

Прогнозирование технического состояния сложных технических систем с помощью метода Берга и байесовских сетей

Дорожко И.В.*, Осипов Н.А., Иванов О.А.*****

*Военно-космическая академия имени А.Ф. Можайского,
ул. Ждановская, 13, Санкт-Петербург, 197198, Россия*

**e-mail: Doroghko-Igor@yandex.ru*

***e-mail: bayes@mail.ru*

****e-mail: komp4ka@yandex.ru*

Статья поступила 11.06.2020

Аннотация

В работе исследованы вопросы прогнозирования технического состояния сложных технических систем с помощью метода Берга и моделей искусственного интеллекта – байесовских сетей. Рассмотрены различные (типовые) функции диагностических признаков и проанализированы результаты прогнозирования. Для уточнения и прогнозирования вида технического состояния сложных технических систем предложено использовать результаты прогнозирования и апостериорный вывод в байесовских сетях доверия.

Ключевые слова: прогнозирование, техническое состояние, диагностический признак, метод Берга, байесовская сеть.

Введение

В настоящее время в связи возросшей ролью автоматизации и интеллектуализации технологических процессов особенно важно при выработке

управляющих воздействий учитывать возможные сценарии развития этих процессов, прогнозировать нештатные и аварийные ситуации, заблаговременно принимать меры для их парирования.

При решении задач диагностирования необходимо не только определить вид технического состояния, но и спрогнозировать его на некоторый период времени [1, 2].

Сама по себе задача определения вида технического состояния также нетривиальна: необходимо по совокупности значений диагностических признаков сделать вывод о виде технического состояния. Таким образом, чтобы спрогнозировать вид технического состояния на некоторый интервал времени, необходимо по имеющимся значениям диагностических признаков осуществить прогнозирование диагностических признаков, по результатам которого принять решение о виде технического состояния. Решению этой задачи и посвящена данная статья.

Применение алгоритма Берга для прогнозирования диагностических признаков различной формы

Существуют достаточно эффективные алгоритмы и методы прогнозирования. Активно развиваются модели искусственного интеллекта, в частности, нейронные сети, для решения задач прогнозирования [3–5].

Как правило, основной проблемой для продуктивной работы нейронной сети является необходимость значительного объема статистических данных, получение

которого в реальных условиях затруднено вследствие ряда причин (высокая стоимость исследуемых систем, большие затраты на проведение испытаний, ограниченные сроки и т.д.) [6]. Следует также отметить, что для разработки нейронных сетей необходимы специальные среды моделирования (например, Matlab, Intel openVINO), а для их реализации – аппаратные средства (ПЛИС, процессоры, нейрочипы, нейрофлэшки, например Intel Movidius Neural Compute Stick и т.п.). Отсутствие четкого понимания в выборе архитектуры нейронной сети для решения различных типов задач (распознавание образов, аппроксимация, прогнозирование и т.п.) и областей применения также осложняет их применение, неясно сколько слоев и нейронов в каждом слое, а также какие функции активации необходимо использовать для решения задачи. В связи с этим алгоритм Берга применительно к задачам прогнозирования отличается достаточной эффективностью и простотой реализации по сравнению с нейросетями.

Основная идея алгоритма Берга достаточно проста, но в то же время и оригинальна: использовать последние m исходных значений данных, чтобы вычислить коэффициенты прогнозирования, а затем использовать последние m точек, чтобы спрогнозировать $(m+1)$ -ю точку [7, 8].

Пусть у нас имеется дискретное множество из наблюдений до текущего момента времени значений диагностического признака $\{pr_t | t = 0, 1, \dots, T\}$. Используя k коэффициентов $\{a_t | t = \overline{1, k}\}$ необходимо аппроксимировать исходный набор диагностических признаков для прогнозирования с помощью функции

$y_t = -\sum_{i=1}^k (a_i \cdot \text{pr}_{t-i})$ («экстраполяция вперед») и ретроспективного анализа с помощью

функции $z_t = -\sum_{i=1}^k (a_i \cdot \text{pr}_{t+i})$ («экстраполяция назад»).

Как правило, для нахождения аппроксимирующих коэффициентов используют метод наименьших квадратов. Особенность нахождения аппроксимирующих коэффициентов в методе Берга заключается в том, что минимизируется сумма сразу двух функций квадратов невязок для «экстраполяции вперед» (1) и «экстраполяции назад» (3) [7, 8].

$$F_k = \sum_{t=k}^T (\text{pr}_t - y_t)^2 = \sum_{t=k}^T \left(\text{pr}_t - \left(-\sum_{i=1}^k (a_i \cdot \text{pr}_{t-i}) \right) \right)^2 = \sum_{t=k}^T \left(a_0 \cdot \text{pr}_t + \sum_{i=1}^k (a_i \cdot \text{pr}_{t-i}) \right)^2 =$$

$$= \sum_{t=k}^T \left(\sum_{i=0}^k (a_i \cdot \text{pr}_{t-i}) \right)^2 = \sum_{t=k}^T (f_k(t))^2. \quad (1)$$

При этом вводится обозначение:

$$f_k(t) = \sum_{i=0}^k (a_i \cdot \text{pr}_{t-i}). \quad (2)$$

$$B_k = \sum_{t=0}^{T-k} (\text{pr}_t - z_t)^2 = \sum_{t=0}^{T-k} \left(\text{pr}_t - \left(-\sum_{i=1}^k (a_i \cdot \text{pr}_{t+i}) \right) \right)^2 = \sum_{t=0}^{T-k} \left(a_0 \cdot \text{pr}_t + \sum_{i=1}^k (a_i \cdot \text{pr}_{t+i}) \right)^2 =$$

$$= \sum_{t=0}^{T-k} \left(\sum_{i=0}^k (a_i \cdot \text{pr}_{t+i}) \right)^2 = \sum_{t=0}^{T-k} (b_k(t))^2. \quad (3)$$

При этом также обозначили:

$$b_k(t) = \sum_{i=0}^k (a_i \cdot \text{pr}_{t+i}). \quad (4)$$

Алгоритм Берга для прогнозирования значений диагностического признака может быть представлен совокупностью следующих шагов [7, 8].:

1-й шаг. Ввод m (числа коэффициентов). То есть прогнозирование будет основываться на m последовательных значениях диагностического признака. Например, $m=1$ может означать, что при прогнозировании учитывается только одно значение диагностического признака: для вычисления pr_{T+1} будет использовано только pr_T .

2-й шаг. Задаем начальное значение вектора коэффициентов аппроксимирующей функции $A_0 = [1]$.

3-й шаг. Используя (2) и (4), вычисляем $f_0(t) = b_0(t) = pr_t$.

4-й шаг. Используя (1) и (3), вычисляем F_0 и B_0 .

5-й шаг. Изменяя k от 0 до $(m-1)$ выполняем следующее:

5.1. Вычисляем
$$\mu = \frac{-2 \sum_{t=0}^{T-k-1} (f_k(t+k+1) \cdot b_k(t))}{\sum_{t=k+1}^T (f_k(t))^2 + \sum_{t=0}^{T-k-1} (b_k(t))^2}$$
 (полученное из решения

дифференциального

уравнения

$$\frac{\partial(F_{k+1} + B_{k+1})}{\partial\mu} = \frac{\partial\left(\sum_{t=k+1}^T (f_k(t) + \mu \cdot b_k(t-k-1))^2 + \sum_{t=0}^{T-k-1} (b_k(t) + \mu \cdot f_k(t+k+1))^2\right)}{\partial\mu} = 0).$$

5.2. Обновляем вектор аппроксимирующих коэффициентов A_{k+1} , используя следующие соотношения (5) и (6):

$$A_{k+1} = A_k + \mu \cdot V_k, \quad (5)$$

$$\text{где } A_k = \begin{bmatrix} 1 \\ a_1 \\ a_2 \\ \vdots \\ a_k \end{bmatrix} \text{ и } V_k = \begin{bmatrix} 0 \\ a_k \\ \vdots \\ a_2 \\ a_1 \\ 1 \end{bmatrix}.$$

$$a_t^* = a_t + \mu \cdot a_{k+1-t}. \quad (6)$$

5.3. Обновляем $(f_{k+1}(t))_{t \in [k+1, T]}$, используя $f_{k+1}(t) = f_k(t) + \mu \cdot b_k(t - k - 1)$.

5.4. Обновляем $(b_{k+1}(t))_{t \in [0, T-k-1]}$, используя $b_{k+1}(t) = b_k(t) + \mu \cdot f_k(t + k + 1)$.

С помощью алгоритма Берга было осуществлено прогнозирование диагностических признаков четырех форм: линейная, экспоненциальная, периодическая и осциллирующая. Исходными данными были 200 значений диагностических признаков каждого вида, причем для прогнозирования использовались первые 100 значений, оставшиеся 100 значений использовались для валидации, т.е. оценки достоверности прогноза.

На рисунках 1-4 представлены результаты прогнозирования и оценки достоверности прогнозирования. Оценивание достоверности прогнозирования производилось путем вычисления относительной ошибки прогнозирования

$$\frac{|r_{\text{валид}} - r_{\text{прогноз}}|}{|r_{\text{валид}}|} \cdot 100\%.$$

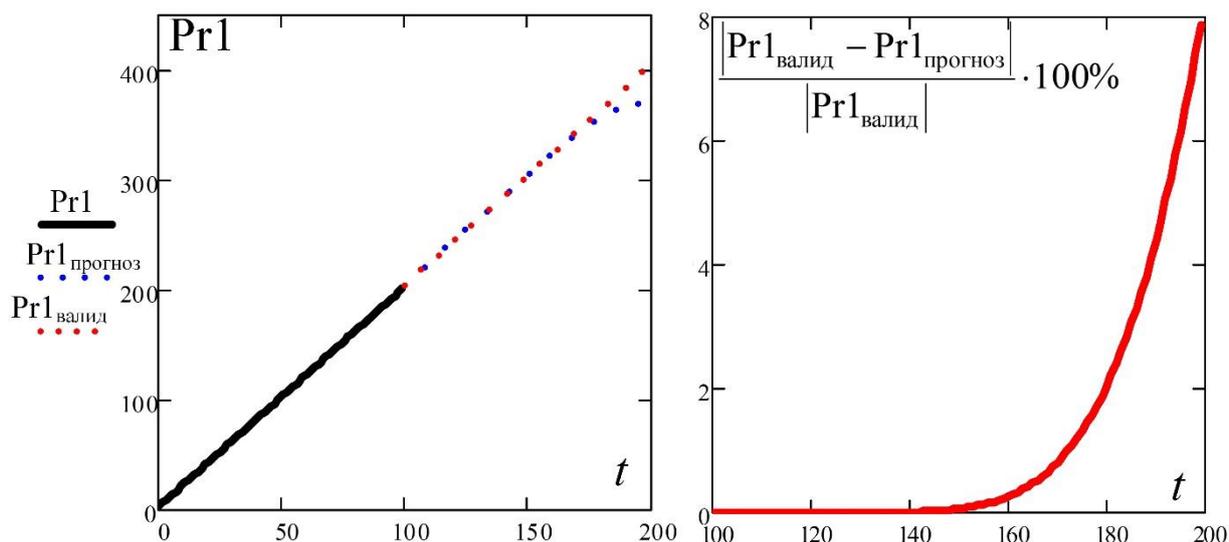


Рис. 1. Графики прогноза и оценки достоверности прогноза линейного
диагностического признака

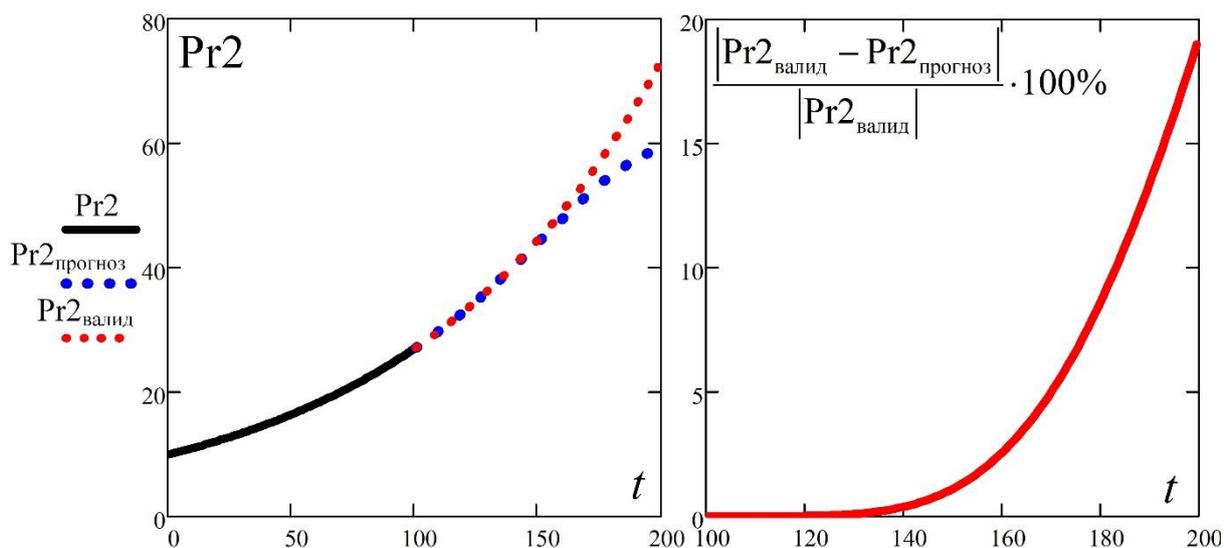


Рис. 2. Графики прогноза и оценки достоверности прогноза экспоненциального
диагностического признака

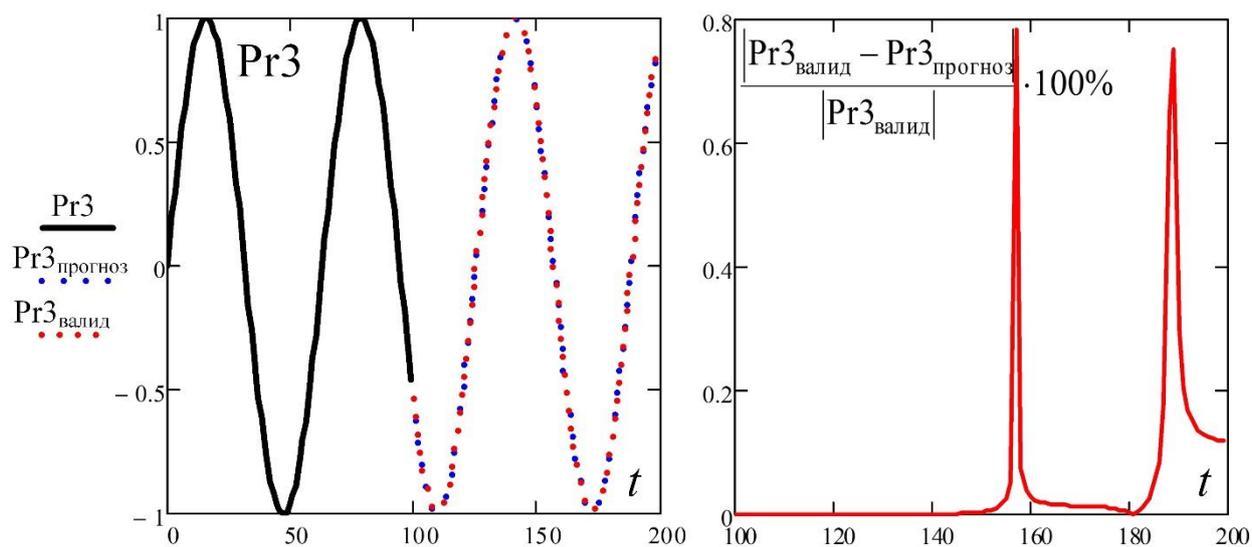


Рис. 3. Графики прогноза и оценки достоверности прогноза периодически изменяющегося диагностического признака

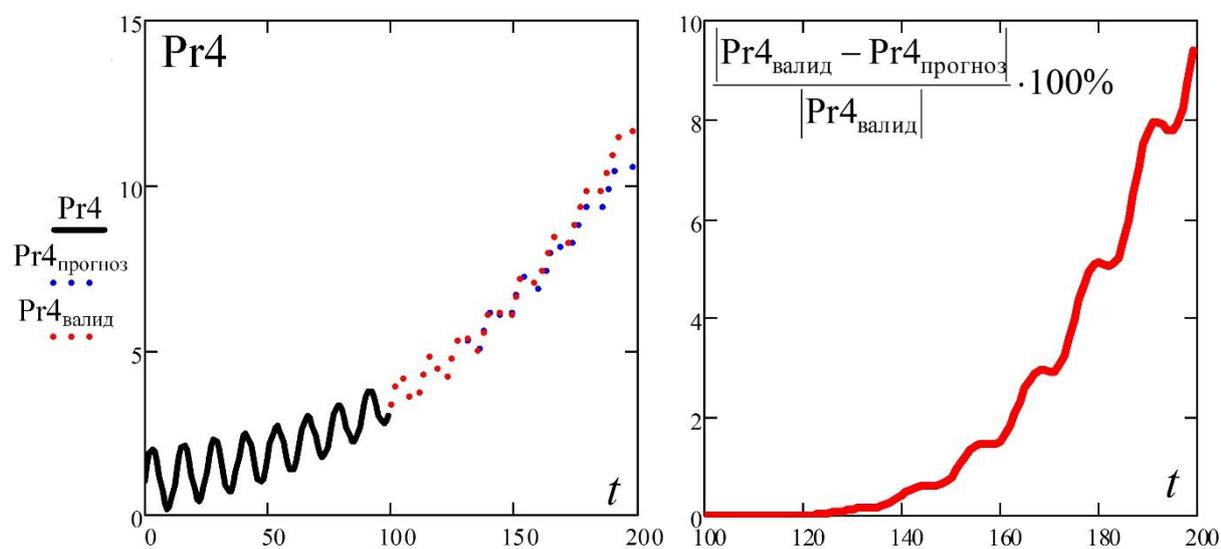


Рис. 4. Графики прогноза и оценки достоверности прогноза осциллирующего диагностического признака

Анализ графиков, изображенных на рисунках 1-4, показывает, что алгоритм Берга показывает удовлетворительные результаты даже для нелинейных зависимостей, хотя являясь по своей сути линейным алгоритмом прогнозирования. При дальности прогноза 40 (т.е. $t_{\text{прогноз}} = t_{\text{тек}} + 40 = 140$) прогнозные значения практически совпадают с истинными (валидационными) значениями диагностических признаков.

Применение байесовских сетей доверия для задач диагностирования сложных технических систем

В настоящее время в искусственном интеллекте активно развиваются различные модели представления знаний. Байесовские сети доверия являются перспективным математическим аппаратом, с помощью которых можно, применительно к задачам диагностирования, учитывать, как причинно-следственную связь между видами технического состояния сложной технической системы (СТС) и диагностическими признаками, так и поступление новой информации в виде статистических данных или прогнозных оценок.

Байесовские сети позволяют объединить априорные (начальные) знания об объекте с новыми (экспериментальными) данными для получения апостериорной (послеопытной) оценки [9-12].

Математическая модель для определения вида технического состояния СТС с помощью аппарата динамических байесовских сетей доверия (ДБСД) представляет собой синтез моделей надежности и диагностирования [13].

В формализованном виде байесовская сеть доверия представляет собой ациклический направленный граф с параметрами [14]:

$$\langle \mathbf{G}, \mathbf{PAR} \rangle, \quad (7)$$

где \mathbf{G} – множество дискретных и непрерывных переменных-вершин и направленных связей между ними (топология сети), \mathbf{PAR} – безусловные и условные вероятности.

Переменными-вершинами ДБСД для рассматриваемой задачи диагностирования СТС являются элементы (модули, блоки, подсистемы) СТС, для которых задаются виды технического состояния, и связанные с ними диагностические признаки:

$$\mathbf{Block} = \{\text{block}_q^{<w>} \mid q = \overline{1, n}, w = \overline{1, r}\}, \quad (8)$$

$$S = \{\text{Rabot}_q^{<w>}, \text{Otkaz}_q^{<w>} \mid q = \overline{1, n}, w = \overline{1, r}\} \text{ и } \mathbf{Pr} = \{\text{pr}^j \mid j = \overline{1, l}\}$$

где block – наименование блока; q – номер блока; n – число блоков; w – иерархический уровень; r – число уровней; $\text{Rabot}_q^{<w>}$ и $\text{Otkaz}_q^{<w>}$ – работоспособное состояние и состояние отказа q -го элемента w -го иерархического уровня СТС; pr^j – диагностический признак (ДП); j – номер ДП; l – число ДП.

Чтобы ввести параметры \mathbf{PAR} в модель надежности и диагностирования СТС на основе динамической байесовской сети необходимо:

1. Для «простейших» блоков, которые не детализируются на блоки более низкого иерархического уровня ($\forall \text{block}_q^{<w>} : \neg(\exists \text{block}_q^{<w-1>} = \text{parent}(\text{block}_q^{<w>}))$), задать:

1.1. Безусловные вероятности в начальный момент времени, а именно, вероятность работоспособного состояния – $P(\text{Rabot}_q^{<w>})_{t=0} = 1$ (полагаем, что перед началом работы блок был проверен и работоспособен), и вероятность отказа – $P(\text{Otkaz}_q^{<w>})_{t=0} = 1 - P(\text{Rabot}_q^{<w>})_{t=0} = 0$;

1.2 Условные вероятности, которые определяют динамические свойства модели:

– вероятность нахождения блока в работоспособном состоянии в текущий момент времени при условии его работоспособности в предыдущий

момент времени – $P(\text{Rabot}_q^{<w>}(t)/\text{Rabot}_q^{<w>}(t-1)) = \frac{e^{-\lambda_q^{<w>}t}}{e^{-\lambda_q^{<w>}(t-1)}} = e^{-\lambda_q^{<w>}}$ (если

рассматривается этап нормальной эксплуатации СТС и применяется экспоненциальный закон распределения для наработки на отказ);

– вероятность отказа блока в текущий момент времени при условии того, что в предыдущий момент времени он был работоспособен –

$$P(\text{Otkaz}_q^{<w>}(t)/\text{Rabot}_q^{<w>}(t-1)) = 1 - e^{-\lambda_q^{<w>}};$$

– вероятность восстановления блока к текущему моменту времени после отказа в предыдущий момент времени –

$$P(\text{Rabot}_q^{<w>}(t)/\text{Otkaz}_q^{<w>}(t-1)) = 1 - e^{-\mu_q^{<w>}}, \quad \text{где } \mu_q^{<w>} \text{ – интенсивность}$$

восстановления q -го блока w -го иерархического уровня СТС. Если блок является невозстанавливаемым, то $P(\text{Rabot}_q^{<w>}(t)/\text{Otkaz}_q^{<w>}(t-1)) = 0$;

– вероятность не восстановления блока к текущему моменту времени после отказа в предыдущий момент времени –

$P(\text{Otkaz}_q^{<w>}(t)/\text{Otkaz}_q^{<w>}(t-1)) = e^{-\mu_q^{<w>}}$. Если блок является

невосстанавливаемым, то $P(\text{Otkaz}_q^{<w>}(t)/\text{Otkaz}_q^{<w>}(t-1)) = 1$.

На рис. 5. представлены формы для ввода параметров блока в среде GeNIe [15].

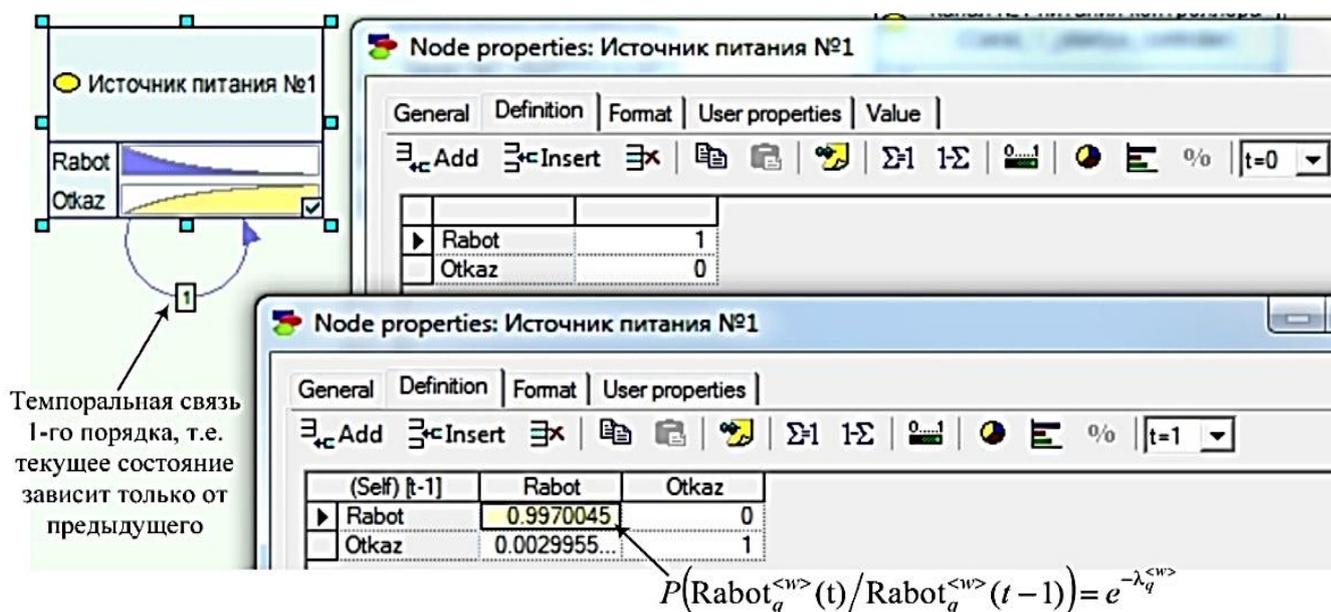


Рис. 5. Пример ввода безусловных и условных вероятностей

Бесплатная и с открытым кодом среда GeNIe представляет удобный графический интерфейс для построения и работы байесовских сетей, что обусловило ее выбор для моделирования.

2. Для сложных блоков (подсистем), состоящих из других блоков ($\forall \text{block}_q^{<w>} : \exists \text{block}_q^{<w-1>} = \text{parent}(\text{block}_q^{<w>})$), задаются условные вероятности, учитывая типы их соединений с точки зрения надежности [14, 16].

Например, если канал питания контроллера представлен последовательным соединением блока «Источник питания» и блока «Устройство ввода, защиты и резервирования питания», то канал питания контроллера будет работоспособен при

условии работоспособности этих двух блоков, отказ хотя бы одного из них приведет к отказу канала питания контроллера (рис. 6).

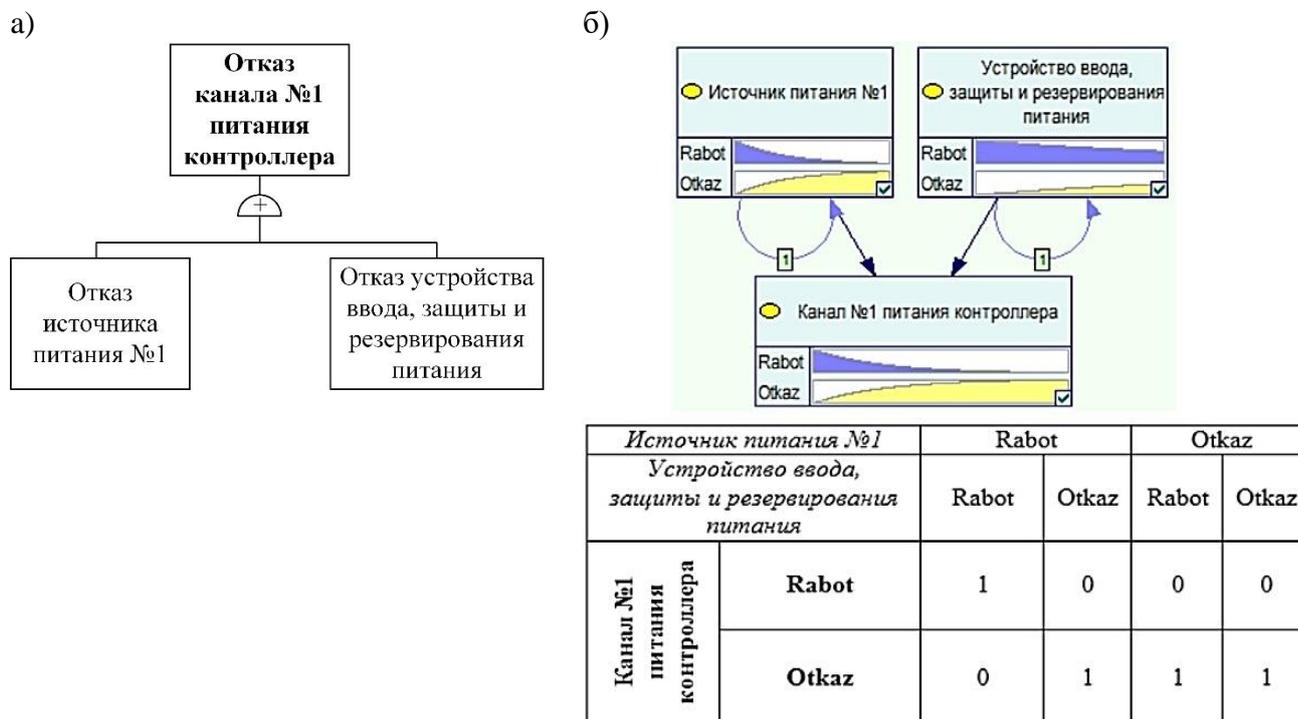


Рис. 6. Модели надежности канала питания контроллера:

а) дерево отказов; б) эквивалентная байесовская сеть

Аналогично можно задать другие типы соединений с точки зрения надежности (параллельное, мостиковое, мажоритарное, «треугольник», «звезда» и т.д.)

3. Для вершин-переменных диагностических признаков (ДП) указываются распределения условных вероятностей $P(p_{r_j} / S_q^{<w>})$ с учетом ошибок (достоверностей) проверок ДП [1, 2, 17-21], что повышает адекватность модели (рис. 7).

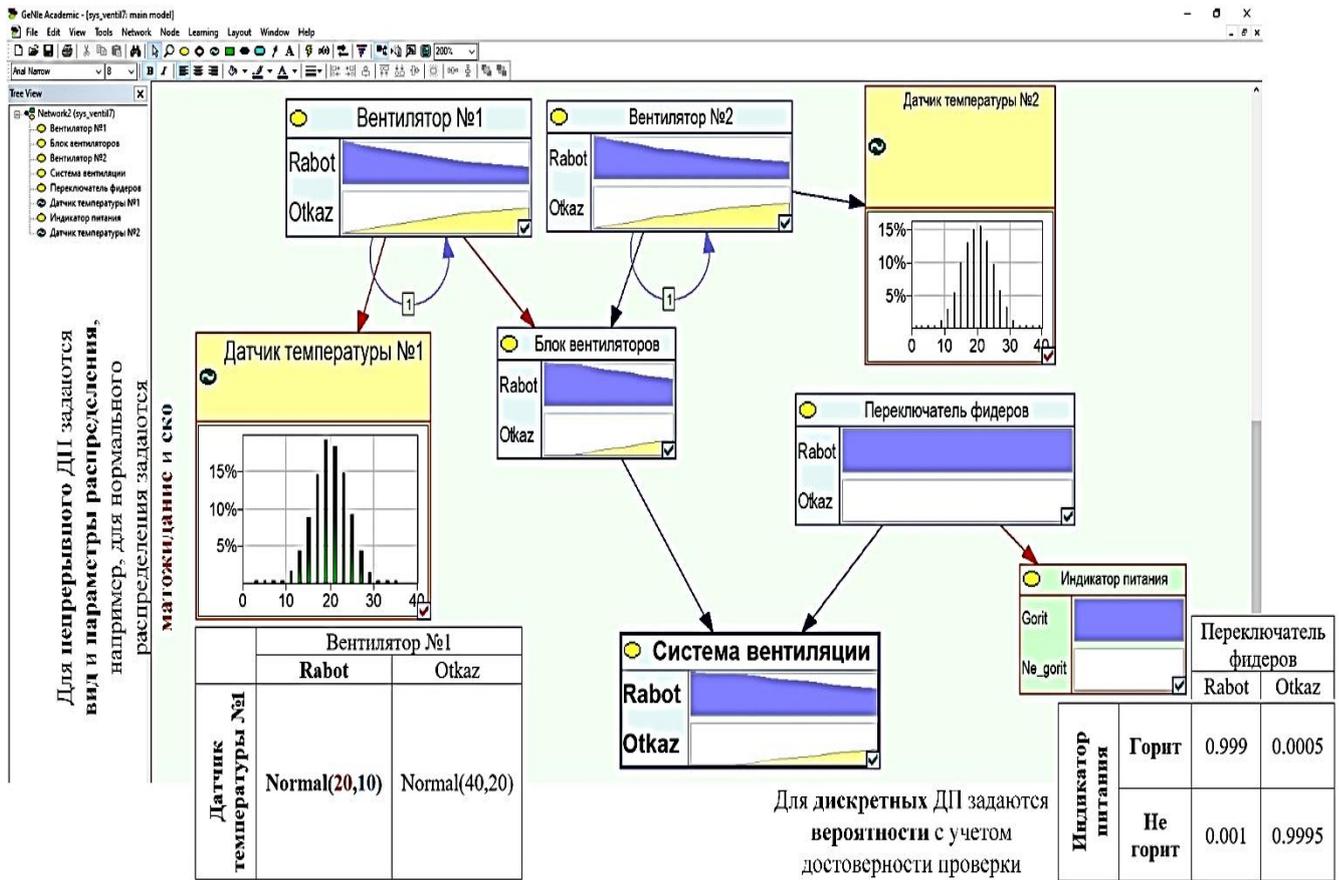


Рис. 7. Пример комплексной модели надежности и диагностирования СТС

на основе гибридной динамической байесовской сети доверия

Работа построенной байесовской сетей заключается в объединении априорной информации (начальных знаний о СТС, данные об аналогах, данные о других СТС, содержащих такие же блоки) и новых данных (свидетельств), т.е. апостериорном выводе. Идея заключается в том, что при поступлении новых данных (свидетельств) обнуляются все несовместимые с этими свидетельствами вероятности исходов и нормируются оставшиеся вероятности, учитывая априорные данные, чтобы сумма вероятностей оставшихся исходов была равна единице [9-12].

Апостериорный вывод для простейшей байесовской сети можно описать выражениями (9) и (10) при поступлении значений дискретного и непрерывного диагностического признака соответственно.

$$P(\text{Rabot}(t)/\text{pr}_j(t)) = \frac{P(\text{pr}_j(t)/\text{Rabot}(t)) \cdot P(\text{Rabot}(t))}{P(\text{pr}_j(t)/\text{Rabot}(t)) \cdot P(\text{Rabot}(t)) + P(\text{pr}_j(t)/\text{Otkaz}(t)) \cdot P(\text{Otkaz}(t))}, \quad (9)$$

$$P(\text{Rabot}(t)/\text{pr}_j(t)) = \frac{f(\text{pr}_j(t)/\text{Rabot}(t)) \cdot P(\text{Rabot}(t))}{f(\text{pr}_j(t)/\text{Rabot}(t)) \cdot P(\text{Rabot}(t)) + f(\text{pr}_j(t)/\text{Otkaz}(t)) \cdot P(\text{Otkaz}(t))}, \quad (10)$$

где $f(\text{pr}_j(t)/\text{Rabot}(t))$ и $f(\text{pr}_j(t)/\text{Otkaz}(t))$ – плотности распределений j -го непрерывного диагностического признака при различных видах технического состояния.

Полученная апостериорная оценка при поступлении новых данных для очередных итераций будет являться уже априорной информацией. Свидетельствами в байесовской сети для рассматриваемой задачи диагностирования СТС являются информация о техническом состоянии элементов (модулей, блоков) СТС (например, факт отказа какого-либо блока и момент времени этого события), а также текущая диагностическая информация в виде значений непрерывных и дискретных диагностических признаков. При получении прогнозных оценок диагностических признаков их также можно использовать в качестве свидетельств для получения апостериорных оценок и прогнозирования технического состояния СТС.

На рис. 8 представлены следующие графики:

- априорной вероятности работоспособного состояния, т.е. учитывается лишь информация о надежности элементов и структурно-логические схемы (красный цвет);
- апостериорной вероятности работоспособного состояния с учетом данных о диагностическом признаке (черный цвет);
- апостериорной вероятности работоспособного состояния с учетом прогнозирования значений диагностического признака (синий цвет).

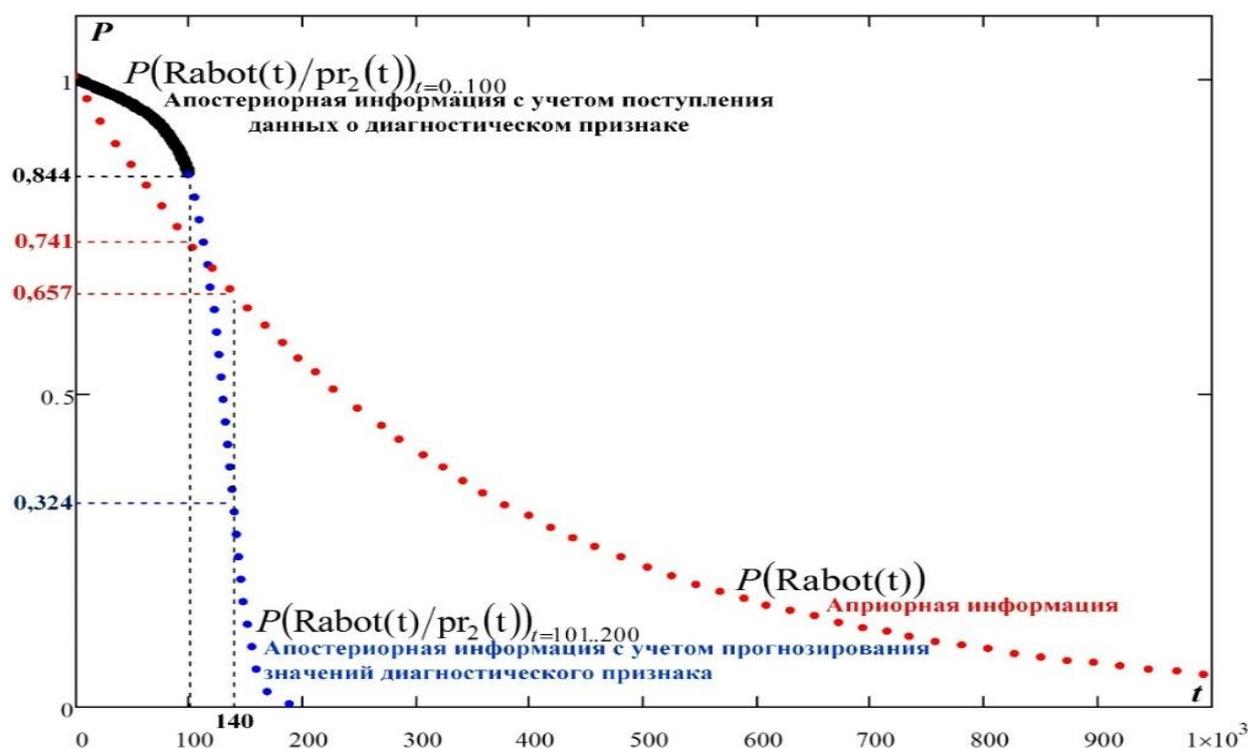


Рис. 8. Графики вероятностей работоспособного состояния, построенные с учетом априорной, статистической и прогнозной информации

На рис. 9 представлены аналогичным образом графики для вероятности отказа СТС:

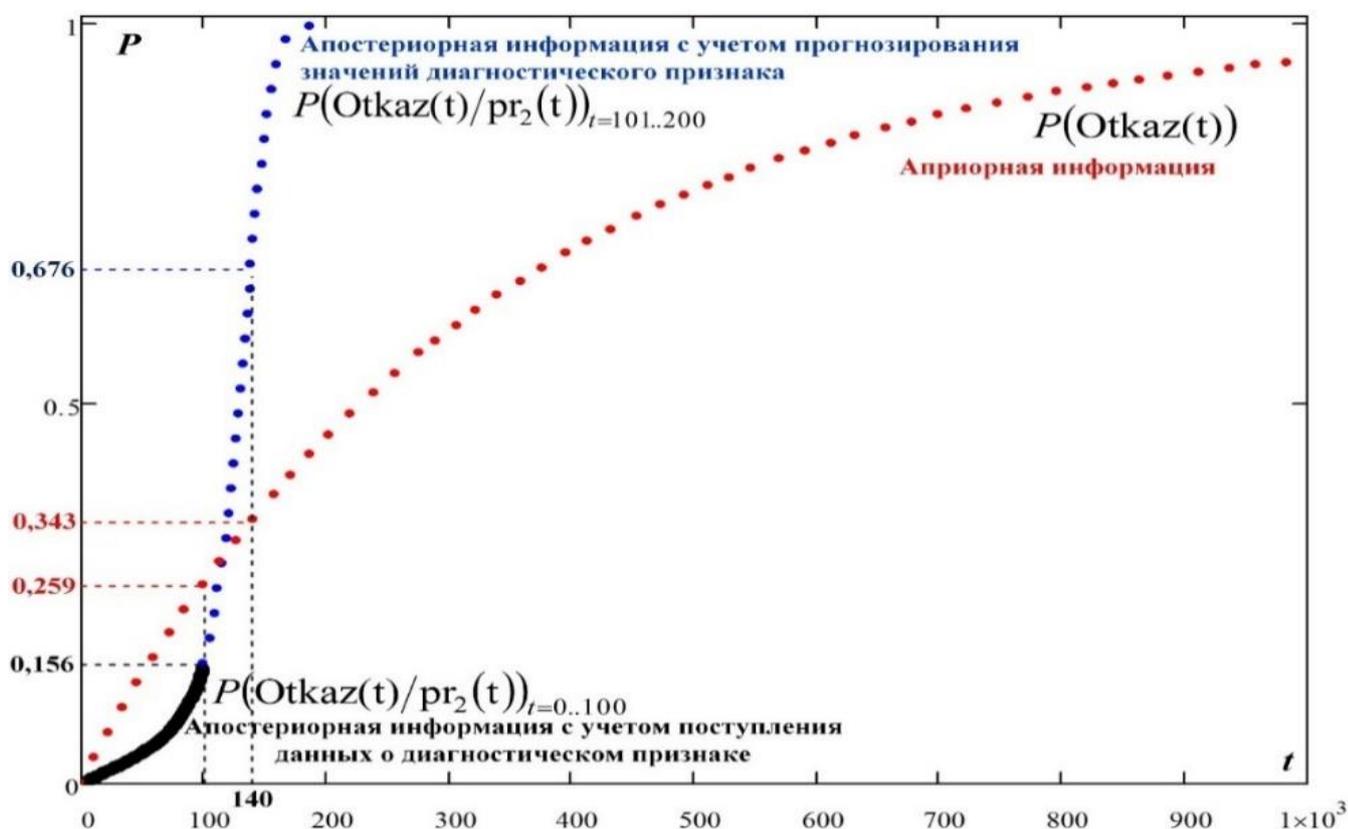


Рис. 9. Графики вероятностей отказа, построенные с учетом априорной, статистической и прогнозной информации

Анализ графиков позволяет сделать вывод о том, что судя по начальной (априорной) информации на момент времени $t=100$ вероятность работоспособного состояния составляет 0,741, использование диагностической информации (рис.2) также подтверждает факт работоспособности ($P(\text{Rabot}(t)/\text{pr}(t))_{t=0..100} = 0,844$), при этом на момент времени $t=140$ априорная вероятность работоспособного состояния составляет 0,657, а прогноз изменения диагностического признака (рис. 2) позволяет сделать вывод о том, что вероятность работоспособного состояния составит лишь 0,324, а вероятность отказа соответственно – 0,676. Таким образом, необходимо предусмотреть мероприятия для парирования возможного отказа (например, подать

управляющее воздействие, сменить режим работы, произвести замену элементов и т.п.).

Заключение

Таким образом, чтобы спрогнозировать вид технического состояния на некоторый интервал времени, необходимо по имеющимся значениям диагностических признаков осуществить прогнозирование диагностических признаков, по результатам которого принять решение о виде технического состояния. Для получения прогнозных оценок в статье предлагается использовать алгоритм Берга, а для вычисления вероятностей видов технического состояния на основе этих прогнозов – использовать байесовскую сеть доверия.

Математический аппарат байесовских сетей доверия легко адаптируется для решения задач диагностирования и оценивания показателей надежности СТС. Для логико-вероятностного вывода в качестве свидетельств могут быть использованы не только начальная (априорная) информация, произошедшие события, экспериментальные данные, но и прогнозные оценки.

Стоит отметить, что алгоритм Берга за счет использования рекурсивных зависимостей для экстраполяции в «обоих» направлениях представляет собой своего рода баланс простоты реализации и точности.

В программном пакете Mathcad данный алгоритм реализован в функции «predict», а в [8] представлен текст кода на языке C++ для данного алгоритма.

Результаты прогнозирования технического состояния СТС дают возможность парировать возможные отказы и осуществить проактивное управление [22-24].

Дальнейшие исследования могут быть связаны с обработкой интервальных оценок и расширением используемых законов распределения диагностических признаков, исследованием взаимных зависимостей диагностических признаков.

Библиографический список

1. Техническая диагностика. Термины и определения. ГОСТ В 20.911-89. - М.: Издательство стандартов, 1990. – 12 с.
2. Ключев В.В. и др. Технические средства диагностирования: Справочник. – М.: Машиностроение, 1989. – 671 с.
3. Гусев П.Ю., Гусев К.Ю. Прогнозирование выполнения производственного плана авиационного предприятия с применением нечетко-нейронной сети // Труды МАИ. 2020. № 110. URL: <http://trudymai.ru/published.php?ID=112933>. DOI: [10.34759/trd-2020-110-20](https://doi.org/10.34759/trd-2020-110-20)
4. Косинский М.Ю., Шатский М.А. Разработка моделей и методики для анализа и прогнозирования надёжности бортовых систем управления космических аппаратов на основе теории нечётких множеств и искусственных нейронных сетей // Труды МАИ. 2014. № 74. URL: <http://trudymai.ru/published.php?ID=49315>
5. Шевцов С.Н., Сибирский В.В., Чигринцев Е.Г. Применение нейронных сетей в прогнозировании качества механической обработки особо нагруженных композитных конструкций // Труды МАИ. 2016. № 91. URL: <http://trudymai.ru/published.php?ID=75572>

6. Арсеньев В.Н. Оценивание характеристик систем управления по ограниченному числу натуральных испытаний. – М.: Изд-во «РЕСТАРТ», 2013. – 126 с.
7. Burg J.P. Maximum Entropy Spectral Analysis, PhD thesis, Department of Geophysics, Stanford University, Stanford, CA, 1975.
8. Cedrick Collomb. Burg's Method, Algorithm and Recursion, 2009. URL: <http://www.emptyloop.com/technotes/a%20tutorial%20on%20burg's%20method,%20algorithm%20and%20recursion.pdf>
9. Тулупьев А.Л., Николенко С.И., Сироткин А.В. Основы теории байесовских сетей. – СПб.: Изд-во Санкт-Петербургского университета, 2019. – 399 с.
10. Cowell R.G., Dawid A.P., Lauritzen S.L., Spiegelhalter D.J. Probabilistic Networks and Expert Systems, Springer-Verlag, 1999.
11. Jensen F.V. Bayesian Networks and Decision Graphs, New York, Springer-Verlag, 2001, 457 p.
12. Pearl J. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, New York, Morgan Kaufman Publ., 1991. DOI: [10.1016/0004-3702\(91\)90084-W](https://doi.org/10.1016/0004-3702(91)90084-W)
13. Дорожко И.В., Кочанов И.А., Осипов Н.А. и др. Комплексная модель надежности и диагностирования сложных технических систем // Труды Военно-космической академии им. А.Ф. Можайского. 2016. № 652. С 137 – 146.
14. Дорожко И.В., Захарова Е.А., Осипов Н.А. Модель оценки вероятности безотказной работы сложных технических комплексов на основе динамических байесовских сетей // Труды Военно-космической академии им. А.Ф. Можайского. 2019. № 669. С. 216 – 223.

15. GeNIe & SMILE. Decisions systems laboratory. School of Information Sciences. University of Pittsburg. URL: <http://genie.sis.pitt.edu/>
16. ГОСТ 27.002-15. Надежность в технике. Основные понятия. Термины и определения. – М.: Стандартинформ, 2016. – 24 с.
17. Дмитриев А.К. Модели и методы анализа технического состояния бортовых систем. – СПб.: ВИКУ имени А.Ф. Можайского, 1999. – 171 с.
18. Дмитриев А.К., Копкин Е.В. Оценивание достоверности проверок непрерывных признаков при диагностировании технического объекта // Известия вузов. Приборостроение. 1999. № 9. Т. 42. С. 3 - 10.
19. Дмитриев А.К., Юсупов Р.М. Идентификация и техническая диагностика. – Л.: МО СССР, 1987. – 521 с.
20. Копкин Е.В., Кравцов А.Н., Мышко В.В. Анализ технического состояния космических средств. – СПб.: ВКА имени А.Ф. Можайского, 2016. – 189 с.
21. Копкин Е.В., Кравцов А.Н., Мышко В.В. Контроль и диагностика космических средств. – СПб.: ВКА имени А.Ф. Можайского, 2016 – 198 с.
22. Охтилев М.Ю., Соколов Б.В., Юсупов Р.М. Теоретические и технологические основы концепции проактивного мониторинга и управления сложными объектами // Известия ЮФУ. Технические науки. 2015. № 1(162). С. 162 - 174.
23. Охтилев М.Ю., Мустафин Н.Г., Миллер В.Е., Соколов Б.В. Концепция проактивного управления сложными объектами: теоретические и технологические основы // Известия Вузов. Приборостроение. 2014. Т. 57. № 11. С. 7 – 15.

24. Motienko A., Basov O., Dorozhko I., Tarasov A. Proactive Robotic Systems For Effective Rescuing Sufferers. GmbH: Springer-Verlag, Lecture Notes In Computer Science, 2016, pp. 172 - 180. DOI: [10.1007/978-3-319-43955-6_21](https://doi.org/10.1007/978-3-319-43955-6_21)