
МЕТОДЫ И ПРИБОРЫ ДЛЯ АНАЛИЗА И КОНТРОЛЯ МАТЕРИАЛОВ, ИЗДЕЛИЙ, ВЕЩЕСТВ И ПРИРОДНОЙ СРЕДЫ

METHODS AND INSTRUMENTS FOR ANALYSIS AND MONITORING OF THE NATURAL ENVIRONMENT, SUBSTANCES, MATERIALS AND PRODUCTS

УДК 004.896
DOI: 10.17586/0021-3454-2025-68-2-168-175

ИНТЕЛЛЕКТУАЛЬНОЕ ДИАГНОСТИРОВАНИЕ СИСТЕМЫ ВЕНТИЛЯЦИИ И КОНДИЦИОНИРОВАНИЯ ВОЗДУХА ЧИСТОГО ПОМЕЩЕНИЯ

Ю. Е. Тупицин, А. С. Матюнин, М. В. Егоричев, А. А. Голуб

Военно-космическая академия им. А. Ф. Можайского, Санкт-Петербург, Россия
vka@mil.ru

Аннотация. Предложен подход к обучению диагностических моделей сложных технических систем при множественной неопределенности априорной информации. Поскольку невозможно определить закон распределения значений параметров рабочих процессов, предложено использовать методы непараметрической статистики. Процедура обучения базируется на использовании топологии и свойств конечномерных евклидовых пространств. Приведен пример процедуры обучения с применением вычислительной схемы по алгоритму Роббинса–Монро. Представлена графическая интерпретация построения эталона параметрического отказа элемента при построении диагностических моделей оборудования системы вентиляции и кондиционирования воздуха чистого помещения специального объекта.

Ключевые слова: контролируемые параметры рабочих процессов, методы обучения, диагностическая модель, техническое состояние, алгоритм Роббинса–Монро

Ссылка для цитирования: Тупицин Ю. Е., Матюнин А. С., Егоричев М. В., Голуб А. А. Интеллектуальное диагностирование системы вентиляции и кондиционирования воздуха чистого помещения // Изв. вузов. Приборостроение. 2025. Т. 68, № 2. С. 168–175. DOI: 10.17586/0021-3454-2025-68-2-168-175.

INTELLIGENT DIAGNOSTICS OF CLEANROOM VENTILATION AND AIR CONDITIONING SYSTEMS

Yu. E. Tupitsin, A. S. Matyunin, M. V. Egorichev, A. A. Golub

A. F. Mozhaisky Military Space Academy, St. Petersburg, Russia
vka@mil.ru

Abstract. An approach to training diagnostic models of complex technical systems with multiple uncertainty of a priori information is proposed. Since it is impossible to determine the law of distribution of values of parameters of working processes, it is proposed to use methods of nonparametric statistics. The training procedure is based on the use of topology and properties of finite-dimensional Euclidean spaces. An example of a training procedure using a computational scheme according to the Robbins-Monroe algorithm is given. A graphical interpretation of the construction of a standard of parametric failure of an element when constructing diagnostic models of equipment of the ventilation and air conditioning system of a clean room of a special facility is presented.

Keywords: controlled workflow parameters, training methods, diagnostic model, technical condition, Robbins–Monroe algorithm

For citation: Tupitsin Yu. E., Matyunin A. S., Egorichev M. V., Golub A. A. Intelligent diagnostics of cleanroom ventilation and air conditioning systems. *Journal of Instrument Engineering*. 2025. Vol. 68, N 2. P. 168–175 (in Russian). DOI: 10.17586/0021-3454-2025-68-2-168-175.

Введение. Системы вентиляции и кондиционирования воздуха чистых помещений специальных объектов (СВКВ) представляют собой сложные технические системы, от надеж-

ного и качественного функционирования которых зависит возможность выполнения целевых задач в установленные сроки. Выход параметров тепловлажностного режима, газового состава и чистоты воздуха за заданные пределы характеризуется как параметрический отказ СВКВ, он приводит к прекращению работ в чистом помещении. Поэтому задача оперативного определения причины возникшего отказа является весьма актуальной.

Для повышения скорости поиска отказа и достоверности принятого решения о текущем техническом состоянии необходимо развивать подходы, алгоритмы и методы диагностирования сложных технических систем в целом и в том числе — СВКВ. Предлагается использовать формализованное описание неработоспособного состояния. Основой для построения описаний неработоспособных состояний служат дрейф параметров с течением времени и изменение технического состояния системы. При параметрическом отказе система продолжает функционировать и возможна регистрация параметров. В теории распознавания образов представление отказа в формализованном виде называется изображением [1]. Иерархия и взаимосвязь всех изображений системы представляют собой модель диагностирования СВКВ.

В научных исследованиях, посвященных диагностированию [2–9], не уделяется должного внимания повышению достоверности принятия решения о техническом состоянии и эффективному использованию априорной информации о рабочих процессах.

Получение исходной информации о параметрических отказах системы является одним из сложных этапов построения и обучения модели диагностирования. Поэтому полученные данные, как правило, характеризуются множественной неопределенностью. В настоящей статье развиваются подходы [3, 10] к моделированию на основе ограниченного объема неоднородных данных.

Задача моделирования. Для реализации алгоритмов диагностирования при ограниченной априорной информации о значениях параметров, характеризующих техническое состояние СВКВ, а также параллельной обработки этой информации необходима структурированная модель системы, включающая модели изображений технического состояния ее элементов.

Для построения диагностической модели системы, состоящей из изображений элементов, введем следующие обозначения:

— неработоспособные состояния системы:

$$Q = \{q_i | i = \overline{1, m}\}, \quad (1)$$

где $q_i, i = \overline{1, m}$ — технические состояния СВКВ;

— контролируемые параметры:

$$Y = (y_1, y_2, \dots, y_n)^T, \quad (2)$$

где $y_j, j = \overline{1, n}$ — значения контролируемых параметров;

— исходные данные об отказах для обучения модели диагностирования:

$$\begin{aligned} \{Y_1 | k = \overline{1, N_1}\} &\subset Y_1; \\ \{Y_2 | k = \overline{1, N_2}\} &\subset Y_2; \\ \{Y_m | k = \overline{1, N_m}\} &\subset Y_m; \end{aligned} \quad (3)$$

где Y_i — подмножество контролируемых параметров, принадлежащих i -му неработоспособному состоянию СВКВ, $i = \overline{1, m}$; N_i — мощность Y_i .

Неработоспособное состояние $i = \overline{1, m}$ представим как область в n -мерном евклидовом пространстве Y , охватывающую подмножество контролируемых параметров Y_i . Области видов технических состояний могут пересекаться [1, 3]. Для повышения достоверности диагностирования, чтобы отделить друг от друга области Y_i , заменим их изображением (эталоном) соответствующего неработоспособного состояния:

$$\mathbf{E}_i = (e_{i1}, e_{i2}, \dots, e_{in})^T, i = \overline{1, m}, \quad (4)$$

которое достаточно точно описывает свойства представленной области Y_i [1, 3, 4]. Построение соответствующего эталона $\mathbf{E}_i$ в процессе использования элементов Y_i показывает, что полученное множество $E = \{\mathbf{E}_i | i = \overline{1, m}\}$ обладает теми же свойствами и содержится в пространстве $E \subset Y$.

Получение однородных априорных данных (3), необходимых для обучения модели диагностирования, — достаточно сложная задача. В общем случае часть данных записывается аппаратурой мониторинга на аналогичных СВКВ системах, недостающую часть можно получить с помощью экспертов, поэтому исходная априорная статистическая информация является неоднородной.

Для построения модели диагностирования, основанной на эталонах неработоспособных состояний функциональных элементов с применением неоднородных данных, предлагается использовать один из методов непараметрической статистики — метод стохастической аппроксимации. В настоящей статье предлагается процедура на основе эффективного рекуррентного алгоритма Роббинса–Монро [3, 10], представляемого выражением:

$$\mathbf{E}_i(k) = \mathbf{E}_i(k-1) - \frac{1}{k}[\mathbf{E}_i(k-1) - G(\mathbf{Y}_i(k))], i = \overline{1, m}, \quad (5)$$

где $k = 2, 3, \dots, N$.

Выражение (5) содержит ортогональное преобразование состояния $\mathbf{Y}$:

$$G(\mathbf{Y}) = (g_1(\mathbf{Y}), g_2(\mathbf{Y}), \dots, g_n(\mathbf{Y}))^T. \quad (6)$$

Применение (6) позволяет исключить возможную взаимозависимость контролируемых параметров [3, 9]. Система (6) строится на основе ортогонального тригонометрического базиса, следовательно, ее координаты формируются следующим образом:

$$g_r(\mathbf{Y}) = \begin{cases} \delta_{rj} \sin(ky_j), & k = \frac{j+1}{2}, j \text{ — нечетно,} \\ \delta_{rj} \cos(ky_j), & k = \frac{j}{2}, j \text{ — четно,} \\ r, j = \overline{1, n}, \end{cases} \quad (7)$$

где $\delta_{rj} = \begin{cases} 1, & \text{если } r = j \\ 0, & \text{если } r \neq j \end{cases}$ — дельта Кронекера.

Применив рекуррентное выражение (5), получим изображение $\mathbf{E}_i(k)$ на последующем шаге обучения с использованием этого же изображения $\mathbf{E}_i(k-1)$ на предыдущем шаге и следующего элемента $\mathbf{Y}_i(k)$ выборки (3).

Изображение $\mathbf{E}_i(1)$ на первом шаге формируется в соответствии с условием:

$$\mathbf{E}_i(1) = G(\mathbf{Y}_i(1)). \quad (8)$$

Процесс обучения начинается с построения первого изображения G преобразованного элемента исходных данных (3), далее применяется рекуррентное выражение (5).

Благодаря применению ортогонального тригонометрического базиса (7) значения координат изображения e_{ij} не выходят из интервала $[-1; 1]$. Таким образом, в случае использования алгоритма Роббинса–Монро при стохастической аппроксимации пространство значений контролируемых параметров Y преобразуется в новое замкнутое пространство $G(Y)$, в котором координаты элементов также ограничены диапазоном $[-1; 1]$.

Теоретически в случае избытка исходных данных (3) неограниченное количество шагов обучения ($k \rightarrow \infty$) позволяет получить эталон $\mathbf{E}_i^*$, для которого справедливо следующее выражение:

$$\lim_{k \rightarrow \infty} \rho(\mathbf{E}_i(k), \mathbf{E}_i^*) = 0, \quad (9)$$

$$\rho(\mathbf{E}_i(k), \mathbf{E}_i^*) = \left(\sum_{j=1}^n (e_{ij}^* - e_{ij}(k))^2 \right)^{0,5}. \quad (10)$$

Выражение (10) описывает евклидово расстояние между векторами $\mathbf{E}_i(k)$ и $\mathbf{E}_i^*$.

При ограниченном количестве исходных данных в качестве эталона принимается вектор $\mathbf{E}_i^*$, который представляет собой оптимальное изображение и характеризуется таким свойством, как минимум суммарного расстояния в пространстве $G(Y)$ между эталоном и всеми G преобразованными значениями исходных данных:

$$\sum_{p: \mathbf{Y}_p \in \mathbf{Y}_i} \rho(\mathbf{E}_i^*, G(\mathbf{Y}_p)) = \min_{\mathbf{E}_i(k) \in G(\mathbf{Y}_i)} \left\{ \sum_{p: \mathbf{Y}_p \in \mathbf{Y}_i} \rho(\mathbf{E}_i(k), G(\mathbf{Y}_p)) \right\}. \quad (11)$$

Хотелось бы отметить, что выражения (9) и (11) отражают теоретическую сторону вопроса. Для получения исходных данных о неработоспособных состояниях новых систем необходимы длительные наблюдения, анализ и фиксация значений параметров, характеризующих это состояние. Таким образом, имеются ограниченные исходные данные объемом N_i , $i = \overline{1, m}$. Полученное в процессе обучения с использованием всех элементов исходных данных изображение $\mathbf{E}_i$ принимаем равным эталону $\mathbf{E}_i^*$:

$$\mathbf{E}_i^* = \mathbf{E}_i(N_i). \quad (12)$$

В завершение процесса обучения элемента модели диагностирования предлагается использовать расстояние в пространстве $G(Y)$ между векторами изображения на предыдущем и последующем шагах обучения:

$$\rho(\mathbf{E}_i(k), \mathbf{E}_i(k+1)) \leq a, a \in \mathbf{R}^+, i = \overline{1, m}. \quad (13)$$

Условие завершения процесса обучения (13) выбирается исходя из решаемой задачи [10].

Рекуррентный способ обучения модели подразумевает возможность использования информации, полученной на последующих этапах эксплуатации. При выполнении условия (13) принимается, что:

$$\mathbf{E}_i^* = \mathbf{E}_i(k+1). \quad (14)$$

Пример. В качестве примера рассмотрим СВКВ, обеспечивающую подготовку и подачу воздуха в чистое помещение. Введем ограничение: рассматриваются два измеряемых параметра: t — температура в помещении ($^{\circ}\text{C}$), Q — расход подаваемого воздуха ($\text{м}^3/\text{ч}$). Известны интервалы значений диагностических параметров, соответствующих работоспособному состоянию: $t = 18\text{--}25^{\circ}\text{C}$, $Q = 12\ 300\text{--}13\ 500\ \text{м}^3/\text{ч}$.

Условимся, что СВКВ оперативно сигнализирует об отклонении параметров от нормы [8]. Для вентилятора рассматривается именно нижний предел значений, когда подача воздуха уменьшается в силу неисправности привода электродвигателя или иных факторов.

На основании изложенного сформирована обучающая выборка мощностью $N_i = 10$ значений параметров неработоспособного состояния вентилятора (табл. 1).

Таблица 1

№ п/п	Вектор состояния	$t, ^{\circ}\text{C}$	$Q, \text{м}^3/\text{ч}$
1	$\mathbf{Y}_в(1)$	19,48	12240,00
2	$\mathbf{Y}_в(2)$	20,40	12245,00
3	$\mathbf{Y}_в(3)$	20,64	12230,00
4	$\mathbf{Y}_в(4)$	19,16	12235,00
5	$\mathbf{Y}_в(5)$	20,72	12247,00
6	$\mathbf{Y}_в(6)$	19,40	12200,00
7	$\mathbf{Y}_в(7)$	19,66	12180,00
8	$\mathbf{Y}_в(8)$	20,20	12238,00
9	$\mathbf{Y}_в(9)$	20,96	12244,00
10	$\mathbf{Y}_в(10)$	19,74	12241,00

Из сопоставления координат элементов выборки табл. 1 и диапазонов $t = 18\text{--}25\text{ }^{\circ}\text{C}$, $Q = 12\,300\text{--}13\,500\text{ м}^3/\text{ч}$ следует, что все диагностические параметры не попадают в область работоспособности. Графически значения параметров формируют область неработоспособного состояния вентилятора, которая представлена в нижней части рис. 1.




Рис. 1

Процедура обучения модели выполнена в соответствии с выражениями (9), (10) и (13), полученные результаты отражены в табл. 2 и 3. Аналогичные процедуры выполнены для построения области неработоспособного состояния калорифера, соответствующие данные представлены в табл. 4–6.

Таблица 2

$E_B(1)$	$E_B(2)$	$E_B(3)$	$E_B(4)$	$E_B(5)$	$E_B(6)$	$E_B(7)$	$E_B(8)$	$E_B(9)$	$E_B(10)$
0,59	0,80	0,86	0,72	0,77	0,73	0,73	0,76	0,77	0,77
0,94	0,77	0,19	0,12	0,19	0,10	−0,06	−0,06	−0,09	−0,06

На рис. 2 красная кривая соответствует процедуре обучения: с увеличением числа шагов изображение приближается к оптимальному, о чем свидетельствует уменьшение расстояния между шагами обучения (табл. 3).

Таблица 3

Шаг обучения	Размер шага
$\rho(E_B(1), E_B(2))$	0,27
$\rho(E_B(2), E_B(3))$	0,59
$\rho(E_B(3), E_B(4))$	0,15
$\rho(E_B(4), E_B(5))$	0,09
$\rho(E_B(5), E_B(6))$	0,10
$\rho(E_B(6), E_B(7))$	0,16
$\rho(E_B(7), E_B(8))$	0,03
$\rho(E_B(8), E_B(9))$	0,03
$\rho(E_B(9), E_B(10))$	0,03

Таблица 4

№ п/п	Вектор состояния	$t, ^{\circ}\text{C}$	$Q, \text{м}^3/\text{ч}$
1	$Y_K(1)$	16,36	12475,00
2	$Y_K(2)$	17,36	13187,50
3	$Y_K(3)$	17,82	12587,00
4	$Y_K(4)$	17,78	12587,50
5	$Y_K(5)$	17,96	12550,00
6	$Y_K(6)$	16,10	13887,50
7	$Y_K(7)$	17,40	12712,50
8	$Y_K(8)$	17,22	12832,50
9	$Y_K(9)$	17,74	12832,50
10	$Y_K(10)$	17,04	12790,50

Таблица 5

$E_K(1)$	$E_K(2)$	$E_K(3)$	$E_K(4)$	$E_K(5)$	$E_K(6)$	$E_K(7)$	$E_K(8)$	$E_K(9)$	$E_K(10)$
-0,61	-0,81	-0,82	-0,84	-0,83	-0,75	-0,79	-0,81	-0,82	-0,84
-0,97	-0,18	-0,33	-0,41	-0,49	-0,47	-0,41	-0,42	-0,44	-0,45

Таблица 6

Шаг обучения	Размер шага
$\rho(E_K(1), E_K(2))$	0,82
$\rho(E_K(2), E_K(3))$	0,16
$\rho(E_K(3), E_K(4))$	0,08
$\rho(E_K(4), E_K(5))$	0,08
$\rho(E_K(5), E_K(6))$	0,08
$\rho(E_K(6), E_K(7))$	0,07
$\rho(E_K(7), E_K(8))$	0,03
$\rho(E_K(8), E_K(9))$	0,02
$\rho(E_K(9), E_K(10))$	0,02




Рис. 2

В качестве эталона принимаем изображение $E_{в}(10)$ как последнее (12), обобщающее свойства всей выборки (табл. 1). Тем самым, точка **C** является эталоном неработоспособного состояния вентилятора.

Таким образом, на рис. 2 представлен результат получения эталонов отказов $E_K^* = B$ и $E_{в}^* = C$ в процессе обучения модели, которые обладают свойствами двух областей неработоспособного состояния, соответствующих отказам элементов СВКВ (рис. 2).

Исходя из вышесказанного, при получении решения о неработоспособности системы фиксируются значения параметров, которые обозначены точками **A** и **D** на рис. 2.

Для определения области технического состояния, к которой относятся данные отказы, необходимо полученный вектор подвергнуть G -преобразованию и классифицировать (распознавать) его. Распознавание предлагается проводить метрическим способом [1, 10]. Критерием распознавания вида неработоспособного состояния является минимальное значение расстояния. Например, получено значение параметров:

$$\rho_1(G(A), B) < \rho_2(G(A), C). \quad (16)$$

Отказ соответствует неработоспособному состоянию, который находится наиболее близко к эталону, в данном случае: **A** — неработоспособному состоянию калорифера, а **D** — вентилятора.

Закключение. Использование методов стохастической аппроксимации при моделировании неработоспособных состояний сложных систем с применением алгоритма Роббинса–Монро позволяет рационально использовать имеющуюся информацию о параметрах сложной системы. Используя описанный поход к обучению модели диагностирования, можно получить новое множество формализованных неработоспособных состояний. Каждое такое неработоспособное состояние математически описывает конкретный параметрический отказ функционального элемента. Модель диагностирования построена и обучена в метрике евклидовых пространств, такой подход позволяет распознавать или диагностировать неработоспособное состояние с применением метода эталонов, когда для обучения модели использованы исходные данные малого объема.

СПИСОК ЛИТЕРАТУРЫ

1. Фомин Я. А. Распознавание образов. Теория и применения. М.: Фазис, 2010. 368 с.
2. Лобан А. В. Информационная технология распределенного диагностирования космических аппаратов. М.–Берлин: Директ-Медиа, 2015. 146 с.
3. Сеньченков В. И. Модели, методы и алгоритмы анализа технического состояния. Saarbrücken: LAP LAMBERT Academic Publishing, 2013. 377 с.
4. Chunhui Z., Furong G. Online fault prognosis with relative deviation analysis and vector autoregressive modeling // *Chemical Engineering Science*. 2015. Vol. 138. P. 531–543.
5. Lu G., Zhou Y., Lu C., Li X. A novel framework of change-point detection for machine monitoring // *Mechanical Systems and Signal Processing*. 2017. Vol. 83. P. 533–548.
6. Будко П. А., Винограденко А. М., Литвинов А. И. Экспериментальные исследования кинетического метода контроля и диагностики технических средств // *Мехатроника, автоматизация, управление*. 2014. № 9. С. 53–58.
7. Liu W. Y., Gao Q. W., Ye G. et al. A novel wind turbine bearing fault diagnosis method based on Integral Extension LMD // *Measurement*. 2015. Vol. 74. P. 70–77.
8. Skliros C., Esperon M. M., Fakhre A., Jennions I. K. A review of model based and data driven methods targeting hardware systems diagnostics // *Diagnostyka*. 2019. Vol. 20(1). P. 3–21.
9. Shi P., Liang K., Han D., Zhang Yi. A novel intelligent fault diagnosis method of rotating machinery based on deep learning and PSO-SVM // *Journal of Vibroengineering*. 2017. Vol. 19(8). P. 5932–5946.
10. Сеньченков В. И., Матюнин А. С. Повышение сходимости обучающих процедур при разработке моделей диагностирования систем // *Приборы и системы. Управление, контроль, диагностика*. 2020. № 8. С. 18–26.

СВЕДЕНИЯ ОБ АВТОРАХ

- Юрий Евгеньевич Тупицин** — канд. техн. наук, доцент; ВКА им. А.Ф. Можайского, кафедра систем жизнеобеспечения объектов наземной космической инфраструктуры; доцент; E-mail: vka@mil.ru
- Александр Сергеевич Матюнин** — канд. техн. наук; ВКА им. А.Ф. Можайского, кафедра систем жизнеобеспечения объектов наземной космической инфраструктуры; преподаватель; E-mail: vka@mil.ru
- Максим Вячеславович Егоричев** — ВКА им. А.Ф. Можайского, кафедра систем жизнеобеспечения объектов наземной космической инфраструктуры; адъюнкт; E-mail: vka@mil.ru
- Андрей Алексеевич Голуб** — ВКА им. А.Ф. Можайского, кафедра систем жизнеобеспечения объектов наземной космической инфраструктуры; курсант; E-mail: vka@mil.ru

Поступила в редакцию 02.05.24; одобрена после рецензирования 16.09.24; принята к публикации 25.12.24.

REFERENCES

1. Fomin Ya. A. *Raspoznavaniye obrazov. Teoriya i primeneniya* (Pattern Recognition. Theory and Applications), Moscow, 2010, 368 p. (in Russ.)
2. Loban A.V. *Informatsionnaya tekhnologiya raspredelennogo diagnostirovaniya kosmicheskikh apparatov* (Information Technology of Distributed Diagnostics of Spacecraft), Moscow, Berlin, 2015, 146 p. (in Russ.)
3. Senchenkov V.I. *Modeli, metody i algoritmy analiza tekhnicheskogo sostoyaniya* (Models, Methods and Algorithms for Technical Condition Analysis), Saarbrücken, 2013, 377 p. (in Russ.)
4. Chunhui Z., Furong G. *Chemical Engineering Science*, 2015, vol. 138, pp. 531–543.
5. Lu G., Zhou Y., Lu C., Li X. *Mechanical Systems and Signal Processing*, 2017, vol. 83, pp. 533–548.
6. Budko P.A., Vinogradenko A.M., Litvinov A.I. *Mechatronics, automation, control*, 2014, no. 9, pp. 53–58. (in Russ.)
7. Liu W.Y., Gao Q.W., Ye G. et al. *Measurement*, 2015, vol. 74, pp. 70–77.
8. Skliros C., Esperon M.M., Fakhre A., Jennions I.K. *Diagnostyka*, 2019, vol. 20(1), pp. 3–21.
9. Shi P., Liang K., Han D., Zhang Yi. *Journal of Vibroengineering*, 2017, vol. 19(8), pp. 5932–5946.
10. Senchenkov V.I., Matyunin A.S. *Pribory i sistemy. Upravleniye, kontrol', diagnostika*, 2020, no. 8, pp. 18–26. (in Russ.)

DATA ON AUTHORS

- Yuri E. Tupitsin** — PhD, Associate Professor; A. F. Mozhaisky Military Space Academy, Department of Life Support Systems for Ground-Based Space Infrastructure Facilities; E-mail: vka@mil.ru
- Alexander S. Matyunin** — PhD; A. F. Mozhaisky Military Space Academy, Department of Life Support Systems for Ground-Based Space Infrastructure Facilities; Lecturer; E-mail: vka@mil.ru
- Maxim V. Egorichev** — Adjunct; A. F. Mozhaisky Military Space Academy, Department of Life Support Systems for Ground-Based Space Infrastructure Facilities; Lecturer; E-mail: vka@mil.ru
- Andrey A. Golub** — Cadet; A. F. Mozhaisky Military Space Academy, Department of Life Support Systems for Ground-Based Space Infrastructure Facilities; Lecturer; E-mail: vka@mil.ru

Received 02.05.24; approved after reviewing 16.09.24; accepted for publication 25.12.24.