискретной байесовской сети.

5. Формирование множества вероятностей переходов  $\{P_{-1,l,i_1-1,i_1}\}$  между различными ситуациями функционирования СТС на всех иерархических уровнях ее представления, определение допустимых значений на изменение вероятностей переходов  $\left[ P_{1-1 \times l_1, \min} \cdot P_{1-1 \times l_1, \max} \right]$  и  $\left[ P_{1 \times l_2, \min} \cdot P_{1 \times l_2, \max} \right]$ ,  $3 \leq l_1 \leq 5$ ,  $2 \leq l_2 \leq 5$ , с использованием знаний экспертов в области функционирования СТС.

6. Ввод в дискретную байесовскую сеть полученных вторичных вероятностных признаков  $\{P_{1,l,i_1,i_1}\}_o$ , соответствующих обучающей выборке, а также начальных значений вероятностей  $\{P_{l-1,l,i_1-1,i_1}\}$  и

параметров пороговых устройств  $a_1, \dots, a_{N_5}, b_1, \dots, b_{N_5}$ .

7. Стохастическое обучение дискретной байесовской сети с использованием алгоритма стохастической аппроксимации в соответствии с целевой функцией  $E_1$  (6) и (7) и ограничениями в виде равенств (3) и (4). Получение в результате обучения множества вероятностей  $\{P_{l-1,l,i_{l-1},i_l}\}^*$  и параметров  $a^*_1, \dots, a^*_{N_5}, b^*_1, \dots, b^*_{N_5}$ .

8. Проверка результата обучения дискретной байесовской сети на множестве вторичных вероятностных признаков  $\{P_{1,l,i_l,i_l}\}_n$  проверочной выборки и множестве полученных в результате обучения вероятностей  $\{P_{l-1,l,i_{l-1},i_l}\}^*$ , вычисление значения целевой функции  $E_1$  вида (6). Если значение целевой функции  $E_1$  уменьшается в сравнении со значением, полученным на предыдущем цикле обучения, то фиксируются текущие параметры дискретной байесовской сети. Если количество циклов обучения не превысило заданного значения  $N_{\text{зад}}$ , то осуществляется выполнение шага 7, иначе – шага 9.

9. Проверка результата обучения дискретной байесовской сети на тестовой выборке  $\{P_{1,l,i_l,i_l}\}_T$  с использованием полученного в ходе обучения множества вторичных вероятностных признаков  $\{P_{l-1,l,i_{l-1},i_l}\}^*$ : вычисление выходных вероятностей на каждом слое дискретной байесовской сети  $\{P_{l,i}\}$ , оценка достоверности  $D_{j_5}$  принятия решения в пользу  $j_5$ -ой ситуации функционирования СТС в соответствии с выражением (8). Если значение  $D_{j_5}$  ниже заданного значения  $D_{\text{зад}}$ , то осуществляется переход к выполнению шага 7, иначе – завершение этапа обучения дискретной байесовской сети.

На этапе применения диагностического комплекса выполняются следующие шаги:

1. Получение новых реализаций  $i_1$ -ых ТМП в виде множества отсчетов временных рядов  $\{x_{1,i_l}\}$ .

2. Сопоставление полученных реализаций  $i_1$ -ых ТМП с моделями изменения ТМП  $\{M_{1,l,i_l,i_l}\}$  в  $i_l$ -ых ситуациях функционирования аппаратных модулей и подсистем СТС и формирование множества текущих вероятностных оценок данного сопоставления  $\{P_{1,l,i_l,i_l}\}$ .

3. Ввод в дискретную байесовскую сеть вероятностей  $\{P_{1,l,i_l,i_l}\}$ , а также вероятностей  $\{P_{l-1,l,i_{l-1},i_l}\}^*$  и параметров пороговых устройств

$a^*_{1}, \dots, a^*_{N_5}, b^*_{1}, \dots, b^*_{N_5}$ , полученных на этапе обучения.

4. Вывод информации о вероятностях ситуаций функционирования СТС на выходе дискретной байесовской сети  $P^*_{5,j_5}$ .

Определение наиболее вероятной ситуации функционирования СТС.

5. Определение значений обобщенных параметров  $P^*_{l,j_l,nc}$  элементов СТС и локализация наиболее проблемных из них, удовлетворяющих критерию (9).

6. Выявление тенденций развития негативных процессов изменения технического состояния СТС на основе анализа значений обобщенных параметров  $P^*_{l,j_l,nc}$ , полученных по результатам обработки полных потоков ТМИ при проведении последующих сеансов диагностирования и управления ее техническим состоянием.

В результате технического диагностирования СТС с использованием рассмотренной диагностической модели в виде гибридных сетевых структур возможны следующие исходы:

1. В одном или нескольких выходных узлах дискретной байесовской сети принято решение о наличии рассмотренной ситуации функционирования из базы данных СТС. Формируется объяснение результата распознавания ситуации функционирования в виде последовательности вершин графической модели  $\{P^*_{l,j_l,nc}\}$  на каждом уровне иерархического представления СТС и локализуется неисправный элемент СТС.

2. В выходных узлах дискретной байесовской сети не принято решение о рассмотренной ситуации функционирования из базы данных СТС. Осуществляется ранжирование вершин  $\{P^*_{l,j_l,nc}\}$  в соответствии с критерием (9) на каждом уровне иерархического представления СТС и локализуются наиболее проблемные элементы СТС.

3. На основе анализа выявленных проблемных элементов СТС и обобщенных параметров  $\{P^*_{l,j_l,nc}\}$  по результатам последующих сеансов диагностирования и управления техническим состоянием СТС формируется вывод о развитии негативных тенденций в изменении технического состояния и функционировании СТС.

В первом случае в результате технического диагностирования СТС осуществляется поддержка принятия решения во внешней системе управления СТС при реализации ситуационного управления ее техническим состоянием и повышается качество управления СТС с

точки зрения оперативности принятия решения. Во втором и третьем случае в результате технического диагностирования СТС выявляются возможные негативные тенденции в изменении технического состояния и функционирования СТС и проблемные элементы СТС, что позволяет реализовать перспективные способы проактивного управления СТС [8–10, 39].

Следует отметить, что при реализации предлагаемого подхода важная роль отводится экспертам в области функционирования СТС, разрабатывающим структуру дискретной байесовской сети и определяющим диапазоны изменения вероятностей переходов между ситуациями функционирования аппаратных модулей и подсистем в СТС. При этом существует три способа получения экспертных знаний о вероятностях переходов  $\{P_{l-1,i,l-1,i}\}$ . Первый способ основан на приблизительной оценке допустимых значений  $[P_{l-1 \times l_1, \min} \cdot P_{l-1 \times l_1, \max}]$ , исходя из анализа сообщений о неисправностях и результатов испытаний однотипных СТС. Второй способ основан на косвенной приблизительной оценке допустимых значений  $[P_{l-1 \times l_1, \min} \cdot P_{l-1 \times l_1, \max}]$  в ходе предварительного имитационного эксперимента и стохастического обучения сети, наполненной вероятностями переходов  $[P_{l \times l_2, \min} \cdot P_{l \times l_2, \max}]$ , полученных на основе модельных ТМП, заданных экспертами для различных ситуаций функционирования СТС. Третий способ основан на комбинировании обоих перечисленных способов.

**6. Результаты моделирования процесса технического диагностирования СТС на примере бортовой аппаратуры КА.** Проведено моделирование процесса технического диагностирования СТС с использованием предлагаемого подхода. В качестве объекта технического диагностирования рассматривалась бортовая система приема и передачи информации. В иерархическом представлении КА, как СТС, данная система относится к уровню функциональных систем КА. Поэтому модель технического диагностирования данной системы, в отличие от обобщенной модели, приведенной на рисунке 1, имеет более простую четырехуровневую структуру: ТМП, аппаратные модули, подсистемы, функциональная система. Пороговые устройства используются на выходе четвертого уровня модели, на которые поступают условные вероятности возникновения текущей ситуации функционирования системы приема и передачи информации. Моделирование работы дискретной байесовской сети осуществлялось

в среде имитационного моделирования AnyLogic [40].

На рисунке 3 представлено отображение диагностической модели системы приема и передачи информации в виде дискретной байесовской сети в среде AnyLogic. В модели учитываются 13 ТМП (вершины Q1\_1 – Q1\_13), полученные в ходе сеансов управления с КА. Временные реализации их преобразуются во вторичные вероятностные признаки ситуаций функционирования анализируемой системы, и 23 ситуации функционирования на всех уровнях формализованного описания функционирования системы в виде дискретной байесовской сети (вершины Q2\_1–Q4\_2). Выход дискретной байесовской сети представлен двумя вершинами, характеризующими штатное функционирование системы (вершина Q4\_1) и наличие нештатной ситуации (вершина Q4\_2). Диапазоны изменения вероятностей переходов  $\{P_{l-1,l,i_{l-1},i_l}\}$  и их начальные значения определены приближенно на основе логики функционирования аппаратуры. Для формирования вероятностей  $\{P_{l,l,i_l,i_l}\}$  отнесения ситуации функционирования системы приема и передачи информации КА на каждом уровне иерархии к типовым ситуациям функционирования по реализациям ТМП использованы динамические модели изменения ТМП на основе многослойных нейронных сетей. Размер «окна наблюдения» каждого ТМП варьировался от  $L=50$  до  $L=150$  отсчетов. Нейронные сети имели количество входных нейронов – от 50 до 100, количество скрытых слоев – 2, количество нейронов в каждом скрытом слое – 10, количество выходных нейронов – 1. При обучении нейронных сетей использованы критерий минимума среднеквадратической ошибки и алгоритм наискорейшего спуска [24].

Полученные значения вероятностей переходов  $\{P_{l,l,i_l,i_l}\}$  и  $\{P_{l-1,l,i_{l-1},i_l}\}$  загружались в дискретную байесовскую сеть, представленную на рисунке 3.

Стохастическое обучение сети реализовано на основе имитационного эксперимента, в ходе которого на вход модели дискретной байесовской сети в среде AnyLogic одновременно поступали заявки, распространяющиеся вдоль ее графа в соответствии с заданными вероятностями переходов. При этом происходила фиксация количества заявок, достигших каждой вершины на каждом уровне иерархии сети, и оценивались вероятности их достижения  $P_{l,l}^*$ . В ходе обучения модели происходило изменение вероятностей переходов в матрицах  $\mathbf{P}_{l-1 \times l}$  и осуществлялась коррекция вероятностей переходов в матрице  $\mathbf{P}_{l \times l}$  с целью оптимизации целевой функции (6)

при ограничениях в виде равенств (4) на основе алгоритма стохастической аппроксимации.

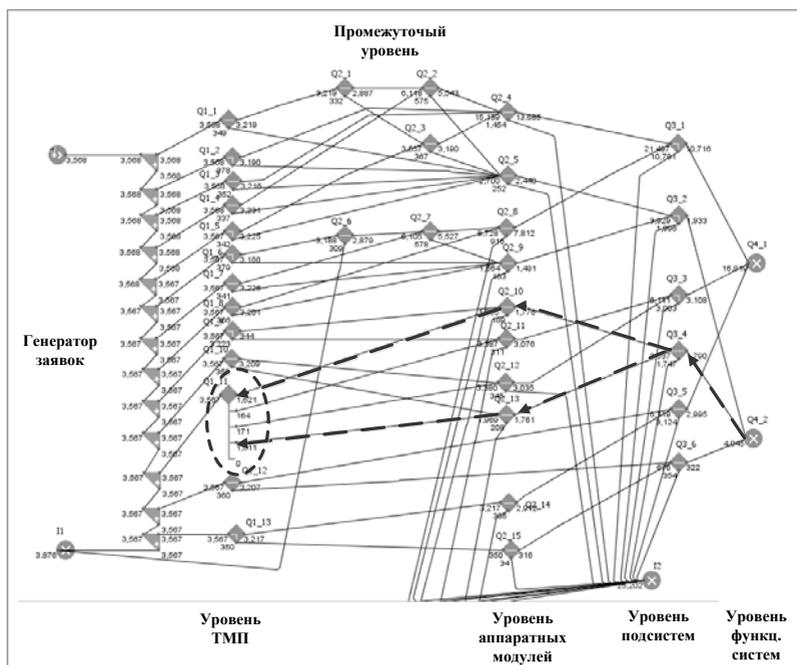


Рис. 3. Отображение в среде AnyLogic диагностической модели системы приема и передачи информации и результата локализации ее проблемного аппаратного модуля – источника вторичного электропитания приемника

Обученная модель позволила распознать рассмотренные ситуации штатного функционирования и нештатные ситуации системы приема и передачи информации на каждом уровне ее иерархии и решить задачу (9) локализации ее проблемных элементов. Кроме того, модель позволила выявить нерассмотренную ситуацию функционирования анализируемой системы и локализовать проблемный аппаратный модуль – источник вторичного электропитания приемника, характеризуемый нестабильностью напряжения питания и изменением его значения вблизи нижней границы допуска. На рисунке 3 пунктирной линией показан результат локализации данного аппаратного модуля, связанного со следующими вершинами диагностической сети: Q4\_2, Q3\_4, Q2\_10, Q2\_13, Q1\_11.

На рисунке 4 представлены результаты распознавания ситуаций

функционирования одного из элементов приемника системы приема и передачи информации – аппаратного модуля шумовой автоматической регулировки усиления (ШАРУ) по одному из ее ТМП – «Напряжение регулировки». На рисунке 4а представлены значения вероятностей  $P_{1,l,i\hat{i}}$  отнесения реализации анализируемого ТМП «Напряжение регулировки» к ситуациям функционирования «Штатное функционирование» (номер ситуации – 1) и «Обрыв в цепи обратной связи» (номер ситуации – 2), полученные с использованием метода допусков (столбцы 1) и на основе нейросетевой динамической модели изменения ТМП (столбцы 2) в отсутствии возмущений и шумов.

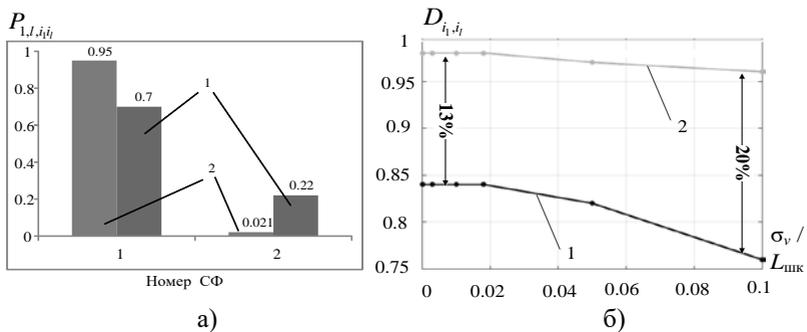


Рис. 4. Результаты распознавания ситуаций функционирования аппаратного модуля ШАРУ приемника системы приема и передачи информации по одному из ее ТМП – «Напряжение регулировки»: а) значения вероятностей отнесения реализации анализируемого ТМП «Напряжение регулировки» к ситуациям функционирования «Штатное функционирование» (номер ситуации – 1) и «Обрыв в цепи обратной связи» (номер ситуации – 2) б) зависимости показателя достоверности принятия решения о возможных ситуациях

На рисунке 4б представлены зависимости показателя достоверности  $D_{i,i\hat{i}}$  принятия решения о возможных  $i$ -ых ситуациях функционирования для рассмотренного аппаратного модуля ШАРУ.

Приведенные зависимости показателя достоверности  $D_{i,i\hat{i}}$  от величины  $\sigma_v / L_{шк}$  получены по результатам формирования вторичных вероятностных признаков для каждой ситуации функционирования аппаратного модуля ШАРУ на основе определения принадлежности ТМП «Напряжение регулировки» допускам (кривая 1) и на основе нейросетевых динамических моделей изменения ТМП (кривая 2).

На рисунке 5 представлены результаты распознавания ситуации

функционирования системы приема и передачи информации по совокупности ее 13 ТМП. На рисунке 5а представлена экспериментальная зависимость изменения нормированных значений целевой функции (6) от дискретного времени  $k$  обучения байесовской сети. На рисунке 5б представлены зависимости показателя достоверности  $D_{j_4}$  распознавания анализируемой ситуации функционирования системы приема и передачи информации по совокупности ТМП с использованием дискретной байесовской сети в условиях динамических возмущений во временных рядах ТМП от параметра среднеквадратического отклонения гауссовского возмущения  $\sigma_v$ , нормированного к шкале ТМП  $L_{\text{шк}}$ .

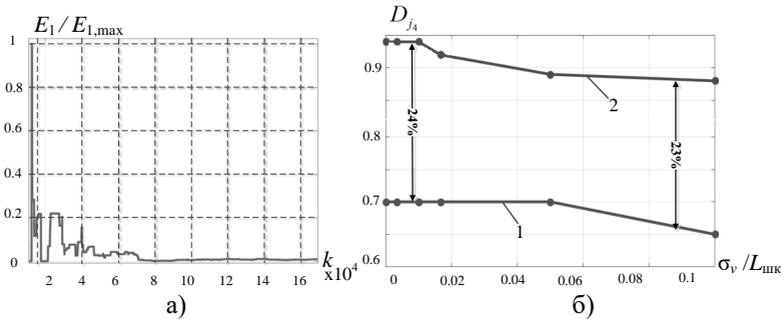


Рис. 5. Результаты распознавания ситуации функционирования системы приема и передачи информации по совокупности ее ТМП:  
 а) экспериментальная зависимость изменения нормированных значений целевой функции (6) от дискретного времени  $k$  обучения байесовской сети;  
 б) зависимости показателя достоверности распознавания анализируемой ситуации

В результате моделирования показана возможность получения выигрыша до 20% в достоверности распознавания ситуаций функционирования анализируемой функциональной системы КА при использовании в диагностической сети нейросетевых моделей изменения ТМП в сравнении с моделями на основе допусков. Нейросетевые модели, реализующие квазиоптимальную фильтрацию отдельных ТМП, позволили повысить достоверность распознавания ситуаций функционирования аппаратных модулей бортовой аппаратуры при увеличении интенсивности помех, действующих в радиоканале передачи ТМИ с КА, а также при наличии существенных возмущений и нелинейного характера временных рядов ТМП, характеризующих некоторые нештатные ситуации.

**7. Заключение.** Предложенный подход к техническому диагностированию СТС соответствует многомодельному описанию процессов их функционирования на различных иерархических уровнях представления и гибридному построению интеллектуальных систем обработки информации, предполагающему совместное использование подсистем статистического распознавания и логико-вероятностного вывода. Практическая реализация рассмотренных моделей в диагностических комплексах СТС различного назначения позволяет эффективно решать комплекс взаимосвязанных задач их технического диагностирования:

- обработки полных потоков ТМИ и отнесения текущей ситуации функционирования к множеству известных штатных и нештатных ситуаций из базы данных СТС;

- обнаружения ситуаций функционирования, не рассмотренных в базе данных СТС;

- уточнения штатной ситуации функционирования при ошибочном диагностировании СТС встроенными средствами технического диагностирования;

- локализации неисправных и проблемных элементов с выдачей во внешние системы контроля и технического диагностирования и управления СТС предложений по их детальному исследованию;

- выявления негативных тенденций в изменении технического состояния СТС по результатам локализации наиболее проблемных элементов.

Дальнейшее развитие рассмотренного подхода к техническому диагностированию СТС связано с поиском адекватного математического аппарата для разработки динамических моделей изменения ТМП, позволяющих достичь более выраженных максимумов гистограммы распределения вероятностей отнесения реализаций ТМП к возможным ситуациям функционирования отдельных аппаратных модулей и подсистем СТС.

### **Литература**

1. Поспелов Д.А. Ситуационное управление: теория и практика // М.: Едиториал УРСС. 2021. 288 с.
2. Мостовой Я.А. Управление сложными техническими системами: конструирование программного обеспечения спутников ДЗЗ // М.: Техносфера. 2016. 352 с.
3. Александровская Л. Н. Современные методы обеспечения безопасности сложных технических систем: учебник // М.: Логос. 2001. 208 с.
4. Кирилин А.Н., Ахметов Р.Н., Сологуб А.Н., Макаров В.П. Методы обеспечения живучести низкоорбитальных автоматических космических аппаратов

- зондирования Земли: математические модели, компьютерные технологии // М.: Машиностроение. 2010. 384 с.
5. Carlton A., Morgan R., Lohmeyer W., Cahoy K. Telemetry Fault-Detection Algorithms: Applications for Spacecraft Monitoring and Space Environment Sensing // *Journal of Aerospace Information Systems*. 2018. vol. 15. no. 5. pp. 239–252.
  6. Мальцев Г.Н., Назаров А.В., Якимов В.Л. Исследование процесса диагностирования бортовой аппаратуры автоматических космических аппаратов с использованием дискретно-событийной имитационной модели // *Труды СПИИРАН*. 2018. Вып. 1(56). С. 95–121.
  7. Hassanien A.E., Darwish A., Abdelghafar S. Machine learning in Telemetry Data Mining of Space Mission: Basics, Challenging and Future Directions // *Artificial Intelligence Review*. 2020. vol. 53. no. 5. pp. 3201–3230.
  8. Bakhmut A.D., Krylov A.V., Okhtilev M.Y. Proactive Management of Complex Objects Using Precedent Methodology // *Advances in Intelligent Systems and Computing*. 2019. vol. 764. pp. 298–307.
  9. Bakhmut A.D., Ustinov A.V., Koromyshlichenko V.N. and oth. Methods of Conceptual Modeling of Intelligent Decision Support Systems for Managing Complex Objects at All Stages of its Life Cycle // *Advances in Intelligent Systems and Computing*. 2019. vol. 875. pp. 171–180.
  10. Охтилев М.Ю., Мустафин Н.Г., Миллер В.Е., Соколов Б.В. Концепция проактивного управления сложными объектами: теоретические и технологические основы // *Известия высших учебных заведений. Приборостроение*. 2014. Т. 57. № 11. С. 7–15.
  11. Titkanloo H.N., Keramati A., Fekri R. Data Aggregation in Multi-Source Assessment Model Based on Evidence Theory // *Applied Soft Computing*. 2018. vol. 69. pp. 443–452.
  12. Luger G. *Artificial Intelligence: Structure and Strategies for Complex Problem Solving*. 5th ed. // Harlow: Addison Wesley. 2005. 903 p.
  13. Burnham K.P. *Model Selection and Multimodel Inference: a Practical Informationtheoretic Approach* // New York: Springer. 2002. 488 p.
  14. Микони С.В., Соколов Б.В., Юсупов Р.М. Квалиметрия моделей и полимодельных комплексов // М.: РАН. 2018. 314 с.
  15. Лоскутов А.И., Бянкин А.А., Семенюк Д.Б., Клыков В.А. Методика синтеза математической модели функционирования бортовой радиоэлектронной аппаратуры объектов ракетно-космической техники на основе полимодельного подхода // *Приборы и системы. Управление, контроль, диагностика*. 2019. № 9. С. 27–36.
  16. Шмелёв В.В., Самойлов Е.Б., Саноцкая Н.А. Полимодельный комплекс интеллектуального мониторинга состояния технических систем с компенсацией возмущающих факторов // *T-Comm: Телекоммуникации и транспорт*. 2018. Т. 12. №8. С. 44–51.
  17. Jimenez J., Schwartz S., Vingerhoeds R., Grabot B. Towards Multi-Model Approaches to Predictive Maintenance: A Systematic Literature Survey on Diagnostics and Prognostics // *Journal of Manufacturing Systems*. 2020. vol. 56. pp. 539–557.
  18. Zhang P., Li T., Wang G., Luo C. Multi-Source Information Fusion Based on Rough Set Theory: A Review // *Information Fusion*. 2021. vol. 68. pp. 85–117.
  19. Li Z., Tian L., Jiang Q., Yan X. Fault Diagnostic Method Based on Deep Learning and Multimodel Feature Fusion for Complex Industrial Processes // *Industrial & Engineering Chemistry Research*. 2020. vol. 59. pp. 18061–18069.

20. Shahraki A.F., Yadav O.P., Liao H. A Review on Degradation Modelling and Its Engineering Applications // *International Journal of Performability Engineering*. 2017. vol. 13. pp. 299–314.
21. Якимов В.Л. Прогнозирование параметров технического состояния стартового комплекса с использованием нейронных сетей // *Известия высших учебных заведений. Приборостроение*. 2006. № 7. С. 7–10.
22. Marushko E.E., Doudkin A.A. Ensembles of Neural Networks for Forecasting of Time Series of Spacecraft Telemetry // *Optical Memory and Neural Networks*. 2017. vol. 26. no. 1. pp. 47–54.
23. Емельянова Ю.Г., Фраленко В.П. Методы когнитивно-графического представления информации для эффективного мониторинга сложных технических систем // *Программные системы: теория и приложения*. 2018. Т. 9. № 4(39). С. 117–158.
24. Мальцев Г.Н., Назаров А.В., Якимов В.Л. Алгоритм максимизации энтропии обучающей выборки и его использование при разработке прогнозной модели дискретных состояний нелинейной динамической системы // *Информационно-управляющие системы*. 2015. № 2. С. 57–66.
25. Preece A. Asking «Why» in AI: Explainability of Intelligent Systems – Perspectives and Challenges // *Intelligent Systems in Accounting, Finance and Management*. 2018. vol. 25. pp. 63–72.
26. Marcot B.G., Penman T.D. Advances in Bayesian Network Modelling: Integration of Modelling Technologies // *Environmental Modelling and Software*. 2019. vol. 111. pp. 386–393.
27. Chen J., Pi D., Wu Z., Zhao X. Imbalanced Satellite Telemetry Data Anomaly Detection Model Based on Bayesian LSTM // *Acta Astronautica*. 2021. vol. 180. pp. 232–242.
28. Масленников Е.Д., Сулимов В.Б. Предсказания на основе байесовских сетей доверия: алгоритм и программная реализация // *Вычислительные методы и программирование*. 2010. Т. 11. № 4. С. 94–107.
29. Мусина В.Ф. Байесовские сети доверия как вероятностная графическая модель для оценки медицинских рисков // *Труды СПИИРАН*. 2013. Вып. 1(24). С. 135–151.
30. Gao X., Guo Z., Ren H., Yang Y. Learning Bayesian Network Parameters Via Minimax Algorithm // *International Journal of Approximate Reasoning*. 2019. vol. 108. pp. 62–75.
31. Торопова А.В. Подходы к диагностике согласованности данных в байесовских сетях доверия // *Труды СПИИРАН*. 2015. Вып. 6(43). С. 156–178.
32. Смирнов В.А. Поиск неисправностей в бортовых системах управления в процессе приемочного контроля // *Информационно-управляющие системы*. 2013. № 2. С. 24–28.
33. Ларин В.П., Шелест Д.К. Формирование информационного обеспечения надежности бортовой аппаратуры на стадии проектирования // *Информационно-управляющие системы*. 2012. № 4. С. 93–97.
34. Ахметов Р.Н. Методы и модели автономного управления живучестью автоматических космических аппаратов дистанционного зондирования Земли // *Вестник Самарского государственного аэрокосмического университета*. 2008. № 2. С. 194–210.
35. Kresoja M., Luzanin Z., Stojkovska I. Adaptive Stochastic Approximation Algorithm // *Numerical Algorithms*. 2017. vol. 76. pp. 917–937.
36. Граничин О.Н., Измакова О.А. Рандомизированный алгоритм стохастической аппроксимации в задаче самообучения // *Автоматика и телемеханика*. 2005. № 8. С. 52–63.

37. Wangab D., Tiana L. Parametric Methods for Confidence Interval Estimation of Overlap Coefficients // *Computational Statistics & Data Analysis*. 2017. vol. 106. pp. 12–26.
38. Мальцев Г.Н., Якимов В.Л., Соловьев С.В., Лебедева Н.В. Первичная обработка телеметрической информации с использованием динамических моделей изменения параметров и парциальной нелинейной фильтрации // *Информационно-управляющие системы*. 2018. № 5. С. 22–34.
39. Andoga R., Fozo L., Judicak J., Breda R. Intelligent Situational Control of Small Turbojet Engines // *International Journal of Aerospace Engineering*. 2018. pp. 1–16.
40. Gorod A., Ireland V., Gunawan I., Hallo L. Evolving Toolbox for Complex Project Management // Boca Raton: Auerbach Publications. 2019. 570 p.

**Якимов Виктор Леонидович** — д-р техн. наук, доцент, доцент, кафедра телеметрических систем, комплексной обработки и защиты информации, Военно-космическая академия имени А.Ф. Можайского (ВКА им. А.Ф. Можайского). Область научных интересов: моделирование сложных систем, нейросетевые технологии, техническая диагностика. Число научных публикаций — 55. yakim78@yandex.ru; Ждановская улица, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(812)347-95-32.

**Мальцев Георгий Николаевич** — д-р техн. наук, профессор, профессор, кафедра космических радиотехнических систем, Военно-космическая академия имени А.Ф. Можайского (ВКА им. А.Ф. Можайского). Область научных интересов: обработка сигналов в радиотехнических и оптико-электронных информационных системах, космические радиотехнические комплексы управления, сбора и передачи информации. Число научных публикаций — 200. georgy\_maltsev@mail.ru; Ждановская улица, 13, 197198, Санкт-Петербург, Россия; р.т.: +7(812)237-12-49.

V. YAKIMOV, G. MALTSEV  
**HYBRID NETWORK STRUCTURES AND THEIR USE IN  
DIAGNOSING COMPLEX TECHNICAL SYSTEMS**

*Yakimov V., Maltsev G. Hybrid Network Structures and Their Use in Diagnosing Complex Technical Systems.*

**Abstract.** An approach to the technical diagnostics of complex technical systems based on the results of telemetry information processing by an external monitoring and diagnostics system using hybrid network structures is proposed. The principle of constructing diagnostic complexes of complex technical systems is considered, which ensures the automation of the technical diagnostics process and is based on the use of models in the form of hybrid network structures for processing telemetric information, including multilayer neural networks and discrete Bayesian networks with stochastic learning. A model of changes in the parameters of complex technical systems technical state based on multilayer neural networks has been developed, which makes it possible to form a probabilistic assessment of attributing the current situation of complex technical system functioning to the set of functions considered situations according to individual telemetry parameters, and multilevel hierarchical model of complex technical systems technical diagnostics based on a discrete Bayesian network with stochastic learning, which allows aggregating the information received from neural network models and recognizing the current situation of complex technical system functioning. In the conditions of functioning emergencies of the complex technical system, according to the results of processing telemetric information, faulty functional units are localized and an explanation of the cause of the emergency is formed. The stages of complex technical systems technical diagnostics implementation using the proposed hybrid network structures in the processing of telemetric information are detailed. An example of using the developed approach to solving problems of spacecraft onboard system technical diagnostics is presented. The advantages of the proposed approach to the technical diagnostics of complex technical systems in comparison with the traditional approach based on analysis of telemetry parameters values belonging to the given tolerances are shown.

**Keywords:** complex technical system, technical diagnostics, reliability of functioning, bayesian network, stochastic learning.

**Yakimov Victor** — Ph.D., Dr.Sci., Associate Professor, Associate professor, Department of the space radio engineering systems, A.F. Mozhaysky military space academy. Research interests: modeling of complex systems, neural network technologies, technical diagnostics. The number of publications — 55. yakim78@yandex.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(812)347-95-32.

**Maltsev Georgiy** — Ph.D., Dr.Sci., Professor, Department of the space radio engineering systems, A.F. Mozhaysky military space academy. Research interests: processing of signals in radio engineering and optico-electronic information systems, space radio-technical complexes for control, collection and transmission of information. The number of publications — 200. georgy\_maltsev@mail.ru; 13, Zhdanovskaya St., 197198, St. Petersburg, Russia; office phone: +7(812)237-12-49.

**References**

1. Pospelov D.A. *Situatsionnoe upravlenie: teoriia i praktika* [The Situational Management: Theory and Practice]. Moscow: Editorial URSS Publ., 2021. 288 p. (In Russ.).
2. Mostovoi Ia.A. *Upravlenie slozhnymi tekhnicheskimi sistemami: konstruirovaniye programmogo obespecheniya sputnikov DZZ* [Management of Complex Technical Systems: Software Design for Remote Sensing Satellites]. Moscow: Tehnosfera Publ., 2016. 352 p. (In Russ.).
3. Aleksandrovskaia L.N. *Sovremennyye metody obespecheniya bezopasnosti slozhnykh tekhnicheskikh sistem: uchebnyk* [Modern Methods of Ensuring the Safety of Complex Technical Systems: Textbook]. Moscow: Logos Publ., 2001. 208 p. (In Russ.).
4. Kirilin A.N., Akhmetov R.N., Sologub A.N., Makarov V.P. *Metody obespecheniya zhivuchesti nizkoorbital'nykh avtomaticheskikh kosmicheskikh apparatov zondirovaniya Zemli: matematicheskie modeli, komp'yuternyye tekhnologii* [Methods for Ensuring the Survivability of Low-Orbit Automatic Earth Sensing Spacecraft: Mathematical Models, Computer Technologies]. Moscow: Mashinostroenie Publ., 2010. 384 p. (In Russ.).
5. Carlton A., Morgan R., Lohmeyer W., Cahoy K. *Telemetry Fault-Detection Algorithms: Applications for Spacecraft Monitoring and Space Environment Sensing*. Journal of Aerospace Information Systems. 2018. vol. 15. no. 5. pp. 239–252.
6. Mal'tsev G.N., Nazarov A.V., Yakimov V.L. [The Study of the Diagnosing of Automatic Spacecraft On-board Equipment Using a Discrete-Event Simulation Model]. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2018. Issue 1(56). pp. 95–121. (In Russ.).
7. Hassanien, A.E., Darwish A., Abdelghafar S. *Machine learning in Telemetry Data Mining of Space Mission: Basics, Challenging and Future Directions*. Artificial Intelligence Review. 2020. vol. 53. no. 5. pp. 3201–3230.
8. Bakhmut A.D., Krylov A.V., Okhtilev M.Y. *Proactive Management of Complex Objects Using Precedent Methodology*. Advances in Intelligent Systems and Computing. 2019. vol. 764. pp. 298–307.
9. Bakhmut A.D., Ustinov A.V., Koromyslichenko V.N. and oth. *Methods of Conceptual Modeling of Intelligent Decision Support Systems for Managing Complex Objects at All Stages of its Life Cycle*. Advances in Intelligent Systems and Computing. 2019. vol. 875. pp. 171–180.
10. Okhtilev M.Ju., Mustafin N.G., Miller V.E., Sokolov B.V. [The Concept of Management Complex Objects Proactive: Theoretical and Technological Foundations]. *Izvestiia vysshikh uchebnykh zavedenii. Priborostroenie – Proceedings of higher educational institutions. Instrumentation*. 2014. vol. 57. no. 11. pp. 7–15. (In Russ.).
11. Titkanloo H.N., Keramati A., Fekri R. *Data Aggregation in Multi-Source Assessment Model Based on Evidence Theory*. Applied Soft Computing. 2018. vol. 69. pp. 443–452.
12. Luger G. *Artificial Intelligence: Structure and Strategies for Complex Problem Solving*. 5th ed. Harlow: Addison Wesley, 2005. 903 p.
13. Burnham K.P. *Model Selection and Multimodel Inference: a Practical Informationtheoretic Approach*. New York: Springer, 2002. 488 p.
14. Mikoni S.V., Sokolov B.V., Iusupov R.M. *Kvalimetriia modelei i polimodel'nykh kompleksov* [Qualimetry of Models and Polymodel Complexes]. Moscow: RAN Publ., 2018. 314 p. (In Russ.).
15. Loskutov A.I., Biankin A.A., Semeniuk D.B., Klykov V.A. [Methods for Onboard Radio electronic Equipment Functioning Mathematical Model Synthesis of Rocket Objects and Space Technology Based on Polymodel Approach]. *Pribery i sistemy*.

- Upravlenie, kontrol', diagnostika – Devices and Systems. Management, Control, Diagnostics. 2019. no. 9. pp. 27–36. (In Russ.).
16. Shmelev V.V., Samoilov E.B., Sanotskaia N.A. [Polymodel Complex for Intelligent Monitoring of Technical Systems State with Disturbing factors Compensation]. T-Comm: Telekommunikatsii i transport. – T-Comm: Telecommunications and Transport. 2018. vol. 12. no. 8. pp. 44–51. (In Russ.).
  17. Jimenez J., Schwartz S., Vingerhoeds R., Grabot B. Towards Multi-Model Approaches to Predictive Maintenance: A Systematic Literature Survey on Diagnostics and Prognostics. *Journal of Manufacturing Systems*. 2020. vol. 56. pp. 539–557.
  18. Zhang P., Li T., Wang G., Luo C. Multi-source Information Fusion Based on Rough Set Theory: A Review. *Information Fusion*. 2021. vol. 68. pp. 85–117.
  19. Li Z., Tian L., Jiang Q., Yan X. Fault Diagnostic Method Based on Deep Learning and Multimodel Feature Fusion for Complex Industrial Processes. *Industrial & Engineering Chemistry Research*. 2020. vol. 59(40). pp. 18061–18069.
  20. Shahraki A.F., Yadav O.P., Liao H. A Review on Degradation Modelling and Its Engineering Applications. *International Journal of Performability Engineering*. 2017. vol. 13. pp. 299–314.
  21. Yakimov V.L. [The Forecasting of Launch Complex Technical State Parameters Using Neural Networks]. *Izvestiia vysshikh uchebnykh zavedenii. Priborostroenie – Proceedings of higher educational institutions. Instrumentation*. 2006. vol. 7. pp. 7–10. (In Russ.).
  22. Marushko E.E., Doudkin A.A. Ensembles of Neural Networks for Forecasting of Time Series of Spacecraft Telemetry. *Optical Memory and Neural Networks*. 2017. vol. 26. no. 1. pp. 47–54.
  23. Emel'ianova Iu.G., Fralenko V.P. [Methods of Information Cognitive-Graphic Presentation for Complex Technical Systems Effective Monitoring]. *Programmnye sistemy: teoriia i prilozheniia – Software Systems: Theory and Applications*. 2018. vol. 9. no. 4(39). pp. 117–158. (In Russ.).
  24. Mal'tsev G.N., Nazarov A.V., Yakimov V.L. [Training Sample Entropy Maximizing Algorithm and Its Use in Synthesis of Predictive Model Nonlinear Dynamic System Discrete States]. *Informatsionno-upravliaiushchie sistemy – Information management systems*. 2015. no. 2. pp. 57–66. (In Russ.).
  25. Preece A. Asking «Why» in AI: Explainability of Intelligent Systems – Perspectives and Challenges. *Intelligent Systems in Accounting, Finance and Management*. 2018. vol. 25. pp. 63–72.
  26. Marcot B.G., Penman T.D. Advances in Bayesian Network Modelling: Integration of Modelling Technologies. *Environmental Modelling and Software*. 2019. vol. 111. pp. 386–393.
  27. Chen J., Pi D., Wu Z., Zhao X. Imbalanced Satellite Telemetry Data Anomaly Detection Model Based on Bayesian LSTM. *Acta Astronautica*. 2021. vol. 180. pp. 232–242.
  28. Maslennikov E.D., Sulimov V.B. [Bayesian Trust Network Predictions: Algorithm and Software Implementation]. *Vychislitel'nye metody i programirovanie – Computational Methods and Programming*. 2010. vol. 11. no. 4. pp. 94–107. (In Russ.).
  29. Musina V.F. [Bayesian Networks of Trust as Probabilistic Graphical Model for Assessing Medical Risks]. *Trudy SPIIRAN – SPIIRAS Proceedings*. 2013. Issue 1(24). pp. 135–151. (In Russ.).
  30. Gao X., Guo Z., Ren H., Yang Y. Learning Bayesian network parameters via minimax algorithm. *International Journal of Approximate Reasoning*. 2019. vol. 108. pp. 62–75.

31. Toropova A.V. [Approaches to Diagnosing Data Consistency in Bayesian Trust Networks]. Trudy SPIIRAN – SPIIRAS Proceedings. 2015. Issue 6(43). pp. 156–178. (In Russ.).
32. Smirnov V.A. [Troubleshooting On-Board Control Systems During Acceptance Control]. Informatsionno-upravliaiushchie sistemy – Information management systems. 2013. no. 2. pp. 24–28. (In Russ.).
33. Larin V.P., Shelest D.K. [Formation of Information Support for Reliability of Onboard Equipment at Design Stage]. Informatsionno-upravliaiushchie sistemy – Information management systems. 2012. no. 4. pp. 93–97. (In Russ.).
34. Akhmetov R.N. [Methods and Models of Autonomous Control Over Earth Remote Sensing Spacecraft Survivability]. Vestnik Samarskogo gosudarstvennogo aerokosmicheskogo universiteta – Bulletin of the Samara State Aerospace University. 2008. no. 3. pp. 194–210. (In Russ.).
35. Kresoja M., Luzanin Z., Stojkovska I. Adaptive Stochastic Approximation Algorithm. Numerical Algorithms. 2017. vol. 76. pp. 917–937.
36. Granichin O.N., Izmakova O.A. [A Randomized Stochastic Approximation Algorithm in Self-Learning Problem]. Avtomatika i telemekhanika – Automation and telemechanics. 2005. no. 8. pp. 52–63. (In Russ.).
37. Wangab D., Tiana L. Parametric Methods for Confidence Interval Estimation of Overlap Coefficients. Computational Statistics & Data Analysis. 2017. vol. 106. pp. 12–26.
38. Mal'tsev G.N., Yakimov V.L., Solov'ev S.V., Lebedeva N.V. [Primary Processing of Telemetry Information Using Dynamic Models of Parameter Changes and Partial Nonlinear Filtering]. Informatsionno-upravliaiushchie sistemy – Information management systems. 2018. no. 5. pp. 22–34. (In Russ.).
39. Andoga R., Fozo L., Judicak J., Breda R. Intelligent Situational Control of Small Turbojet Engines. International Journal of Aerospace Engineering. 2018. pp. 1–16.
40. Gorod A., Ireland V., Gunawan I., Hallo L. Evolving Toolbox for Complex Project Management. Boca Raton: Auerbach Publications, 2019. 570 p.