

ИНФОРМАТИКА, МОДЕЛИРОВАНИЕ И УПРАВЛЕНИЕ

Научная статья

УДК 681.5

URL: <https://trudymai.ru/published.php?ID=186315>

EDN: <https://www.elibrary.ru/QOPFDE>

**ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ БАЙЕСОВСКИХ
СЕТЕЙ ДЛЯ РЕШЕНИЯ ЗАДАЧ ДИАГНОСТИРОВАНИЯ СЛОЖНЫХ
ТЕХНИЧЕСКИХ СИСТЕМ С ИСПОЛЬЗОВАНИЕМ ДИСКРЕТНЫХ
ДИАГНОСТИЧЕСКИХ ПРИЗНАКОВ**

Игорь Владимирович Дорожко✉

ВКА им. А.Ф. Можайского

Санкт-Петербург, Россия

✉ yka@mil.ru.

Аннотация. В статье предложено применение алгоритмов машинного обучения байесовских сетей для построения моделей диагностирования сложных технических систем. Описан подход к построению модели диагностирования типовой стойки, входящей в состав автоматизированной системы управления технологическим оборудованием стартового комплекса. Рассматриваются примеры параметрического обучения модели при заданной топологии байесовской сети, а также структурно-параметрического обучения, когда структура модели не задана и синтезируется в процессе машинного обучения. В статье обращается внимание на возможность учета степени доверия к априорной информации при обучении моделей.

Анализируются результаты параметрического обучения моделей при различных значениях степеней доверия к априорной информации. Предлагаются возможности выявления зависимостей между диагностическими признаками при использовании машинного обучения.

Ключевые слова: диагностирование, диагностические признаки, априорная информация, байесовская сеть, структурно-параметрическое машинное обучение

Для цитирования: Дорожко И.В. Применение алгоритмов машинного обучения байесовских сетей для решения задач диагностирования сложных технических систем с использованием дискретных диагностических признаков // Труды МАИ. 2025. № 144. URL: <https://trudymai.ru/published.php?ID=186315>

COMPUTER SCIENCE, MODELING AND MANAGEMENT

Original article

APPLICATION OF MACHINE LEARNING ALGORITHMS OF BAYESIAN NETWORKS TO SOLVE THE PROBLEMS OF DIAGNOSING COMPLEX TECHNICAL SYSTEMS USING DISCRETE DIAGNOSTIC PARAMETER

Dorozhko I.V.✉

Military space Academy named after A.F. Mozhaisky

Saint-Petersburg, Russia

✉vka@mil.ru.

Abstract. The article suggests the use of the Bayesian network apparatus to formalize the process of diagnosing technical systems. With the help of a priori information about the

composition, reliability, relationships of diagnostic features and types of technical conditions, an initial model is built. The scientific novelty of the research lies in the study of the possibility of correcting the parameters of the diagnostic model as a result of machine learning with a limited training sample size, taking into account the degree of confidence in a priori information. It is pointed out the advantages of Bayesian networks, which consist in the ability to compensate for limited experimental data by using a priori information. The influence of taking into account the degree of trust in a priori data and the amount of statistical information on the results of machine learning is investigated. The practical significance lies in the possibility of applying the proposed approach to standard racks of an automated control system for technological equipment of the launch complex. A study of structural-parametric learning of the diagnostic process model in the form of a Bayesian network has been conducted, as a result of which not only the parameters, but also the structure of the model is adjusted. This opens up opportunities to identify dependencies between diagnostic features that may not have been taken into account at the design stage. Attention is drawn to the problem of inconsistency of the initial data, which, with certain combinations of diagnostic signs, lead to the inability to draw a conclusion about the type of technical condition, i.e. to obtain a diagnostic result. These contradictions are the result of errors in setting the initial model or the presence of unaccounted-for dependencies of diagnostic features and can be resolved as a result of structural-parametric machine learning. The results obtained contribute to the development of a methodology for monitoring and diagnosing complex technical systems. The proposed approach can be used at the design and operation stages of automated control systems for technological equipment of the launch complex.

Keywords: diagnosis, diagnostic parameters, a priori information, Bayesian network, structural-parametric machine learning

For citation: Dorozhko I.V. Application of machine learning algorithms of bayesian networks to solve the problems of diagnosing complex technical systems using discrete diagnostic parameter // Trudy MAI. 2025. No. 144. (In Russ.) URL: <https://trudymai.ru/published.php?ID=186315>

Введение

В настоящее время наблюдается возросший объем разработок и применения моделей искусственного интеллекта в различных направлениях деятельности: автономное управление, робототехника, финансы, медицина, планирование, проектирование и т.п. Широкое применение нашли модели нейронных сетей для распознавания образов [13, 15]. Разрабатываются и развиваются различные архитектуры нейронных сетей и их алгоритмы обучения. При этом следует отметить, что начальный выбор той или иной структуры нейронной сети зачастую оказывает решающую роль на результаты решения задачи. Алгоритмы параметрического обучения в большинстве случаев оказываются «бессильны» при «неправильном» выборе архитектуры нейронной сети. Правильно или неправильно выбрана архитектура нейронной сети, существует ли ещё более «совершенная» архитектура являются актуальными вопросами, на которые четкие и конкретные ответы, как правило, отсутствуют, существуют лишь некоторые рекомендации при выборе числа слоев, нейронов в каждом слое и функций активации для решения тех или иных задач. В данной статье предлагается рассмотреть возможности байесовских сетей [5-7, 10,

14, 16-19] для решения задач диагностирования сложных технических систем (СТС) [3, 4, 8, 9, 11, 12] как альтернативный вариант моделям нейронных сетей.

Байесовские сети доверия (Bayesian Believe Network) используются в тех областях, которые характеризуются неопределённостью, а также когда задача характеризуется случайностью. Для байесовских сетей доверия иногда используется ещё одно название – «причинно-следственная сеть». В этих сетях случайные события соединены причинно-следственными связями [5-7, 10, 14, 16-19]. Байесовская сеть доверия представляется в виде направленного ациклического графа, вершины которого представляют переменные, а ребра кодируют условные зависимости между переменными [16]. Эти графические структуры служат для представления вероятностных отношений между большим количеством переменных и для осуществления вероятностного вывода на основе этих переменных. Байесовские сети доверия обладают рядом преимуществ, среди которых основным является возможность объединения априорных (начальных) знаний об объекте, включая статистические данные и экспертные оценки, с новыми (экспериментальными) данными для получения апостериорной (послеопытной) оценки.

Модели байесовских сетей, как и нейронных сетей, можно обучать. При этом в байесовских сетях можно проводить не только параметрическое обучение, но и структурно-параметрическое. Для проведения машинного обучения нейронных сетей требуются большие объёмы информации, при этом для байесовских сетей за счет использования априорной информации может быть использован меньший объём обучающей выборки.

Рассмотрим применение алгоритмов машинного обучения моделей байесовских сетей для решения задач диагностирования СТС.

Параметрическое обучение модели байесовской сети для решения задач диагностирования сложных технических систем

Исходные данные:

– $S = \{S_i \mid i = \overline{0, m}\}$ – множество видов технического состояния СТС, где S_0 – работоспособное состояние СТС, а $S_1, \dots, S_m$, состояния характеризующие отказы СТС (например, отказ блока №1, блока №2, ..., блока №m);

– $\{P(S_i) \mid i = \overline{0, m}\}$ – априорное распределение вероятностей видов технического состояния СТС. При этом $\sum_{i=0}^m P(S_i) = 1$. В некоторых случаях для СТС может быть доступна информация об интенсивностях отказов элементов (блоков), входящих в СТС – множество $\Lambda = \{\lambda_i \mid i = \overline{1, m}\}$. Тогда вероятности видов технического состояния можно получить на момент диагностирования (или произвольный момент времени t), используя соотношения (1) и (2) [5, 9, 11, 12]:

$$P(S_0) = \frac{1}{1 + \sum_{i=1}^m \frac{1 - p_i}{p_i}} = \frac{1}{1 + \sum_{i=1}^m \frac{1 - e^{-\lambda_i t}}{e^{-\lambda_i t}}}. \quad (1)$$

$$P(S_i) = \frac{\frac{1-p_i}{p_i}}{1 + \sum_{i=1}^m \frac{1-p_i}{p_i}} = \frac{\frac{1-e^{-\lambda_i t}}{e^{-\lambda_i t}}}{1 + \sum_{i=1}^m \frac{1-e^{-\lambda_i t}}{e^{-\lambda_i t}}} \quad (2)$$

– $\mathbf{Pr} = \{pr_j \mid j = \overline{1, n}\}$ – множество диагностических признаков;

– $\{P(pr_j / S_i) \mid i = \overline{0, m}; j = \overline{1, n}\}$ – условное распределение, задающее связь

диагностических признаков с видами технического состояния. В данном условном распределении можно учесть достоверность (ошибки) диагностических признаков;

Этих исходных данных достаточно для построения топологии байесовской сети и указания параметров (безусловных и условных вероятностей).

Рассмотрим простейший пример: имеется СТС, которая может находиться в двух видах технического состояния S_0 (работоспособное) и S_1 (отказ). Априорные вероятности видов технического состояния равны соответственно $P(S_0)=0,9$ и $P(S_1)=0,1$. Дан диагностический признак (индикатор), который должен гореть зеленым в работоспособном состоянии и красным – при отказе СТС. Байесовская сеть, построенная по априорной информации, изображена на рис. 1.




Рис. 1. Байесовская сеть простейшей системы, построенная по априорной информации и при поступлении информации о значении диагностического признака

Допустим известно по паспортным данным на индикатор, что данный диагностический признак имеет ошибки 1-го и 2-го рода:
 $\alpha = P(\langle pr_1 = krasn \rangle / S_0) = 0,05$ и $\beta = P(\langle pr_1 = zelen \rangle / S_1) = 0,02$. Тогда достоверности равны $P(\langle pr_1 = zelen \rangle / S_0) = 0,95$ и $P(\langle pr_1 = krasn \rangle / S_1) = 0,98$.

Байесовская сеть тогда примет вид, изображенный на рис. 2.




Рис. 2. Байесовская сеть простейшей системы, построенная по априорной информации и при поступлении информации о значении диагностического признака

Апостериорные вероятности вычисляются по формулам (3).

$$\begin{aligned}
 P(S_0 / \langle pr_1 = zelen \rangle) &= \frac{P(\langle pr_1 = zelen \rangle / S_0) \cdot P(S_0)}{P(\langle pr_1 = zelen \rangle / S_0) \cdot P(S_0) + P(\langle pr_1 = zelen \rangle / S_1) \cdot P(S_1)} = \\
 &= \frac{0,95 \cdot 0,9}{0,95 \cdot 0,9 + 0,02 \cdot 0,1} \approx 0,998; \\
 P(S_0 / \langle pr_1 = krasn \rangle) &= \frac{P(\langle pr_1 = krasn \rangle / S_0) \cdot P(S_0)}{P(\langle pr_1 = krasn \rangle / S_0) \cdot P(S_0) + P(\langle pr_1 = krasn \rangle / S_1) \cdot P(S_1)} = \\
 &= \frac{0,05 \cdot 0,9}{0,05 \cdot 0,9 + 0,98 \cdot 0,1} \approx 0,31.
 \end{aligned} \tag{3}$$

Дана обучающая выборка, представленная в табл. 1.

Опытные данные (обучающая выборка)




Pr1	S
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
krasn	S1
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
zelen	S0
krasn	S0
zelen	S0
zelen	S1

При обучении байесовской сети можно установить различную степень доверия к априорной информации, характеризующуюся объемом априорных данных N_p . В [2] рассматриваются вопросы обоснования веса априорной информации с учетом приоритета опытных данных для повышения точности апостериорной оценки. В данной статье проводились исследования с различными весами априорной информации. Соответственно, если указать вес априорной информации, равный 0 ($N_p = 0$), то в результате обучения будут учитывать лишь опытные данные (рис. 3а). Если установить вес априорной информации, значительно превышающий вес опытных данных ($N_p \gg N_o$), то опытные данные никак не повлияют на параметры

модели (рис. 3б). Если вес априорной информации будет равен весу опытных данных, то в результате машинного обучения получим оценки с одинаковым влиянием опытных данных и априорной информации (рис. 3в).

a)

B)



	S	S0	S1
►	zelen	0.9499990...	0.0200095...
	krasn	0.0500009...	0.9799904...

	S	S0	S1
► zelen		0.9444...	0.5
krasn		0.0555...	0.5

	S	S0	S1
zelen		0.9473...	0.0636...
krasn		0.0526...	0.9363...

Рис. 3. Параметры модели байесовской после обучения при: а) $N_p \gg N_0$;

Анализ полученных результатов показывает, что вероятности видов технического состояния в результате машинного обучения не изменились, так как по обучающей выборке также можно видеть, что опытные значения

Параметры модели байесовской сети после машинного обучения с учетом степени доверия к априорным данным можно вычислить следующим образом:

$$\begin{aligned}
P_a(S_0) &= \frac{N_p}{N_p + N_o} \cdot P_p(S_0) + \frac{N_o}{N_p + N_o} \cdot P_o(S_0) = \frac{20}{20 + 20} \cdot 0,9 + \frac{20}{20 + 20} \cdot \frac{18}{20} = 0,9; \\
P_a(S_1) &= \frac{N_p}{N_p + N_o} \cdot P_p(S_1) + \frac{N_o}{N_p + N_o} \cdot P_o(S_1) = \frac{20}{20 + 20} \cdot 0,1 + \frac{20}{20 + 20} \cdot \frac{2}{20} = 0,1; \\
P_a(\langle pr_1 = zelen \rangle / S_0) &= \frac{N_p}{N_p + N_o(S_0)} \cdot P_p(\langle pr_1 = zelen \rangle / S_0) + \\
&+ \frac{N_p}{N_p + N_o(S_0)} \cdot P_o(\langle pr_1 = zelen \rangle / S_0) = \frac{20}{20 + 18} \cdot 0,95 + \frac{20}{20 + 18} \cdot \frac{17}{18} \approx 0,947; \\
P_a(\langle pr_1 = krasn \rangle / S_0) &= \frac{N_p}{N_p + N_o(S_0)} \cdot P_p(\langle pr_1 = krasn \rangle / S_0) + \\
&+ \frac{N_p}{N_p + N_o(S_0)} \cdot P_o(\langle pr_1 = krasn \rangle / S_0) = \frac{20}{20 + 18} \cdot 0,05 + \frac{20}{20 + 18} \cdot \frac{1}{18} \approx 0,053; \\
P_a(\langle pr_1 = zelen \rangle / S_1) &= \frac{N_p}{N_p + N_o(S_1)} \cdot P_p(\langle pr_1 = zelen \rangle / S_1) + \\
&+ \frac{N_p}{N_p + N_o(S_1)} \cdot P_o(\langle pr_1 = zelen \rangle / S_1) = \frac{20}{20 + 2} \cdot 0,02 + \frac{20}{20 + 2} \cdot \frac{1}{2} \approx 0,064; \\
P_a(\langle pr_1 = krasn \rangle / S_1) &= \frac{N_p}{N_p + N_o(S_1)} \cdot P_p(\langle pr_1 = krasn \rangle / S_1) + \\
&+ \frac{N_p}{N_p + N_o(S_1)} \cdot P_o(\langle pr_1 = krasn \rangle / S_1) = \frac{20}{20 + 2} \cdot 0,98 + \frac{20}{20 + 2} \cdot \frac{1}{2} \approx 0,936.
\end{aligned} \tag{3}$$

Рассмотрим в упрощенном виде процесс диагностирования типовой стойки, входящей состав автоматизированной системы управления технологическим оборудованием стартового комплекса «Союз-2» (АСУ ТО СК «Союз-2») [1]. Исходные данные представлены в таблицах 2 и 3.

Таблица 2

Априорные вероятности видов технического состояния стойки АСУ ТО СК

№ п/п	Название вида технического состояния	Вероятность
1.	Работоспособное – S_0	0,9
2.	Отказ блока питания – S_1 	0,04
3.	Отказ контроллера – S_2 	0,01
4.	Отказ вентилятора – S_3 	0,03
5.	Отказ коммутатора – S_4 	0,02

Таблица 3

Вероятности, связывающие диагностические признаки с видами технического состояния стойки АСУ ТО СК

		Вид технического состояния (S)				
Диагностический признак		S_0	S_1	S_2	S_3	S_4
pr_1 (зеленый индикатор)	горит	1	0	0	0	0
	мигает	0	0	0	0,5	0,5
	не горит	0	1	1	0,5	0,5
pr_2 (красный индикатор)	горит	0	0	1	0,5	0
	мигает	0,5	0	0	0,5	1
	не горит	0,5	1	0	0	0
$pr_3(U)$	да	1	0	0	1	0
	нет	0	1	1	0	1
$pr_4(t^\circ)$	$\leq 35^\circ\text{C}$	1	0	1	0	1
	$> 35^\circ\text{C}$	0	1	0	1	0

Вид байесовской сети представлен на рис. 4.




Рис. 4. Вид байесовской сети стойки, построенной по априорной информации

При поступлении информации о значениях диагностических признаков в результате апостериорного вывода получим следующие оценки вероятностей видов технического состояния, представленные на рисунках 5 и 6.




Рис. 5. Вид байесовской сети стойки при поступлении информации о мигании зеленого индикатора




Рис. 6. Вид байесовской сети стойки при поступлении информации о мигании зеленого индикатора и о том, что температура не превышает 35°C

При определенных сочетаниях значений диагностических признаков, например, при поступлении информации о мигании двух индикаторов, наличии напряжения и не превышении температуры 35°C не может быть получен результат диагностирования, что позволяет сделать вывод о наличии противоречий в исходной информации или наличии неучтенных зависимостей диагностических признаков. В таблице 4 представлена обучающая выборка.

Таблица 4 Обучающая выборка

№ п/п	Pr1	Pr2	Pr3	Pr4	S
1	gorit	ne_gorit	Da	ne_prevushaet_35	S0
2	gorit	ne_gorit	Da	ne_prevushaet_35	S0
3	gorit	ne_gorit	Da	ne_prevushaet_35	S0
4	gorit	migaet	Da	ne_prevushaet_35	S0
5	gorit	ne_gorit	Da	ne_prevushaet_35	S0
6	gorit	ne_gorit	Da	ne_prevushaet_35	S0
7	gorit	ne_gorit	Da	ne_prevushaet_35	S0
8	gorit	ne_gorit	Da	ne_prevushaet_35	S0
9	gorit	ne_gorit	Da	ne_prevushaet_35	S0
10	ne_gorit	gorit	Da	prevushaet_35	S3
11	gorit	ne_gorit	Da	ne_prevushaet_35	S0
12	gorit	ne_gorit	Da	ne_prevushaet_35	S0
13	gorit	ne_gorit	Da	ne_prevushaet_35	S0
14	gorit	ne_gorit	Da	ne_prevushaet_35	S0
15	gorit	ne_gorit	Da	ne_prevushaet_35	S0
16	gorit	ne_gorit	Da	ne_prevushaet_35	S0
17	gorit	ne_gorit	Da	ne_prevushaet_35	S0
18	migaet	ne_gorit	Da	ne_prevushaet_35	S4
19	gorit	ne_gorit	Da	ne_prevushaet_35	S0
20	gorit	ne_gorit	Da	ne_prevushaet_35	S0
21	gorit	ne_gorit	Da	ne_prevushaet_35	S0
22	gorit	ne_gorit	Da	ne_prevushaet_35	S0
23	gorit	ne_gorit	Da	ne_prevushaet_35	S0
24	gorit	ne_gorit	Da	ne_prevushaet_35	S0
25	ne_gorit	gorit	Da	prevushaet_35	S3
26	gorit	ne_gorit	Da	ne_prevushaet_35	S0
27	gorit	ne_gorit	Da	ne_prevushaet_35	S0
28	gorit	ne_gorit	Da	ne_prevushaet_35	S0
29	gorit	ne_gorit	Da	ne_prevushaet_35	S0
30	migaet	migaet	Da	ne_prevushaet_35	S2
31	gorit	ne_gorit	Da	ne_prevushaet_35	S0
32	gorit	ne_gorit	Da	ne_prevushaet_35	S0
33	gorit	ne_gorit	Da	ne_prevushaet_35	S0
34	gorit	ne_gorit	Da	ne_prevushaet_35	S0
35	gorit	ne_gorit	Net	ne_prevushaet_35	S1
36	gorit	ne_gorit	Da	ne_prevushaet_35	S0

№ п/п	Pr1	Pr2	Pr3	Pr4	S
37	gorit	gorit	Da	ne_prevushaet_35	S2
38	migaet	gorit	Da	ne_prevushaet_35	S4
39	ne_gorit	gorit	Da	ne_prevushaet_35	S2
40	gorit	gorit	Da	prevushaet_35	S3
41	migaet	gorit	Da	prevushaet_35	S3
42	ne_gorit	gorit	Da	prevushaet_35	S3
43	gorit	gorit	Net	ne_prevushaet_35	S1
44	migaet	gorit	Net	ne_prevushaet_35	S1
45	ne_gorit	gorit	Net	ne_prevushaet_35	S1
46	gorit	gorit	Net	prevushaet_35	S1
47	migaet	gorit	Net	prevushaet_35	S1
48	ne_gorit	gorit	Net	prevushaet_35	S1
49	gorit	migaet	Da	ne_prevushaet_35	S0
50	migaet	migaet	Da	ne_prevushaet_35	S2
51	ne_gorit	migaet	Da	ne_prevushaet_35	S4
52	gorit	migaet	Da	prevushaet_35	S3
53	migaet	migaet	Da	prevushaet_35	S3
54	ne_gorit	migaet	Da	prevushaet_35	S3
55	gorit	migaet	Net	ne_prevushaet_35	S1
56	migaet	migaet	Net	ne_prevushaet_35	S1
57	ne_gorit	migaet	Net	ne_prevushaet_35	S4
58	gorit	migaet	Net	prevushaet_35	S3
59	migaet	migaet	Net	prevushaet_35	S1
60	ne_gorit	migaet	Net	prevushaet_35	S1
61	gorit	ne_gorit	Da	ne_prevushaet_35	S0
62	migaet	ne_gorit	Da	ne_prevushaet_35	S4
63	ne_gorit	ne_gorit	Da	ne_prevushaet_35	S0
64	gorit	ne_gorit	Da	prevushaet_35	S3
65	migaet	ne_gorit	Da	prevushaet_35	S3
66	ne_gorit	ne_gorit	Da	prevushaet_35	S3
67	gorit	ne_gorit	Net	ne_prevushaet_35	S1
68	migaet	ne_gorit	Net	ne_prevushaet_35	S1
69	ne_gorit	ne_gorit	Net	ne_prevushaet_35	S1
70	gorit	ne_gorit	Net	prevushaet_35	S4
71	migaet	ne_gorit	Net	prevushaet_35	S1
72	ne_gorit	ne_gorit	Net	prevushaet_35	S1

В результате машинного обучения получим следующую скорректированную модель (рис. 7).




Рис. 7. Вид байесовской сети стойки после обучения при $N_p = N_o$ (равновесном учете априорных и статистических данных)

Таблица 5

Уточненные в результате машинного обучения вероятности, связывающие диагностические признаки с видами технического состояния стойки АСУ ТО СК

		Вид технического состояния (S)				
Диагностический признак		S_0	S_1	S_2	S_3	S_4
pr ₁ (зеленый индикатор)	горит	0,99	0,057	0,0132	0,048	0,0128
	мигает	0	0,068	0,0263	0,464	0,5
	не горит	0,01	0,875	0,9605	0,488	0,4872
pr ₂ (красный индикатор)	горит	0	0,0682	0,974	0,488	0,0128
	мигает	0,358	0,0454	0,026	0,476	0,9487
	не горит	0,642	0,8864	0	0,036	0,0385
pr ₃ (U)	да	1	0	0,053	0,988	0,051
	нет	0	1	0,947	0,012	0,949
pr ₄ (t°)	$\leq 35^\circ\text{C}$	1	0,1	1	0	0,987
	$> 35^\circ\text{C}$	0	0,9	0	1	0,013

Структурно-параметрическое обучение модели байесовской сети для решения задач диагностирования сложных технических систем

С помощью обучающей выборки можно провести также структурное обучение [16-20] для коррекции структуры модели. На рис. 8 представлена структура модели, полученная по обучающей выборке.




Рис. 8. Полученная структура модели в результате обучения

Как видно из рис. 8, в результате структурного обучения выявлены связи только между переменной вида технического состояния и переменными диагностических признаков, между диагностическими признаками данная связь отсутствует, что позволяет сделать вывод о независимости диагностических признаков.

Как видно из анализа обучающей выборки (табл. 4), первая ее часть (значения с 1-го по 36-е) содержат редкие отказы, что может соответствовать этапу нормальной эксплуатации. Проведем структурное обучение, используя лишь вторую часть обучающей выборки (значения с 37-го по 72-е из табл. 4). Данная часть обучающей

выборки более разнообразна и может рассматриваться как этап старения (деградации) системы, когда часто происходят отказы. На рис. 9 представлена полученная структура модели.




Рис. 9. Полученная структура модели в результате обучения

Как видно из рис. 9, в ходе структурного обучения были выявлены связи не только между переменной видов технического состояния S и переменными диагностических признаков, но и связи между некоторыми диагностическими признаками. Например, значения признаков Pr_1 и Pr_2 зависят от значений признаков Pr_3 и Pr_4 , при этом Pr_1 и Pr_2 между собой не имеют зависимости. Связь между Pr_3 , Pr_4 и S выявлена, но требует уточнения, что является причиной, а что следствием. На рис. 10 и 11 представлены результаты структурно-параметрического обучения байесовской сети и апостериорного вывода в полученной модели соответственно. При этом из рис. 11 видно, что по ранее необрабатываемому сочетанию значений диагностических признаков (мигание двух индикаторов, наличие напряжения и не

превышение температуры 35°C) можно получить результат диагностирования или убрать из рассмотрения менее вероятные диагнозы.




Рис. 10. Полученная структура модели в результате обучения




Рис. 11. Апостериорный вывод в модели, полученной в результате структурно-параметрического обучения

Заключение

Таким образом, в статье рассматривается применение алгоритмов машинного обучения байесовских сетей для решения задач диагностирования сложных технических систем. Указывается на возможность учета априорной информации при обучении, что позволяет использовать обучающие выборки достаточно небольшого объема в сравнении с нейронными сетями. Значительное внимание обращено на структурно-параметрическое обучение, позволяющее корректировать не только параметры модели, но и синтезировать структуру самой модели, что может быть использовано для выявления зависимостей между диагностическими признаками.

Список источников

1. Автоматизация технологических процессов и производств: учебник / В.А. Белозеров и др.; под редакцией А.Б. Кузнецова – СПб.: ВКА имени А.Ф. Можайского, 2014. – 284 с.
2. Арсеньев В.Н. Оценивание характеристик систем управления по ограниченному числу натурных испытаний. М.: Рестарт. – 2013. – 126 с.
3. Воронцов В.А. Разработка прототипа интеллектуальной системы оперативного мониторинга и технического состояния основных бортовых систем космического аппарата / В.А. Воронцов, Е.А. Федоров // Труды МАИ. – 2015. – № 82. URL: <https://trudymai.ru/published.php?ID=58817> (дата обращения 16.05.2024).

4. Дмитриев А.К. Модели и методы анализа технического состояния бортовых систем: учебное пособие. – СПб.: ВИКУ имени А.Ф. Можайского, 1999. – 171 с.
5. Дорожко И. В. Модель системы поддержки принятия решений для диагностирования бортовых систем космического аппарата на основе байесовских сетей / И. В. Дорожко, О. А. Иванов // Труды МАИ. – 2021. – № 118. URL: <https://trudymai.ru/published.php?ID=158259> (дата обращения 16.05.2024).
6. Дорожко И.В. Модель оценки вероятности безотказной работы сложных технических комплексов на основе динамических байесовских сетей / И.В. Дорожко, Е.А. Захарова, Н.А. Осипов. // Труды Военно-космической академии им. А.Ф. Можайского. – СПб., 2019. – № 669 – С. 216 – 223.
7. Дорожко И.В., Осипов Н.А., Иванов О.А. Прогнозирование технического состояния сложных технических систем с помощью метода Берга и байесовских сетей // Труды МАИ. – 2020. – №113. URL: <http://trudymai.ru/published.php?ID=118181> (дата обращения 16.05.2024).
8. Заведеев, А.И. Диагностика состояния и принципы повышения отказоустойчивости бортовой системы управления космического аппарата / А.И. Заведеев, А.Ю. Ковалев // Труды МАИ. – 2012. – № 54. URL: <https://trudymai.ru/published.php?ID=29688> (дата обращения 16.05.2024).
9. Кобзарев И.М. Использование меры ценности информации В.И. Корогодина для построения гибких диагностических процедур распознавания технического состояния бортовых систем космических аппаратов / И.М. Кобзарев, Е.В. Копкин. // Труды Военно-космической академии им. А.Ф. Можайского. – СПб., 2019. – № 671 – С. 326 – 337.

10. Копейка Е.А. Методический подход оценивания вероятности безотказной работы сложных технических систем с учетом характеристик системы контроля на основе байесовской сети доверия / Е.А. Копейка, А.В. Вербин // Труды МАИ. – 2023. – № 128. URL: <https://trudymai.ru/published.php?ID=171411> (дата обращения 16.05.2024).
11. Копкин Е.В., Кравцов А.Н., Мышко В.В. Анализ технического состояния космических средств. – СПб.: ВКА имени А.Ф. Можайского, 2016. – 189 с.
12. Копкин Е.В., Кравцов А.Н., Мышко В.В. Контроль и диагностика космических средств: учебное пособие – СПб.: ВКА имени А.Ф. Можайского, 2016. – 198 с.
13. Митькин М.А., Гаврилов К.Ю. Применение искусственных нейронных сетей для восстановления объектов на радиолокационных изображениях // Труды МАИ. 2025. № 141. URL: <https://trudymai.ru/published.php?ID=184505> (дата обращения 16.05.2024).
14. Сукар Л.Э. Вероятностные графовые модели. Принципы и приложения / пер. с англ. А.В. Снастина. – М.: ДМК Пресс, 2021. – 338 с.: ил.
15. Тонких А.Н. Применение нейросетевых технологий для распознавания распределенных объектов на радиолокационных изображениях // Труды МАИ. 2025. № 141. URL: <https://trudymai.ru/published.php?ID=184504> (дата обращения 16.05.2024).
16. Тулупьев А.Л., Николенко С.И., Сироткин А.В. Основы теории байесовских сетей: учебник. – СПб.: Изд-во С.-Петербург. ун-та, 2019. – 399 с.
17. Cowell R.G., Dawid A.P., Lauritzen S.L., Spiegelhalter D.J. Probabilistic Networks and Expert Systems. Springer-Verlag, 1999.

18. GeNIe & SMILE // Decisions systems laboratory. School of Information Sciences. University of Pittsburg. URL: <http://genie.sis.pitt.edu/> (дата обращения 16.05.2024).
19. Jensen F.V. Bayesian Networks and Decision Graphs. New York: Springer-Verlag, 2001.
20. Pearl J. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference. New York: Morgan Kaufman Publ., 1991.

References

1. Belozеров V.A. et al. Avtomatizatsiya tekhnologicheskikh protsessov i proizvodstv (Automation of technological processes and productions), Saint Petersburg, VKA imeni A.F. Mozhaiskogo, 2014, 284 p.
2. Arsen'ev V.N. Otsenivanie kharakteristik sistem upravleniya po ogranichennomu chislu naturnykh ispytaniy (Evaluation of control system characteristics based on a limited number of verification tests), Moscow, Restart, 2013, 126 p.
3. Vorontsov V.A., Fedorov E.A. Trudy MAI, 2018, no. 82, URL: <https://trudymai.ru/published.php?ID=58817> (accessed 05.05.2025).
4. Dmitriev A.K. Modeli i metody analiza tekhnicheskogo sostoyaniya bortovykh system (Models and methods of analysis of the technical condition of on-board systems: training manual), Saint Petersburg, VIKU imeni A.F. Mozhaiskogo, 1999, 171 p.
5. Dorozhko I.V., Ivanov O.A. Trudy MAI, 2021, no. 118, URL: <https://trudymai.ru/published.php?ID=158259> (accessed 05.05.2025).
6. Dorozhko I.V., Zakharova E.A., Osipov N.A. Trudy Voenno-kosmicheskoi akademii im. A.F. Mozhaiskogo, 2019, no. 669, pp. 216 – 223.

7. Dorozhko I.V., Osipov N.A., Ivanov O.A. Trudy MAI, 2020, no. 113. URL: <http://trudymai.ru/eng/published.php?ID=118181> (accessed 05.05.2025).
8. Zavedeev A.I. Trudy MAI, 2012, no. 54, URL: <https://trudymai.ru/published.php?ID=29687> (accessed 05.05.2025).
9. Kobzarev I.M. Kopkin E.V. Trudy Voenno-kosmicheskoi akademii im. A.F. Mozhaiskogo, 2019, no. 671, pp. 326 – 337.
10. Kopeika E.A., Verbin A.V. Trudy MAI, 2023, no. 128, URL: <https://trudymai.ru/published.php?ID=171411> (accessed 05.05.2025).
11. Kopkin E.V., Kravtsov A.N., Myshko V.V. Analiz tekhnicheskogo sostoyaniya kosmicheskikh sredstv (Analysis of the technical condition of space assets), Saint Petersburg, VKA imeni A.F. Mozhaiskogo, 2016, 189 p.
12. Kopkin E.V., Kravtsov A.N., Myshko V.V. Kontrol' i diagnostika kosmicheskikh sredstv (Control and diagnosis of space tools: a training manual), Saint Petersburg, VKA imeni A.F. Mozhaiskogo, 2016, 198 p.
13. Mit'kin M.A., Gavrilov K.Yu. Trudy MAI, 2025, no. 141, URL: <https://trudymai.ru/published.php?ID=184505> (accessed 05.05.2025).
14. Luis Enrique Sucar. Veroyatnostnye grafovye modeli. Printsipy i prilozheniya (Probabilistic Graphical Models. Principles and Applications), Moscow, DMK Press, 2021, 338 p.
15. Tonkikh A.N. Trudy MAI, 2025, no. 141, URL: <https://trudymai.ru/published.php?ID=184504> (accessed 05.05.2025).

16. Tulup'ev A.L., Nikolenko S.I., Sirotkin A.V. Osnovy teorii baiesovskikh setei. (The basics of the theory of Bayesian networks), Saint-Petersburg, Izd-vo Sankt-Peterburgskogo universiteta, 2019, 399 p.
17. Cowell R.G., Dawid A.P., Lauritzen S.L., Spiegelhalter D.J. Probabilistic Networks and Expert Systems, New York, Springer-Verlag, 1999. DOI:[10.1198/JASA.2001.S424](https://doi.org/10.1198/JASA.2001.S424)
18. GeNie & SMILE. Decisions systems laboratory, School of Information Sciences, University of Pittsburg. URL: <https://www.innovation.pitt.edu/pitt-startups/bayesfusion/>.
19. Jensen F.V. Bayesian Networks and Decision Graphs, New York, Springer-Verlag, 2001. DOI:[10.1007/978-1-4757-3502-4](https://doi.org/10.1007/978-1-4757-3502-4)
20. Pearl J. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, New York, Morgan Kaufman Publ., 1991, [DOI:10.2307/2026705](https://doi.org/10.2307/2026705).