

## Интеллектуальная система поддержки функциональных характеристик РЛК мониторинга на основе прогнозирования отказов

А. В. Осипов<sup>1,2</sup>, А. В. Тимошенко<sup>3</sup>, А. Ю. Перлов<sup>2,\*</sup>, К. В. Львов<sup>4</sup>

<sup>1</sup>АО «Национальный экологический оператор», 125047, Москва, Россия

<sup>2</sup>Радиотехнический институт им. акад. А. Л. Минца, 127083, Москва, Россия

<sup>3</sup>Национальный исследовательский университет «Московский институт электронной техники», 124498, Москва, Россия

<sup>4</sup>Московский государственный университет им. М. В. Ломоносова, 119991, Москва, Россия

\*Контактный автор: Перлов Анатолий Юрьевич, e-mail: laperlov@yandex.ru

Поступила 17 сентября 2020 г., доработана 14 декабря 2020 г., принята в печать 18 декабря 2020 г.

Показаны особенности применения методов искусственного интеллекта в современных радиолокационных комплексах (РЛК) мониторинга для организации превентивного технического обслуживания. Приведена структурно-функциональная схема интеллектуальной системы поддержки функциональных характеристик РЛК. Представлены экспериментальные оценки точности прогнозирования излучаемой мощности РЛК по данным диагностического контроля.

*Ключевые слова:* РЛК, искусственный интеллект, прогнозирование, энергетический потенциал, излучаемая мощность, машинное обучение.

*Цитирование:* Осипов А.В., Тимошенко А.В., Перлов А.Ю., Львов К.В. Интеллектуальная система поддержки функциональных характеристик РЛК мониторинга на основе прогнозирования отказов. Вычислительные технологии. 2020; 25(6):95–103. DOI:10.25743/ICT.2020.25.6.006.

### Введение

Современные радиолокационные комплексы (РЛК), решающие задачи непрерывного мониторинга воздушного пространства, представляют собой высокоинтегральные цифровые системы, построенные на базе активной фазированной антенной решетки (АФАР). Они оснащены значительным количеством элементов контроля, которые, в свою очередь, могут обладать взаимным влиянием друг на друга [1].

Ключевые особенности современных цифровых РЛК мониторинга:

- переход от схемы деления к функционально-блочной структуре РЛК;
- значительное количество компонентов РЛК, которые являются элементами контроля (число может достигать нескольких тысяч);
- использование цифровых датчиков (с вещественным и бинарным типом данных) в каждом элементе контроля;
- наличие реконфигурируемой контрольно-диагностической системы, осуществляющей сбор данных о техническом состоянии всех элементов несколько раз в минуту.

Таким образом, достигнутый в современных РЛК уровень цифровизации создает основу для применения методов искусственного интеллекта в интересах решения задачи прогнозирования функциональных характеристик радиолокационных систем (РЛС) [2, 3]. Под функциональными характеристиками понимается энергетический потенциал РЛС, к ним также относятся характеристики функциональных систем РЛС: излучаемая мощность, коэффициент усиления АФАР на прием и передачу. Энергетический потенциал — это комплексная характеристика, которая обеспечивает достижение основных тактико-технических характеристик РЛС, определяющих ее функциональное назначение [4]: вероятность обнаружения цели, точность измерения параметров движения цели, пропускную способность многоканальной РЛС при работе по множеству целей. Под энергетическим потенциалом РЛС понимается отношение сигнал/шум, выраженное в децибелах, получаемое в результате приема и цифровой обработки принятого сигнала для объекта, имеющего эффективную площадь рассеяния  $1 \text{ м}^2$  и находящегося на дальности 1000 км по нормали к АФАР. Энергетический потенциал пропорционален излучающей мощности РЛК, поэтому данную величину можно выбрать в качестве оценки энергетического потенциала.

Принципиальная возможность применения классических статистических методов, а также методов машинного обучения в целях превентивного технического обслуживания различных электронных систем продемонстрирована в работах [5, 6]. Так, в [6] представлен широкий обзор различных методов прогнозирования отказов электронных компонентов, а также показано, что для каждой электронной системы требуется уникальный подход.

## 1. Схема интеллектуальной системы поддержки

Необходимость прогнозирования функциональных характеристик РЛК с заданными горизонтом и точностью обуславливает актуальность создания интеллектуальной системы поддержки принятия решений (ИСП) для автоматизированного управления РЛК по данным прогноза. ИСП предназначена для поддержания функциональных характеристик РЛК и формирования рекомендаций по проведению необходимых работ по превентивному техническому обслуживанию на основе прогнозных оценок энергетического потенциала.

Основными задачами интеллектуальной системы поддержки принятия решений являются:

- адаптивное к заданному горизонту прогноза формирование данных о техническом состоянии функциональных систем РЛК с помощью контрольно-диагностической системы;
- формирование структурной схемы надежности РЛК по результатам анализа вклада отказа компонента РЛК в снижение его функциональной характеристики;
- оценка и прогнозирование энергетического потенциала РЛК как основной функциональной характеристики по данным диагностического контроля в реальном масштабе времени;
- вычисление интервала и длительности технического обслуживания (ТО) на основе прогнозирования функциональных характеристик РЛК.

На рис. 1 показан вариант структурно-функциональной схемы ИСП, обеспечивающей прогнозирование функциональных характеристик РЛК с заданными горизонтом и точностью в режиме реального времени.

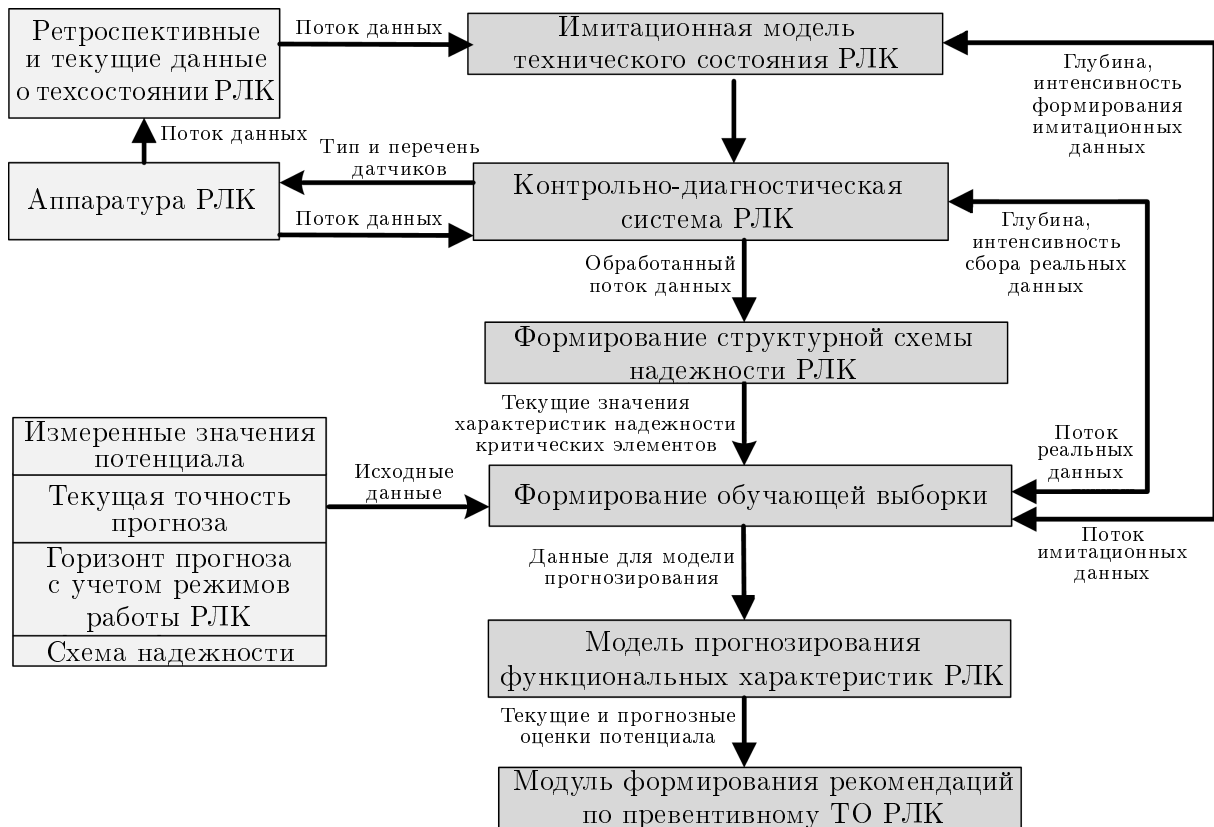


Рис. 1. Структурно-функциональная схема ИСП

Fig. 1. Function structure diagram of ISS

Управление параметрами (тип и перечень датчиков, интенсивность) сбора данных о техническом состоянии элементов РЛК осуществляется с помощью контрольно-диагностической системы (КДС). Контрольно-диагностическая система является по своей сути гетерархической сетевой моделью, отражающей функционально-параметрические зависимости характеристик элементов контроля на всех уровнях функциональной иерархии РЛК. Такое представление КДС позволяет повысить достоверность и полноту данных о техническом состоянии РЛК.

В случае малой выборки данных об отказах РЛК в качестве инструмента формирования данных технического состояния используется имитационная модель РЛК. Имитационная модель основана на ретроспективных данных о техническом состоянии РЛК предыдущего поколения и постоянно уточняется по реальным данным в процессе функционирования изделия:

$$\begin{cases} \mathbf{X}_n^{(0)}(t_i) = g_n(a_{retro}, t_i), \\ \dots \\ \mathbf{X}_n^{(k)}(t_i) = g_n(a_{retro}^{(k)}, t_i), \end{cases} \quad n = \overline{1, N}, \quad i = \overline{1, I}.$$

Здесь  $\mathbf{X}_n^{(k)}$  — вектор значений определенных КДС величин, формируемых имитатором для  $n$ -го блока и момента времени  $t_i$ , верхний индекс указывает на “версию” имитатора (ноль означает имитатор, обученный только на ретроспективных данных  $a_{retro}$ );  $N$  — число анализируемых блоков, задаваемое КДС;  $I$  — размер “временного окна”.

Для выявления критических элементов в состав ИСП входит модуль формирования структурной схемы надежности. Под структурной схемой надежности понимают логи-

ческое описание схемы РЛК, отображающее, каким образом безотказность его блоков и их сочетаний влияет на безотказность объекта. Таким образом, при управлении КДС модуль формирования структурной схемы надежности РЛК служит для формирования потока данных о наиболее информативных элементах (критических элементах) с точки зрения влияния на отказ РЛК, что обеспечивает возможность исключения отрицательного влияния излишней информации на точность и горизонт прогноза.

Для обеспечения прогнозирования энергетического потенциала с требуемыми точностью и интервалом прогноза в состав ИСП включен модуль прогнозирования функциональных характеристик РЛК. Его основной задачей является формирование в реальном масштабе времени работы РЛК текущих  $\tilde{y}_m(t_j)$  и прогнозных  $y_m(t_j)$  оценок энергетического потенциала:

$$\begin{aligned} \tilde{y}_m(t_j) &= h_m(X(t_j)), \\ y_m(t_j) &= f_m(X(t_{-I}), X(t_{-I+1}), \dots, X(t_{-1}), X(t_0)), \quad m = \overline{1, M}, \quad j = \overline{1, L}. \end{aligned}$$

Здесь индекс  $m$  означает номер функциональной характеристики;  $M$  — количество прогнозируемых функциональных характеристик;  $h_m$  — известная функция расчета  $m$ -й функциональной характеристики в произвольный момент времени  $t_j$ ;  $L$  — горизонт прогноза;  $f_m$  — функция расчета  $m$ -й функциональной характеристики, получаемая с помощью методов искусственного интеллекта. Значение  $y_m(t_j)$  в произвольный момент времени  $t_j$  определяется состоянием блоков в предыдущие моменты времени.

Модуль прогнозирования работает в режиме поступления данных от КДС в реальном времени с использованием технологии скользящего окна, которая заключается в наблюдении за последними поступившими измерениями (записями) и перемещении вдоль оси времени по мере поступления новых записей.

Выявленные с помощью модуля прогнозирования критические элементы должны отображаться на одном экране с текущей и прогнозной оценками потенциала с помощью модуля формирования рекомендаций по превентивному техническому обслуживанию РЛК. Этот модуль отображает критические элементы РЛК, а также прогнозные причины снижения функциональных характеристик и меры по их заблаговременному упреждению путем замены критических элементов, находящихся в предотказном сос-




Рис. 2. Пример мнемосхемы критических элементов

Fig. 2. Example of mnemonic diagram for critical elements

тоянии. Пример мнемосхемы критических элементов показан на рис. 2. Цветом изображено состояние элементов (блоков усиления мощности) по температуре.

Ключевым элементом ИСП является модель прогнозирования функциональных характеристик РЛК. Основные источники данных модели прогнозирования — контрольно-диагностическая система и имитационная модель технического состояния РЛК [7]. Прогноз значений функциональных характеристик, в том числе и энергетического потенциала, основан на оценке частоты отказов критических элементов РЛК по наиболее информативным признакам технического состояния. Для обеспечения требуемой точности прогноза в процессе функционирования РЛК итеративно уточняются параметры модели прогноза, а именно максимально возможный период прогнозирования, а также минимально необходимый объем обучающей выборки. На основе прогнозных оценок потенциала формируются рекомендации о замене критических элементов с точки зрения их вклада в снижение энергетического потенциала.

## 2. Экспериментальная часть

Оценка эффективности методов искусственного интеллекта для прогнозирования функциональных характеристик проводилась на примере передающей системы РЛК — одной из наиболее важных с точки зрения влияния отказов на энергетический потенциал изделия. Характерной особенностью передающей системы является большое число блоков усиления мощности, работающих в теплонапряженных режимах, что обуславливает возможность их перегрева и выхода из строя на время охлаждения до заданной температуры. В качестве наиболее информативного признака для прогноза состояния системы выбрана температура блоков усиления мощности, а в качестве функциональной характеристики (максимально влияющей на потенциал) — излучаемая мощность РЛК.

На первом этапе экспериментальной работы прогнозировалось значение температуры каждого из блоков усиления мощности и определялось его состояние (работоспособен или нет):

$$\mathbf{X}_n(t_j) = \begin{cases} 1, & (y_n(t_j) < T_{th}) \text{ and } (mode_n(t_j) = 1), \\ 0, & (y_n(t_j) > T_{th}) \text{ or } (mode_n(t_j) = 0), \end{cases} \quad n = \overline{1, N}, \quad j = \overline{1, L}.$$

Здесь  $y_n$  — прогнозная температура  $n$ -го блока;  $T_{th}$  — температурный порог;  $mode_n$  — режим работы (1 — работает, 0 — охлаждается).

Для решения этой задачи были опробованы различные методы машинного обучения [8]. Оценка точности прогноза температуры проводилась с помощью метрики MAPE (средняя абсолютная процентная ошибка):

$$MAPE = \frac{1}{N} \sum_{n=1}^N \left| \frac{y_n - T_n}{T_n} \right|,$$

где  $N$  — горизонт прогноза (под одним отсчетом понимается время 20 с, равное интервалу записи технического состояния контрольно-диагностической системой);  $y_n$  — прогнозное значение температуры блока усиления мощности;  $T_n$  — его действительная температура,  $n = \overline{1, N}$ .

Как показали компьютерные эксперименты, лучшую точность прогноза показал алгоритм градиентного бустинга на решающих деревьях, который позволяет проводить

непрерывное дообучение модели путем итеративной минимизации ошибки прогноза (рис. 3). На втором этапе по результатам прогнозирования состояния каждого блока решается задача определения вероятности отказа системы. Под отказом передающей системы понимается критическое снижение излучаемой мощности РЛК, т. е. уменьшение числа работоспособных блоков усиления мощности ниже заданного критического значения  $N_{cr}$ :

$$P(t_j) = P\left(\sum_{n=1}^N X_n(t_j) < N_{cr}\right).$$

На рис. 4 показана рассчитанная вероятность отказа передающей системы РЛК в сравнении с реальным состоянием изделия при горизонте прогноза в 60 отсчетов, что составляет 20 мин.

В результате качественного сравнения прогнозной кривой с реальной кривой отказа системы сделан вывод, что построенные модели позволяют верно прогнозировать наступление отказов передающей системы, т. е. снижение ее мощности ниже критического значения, а значит, и уменьшение энергетического потенциала РЛК ниже критического значения. Для количественной оценки точности прогноза было рассчитано среднее отклонение от реальной кривой, которое составило 20 %.

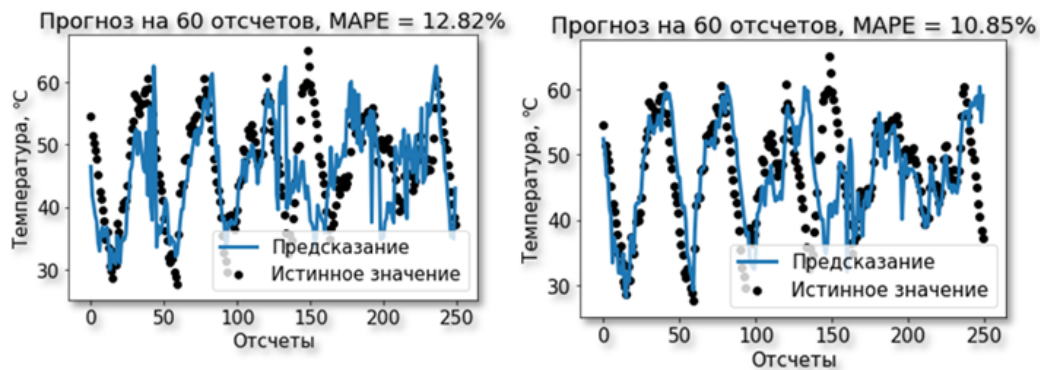


Рис. 3. Прогноз температуры блока усиления мощности методом линейной регрессии (слева) и методом градиентного бустинга на решающих деревьях (справа)

Fig. 3. Temperature prediction for the power amplifier block using the linear regression method (left) and the gradient boosting method on the decision trees (right)




Рис. 4. Прогноз вероятности отказа системы (оранжевый цвет) в сравнении с реальным наличием отказа (синий цвет)

Fig. 4. Prediction of system failure probability (orange colour) in comparison with the real presence of failure (blue colour)

## Заключение

Существующие цифровые решения в РЛК в совокупности с методами искусственного интеллекта создают основы для перехода к превентивному техническому обслуживанию на основе прогнозных оценок функциональных характеристик.

Полученные в ходе экспериментов ошибка (20 %) и горизонт (20 мин) прогноза достаточны, чтобы обслуживающий РЛК персонал смог предпринять необходимые меры и предотвратить критическое снижение функциональных характеристик изделия.

Внедрение ИСП позволит:

- обеспечить поддержание назначенных показателей надежности на заданном интервале времени;
- реализовать максимальные функциональные возможности РЛК с учетом прогноза их изменения;
- оперативно оценивать, а также прогнозировать функциональную готовность РЛК с требуемой точностью;
- осуществлять оперативный доклад на командный пункт РЛК о причинах снижения функциональной готовности по данным всплывающих подсказок о неисправном элементе и степени его влияния на функциональные характеристики.

## Список литературы

- [1] **Боев С.Ф.** Управление рисками проектирования и создания радиолокационных станций дальнего обнаружения. М.: Изд-во Моск. гос. техн. ун-та им. Н.Э. Баумана; 2017: 430.
  - [2] **Логовский А.С., Мальцев Г.Н., Рахманов А.А., Тимошенко А.В.** Техничко-экономический показатель эффективности создания радиолокационных систем дальнего обнаружения. Вооружение и экономика. 2020; 2(52):9–23.
  - [3] **Сколник М.И.** Справочник по радиолокации: Пер. с англ. под общей ред. В.С. Вербы. В 2 кн. Кн. 2. М.: Техносфера; 2014: 680.
  - [4] **Белоцерковский Г.Б.** Основы радиолокации и радиолокационные устройства. М.: Сов. радио; 1975: 336.
  - [5] **Baptista M., Sankararaman S., de Medeiros I.P., Nascimento C., Prendinger H., Henriques E.M.** Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. Computers & Industrial Engineering. 2018; (115):41–53.
  - [6] **Carvalho T.P., Soares F.A.A.M.N., Vita R., da Francisco P.R., Basto J.P., Alcalá S.G.S.** A systematic literature review of machine learning methods applied to predictive maintenance. Computers & Industrial Engineering. 2019; (1):1–12.
  - [7] **Антошина В.М., Загер И.Б., Логовский А.С., Львов К.В., Перлов А.Ю.** Имитационная модель данных о техническом состоянии функциональных систем РЛК при решении задачи прогнозирования отказов. Электромагнитные волны и электронные системы. 2019; 24(5):11–16.
  - [8] **Калинов И.А., Кочкаров А.А., Матвеева С.С.** Основные принципы применения методов машинного обучения для оценки функционирования радиолокационных станций. Радиотехника. 2018; 10:18–23. DOI:10.18127/j00338486-201810-02.
-

**Intelligent system for supporting functional characteristics of radar monitoring based on failure prediction**

OSIPOV ALEXANDR V.<sup>1,2</sup>, TIMOSHENKO ALEXANDER V.<sup>3</sup>, PERLOV ANATOLY YU.<sup>2,\*</sup>,  
LVOV KIRILL V.<sup>4</sup>

<sup>1</sup>Joint-stock company “Natsional’nyy Ekologicheskiiy Operator”, 125047, Moscow, Russia

<sup>2</sup>Academician A. L. Mintz Radiotechnical Institute, 127083, Moscow, Russia

<sup>3</sup>National Research University of Electronic Technology, 124498, Moscow, Russia

<sup>4</sup>M. V. Lomonosov Moscow State University, 119991, Moscow, Russia

\*Corresponding author: Perlov Anatoly Yu., e-mail: [laperlov@yandex.ru](mailto:laperlov@yandex.ru)

Received September 17, 2020, revised December 14, 2020, accepted December 18, 2020

**Abstract**

*Purpose.* This work is devoted to a description of an intelligent support system (ICP) of the functional characteristics of radar systems operating in heat-stressed modes. The purpose of the work is to simulate the operation of the failure prediction module based on the data on the operation of the critical components of the radar.

*Methodology.* Failure prediction based on block temperature data was performed using supervised machine learning methods, including regression methods. The highest quality parameters of the forecasting model (horizon — accuracy) were achieved when training the model using the gradient boosting method, which allows organizing continuous additional training of the forecasting model during the operation of the radar by forming a training sample consisting of a data flow about the technical state.

*Findings.* A structural and functional diagram of the ICP has been developed and a description of the operation of its components is given. The error (20 %) and the horizon (20 min.) of the prediction of failures obtained during the experiments are sufficient for the staff serving the radar to take the necessary measures and prevent a critical decrease in the functional characteristics of the product.

*Originality/value.* The introduction of ISP will allow realizing the maximum functional capabilities of the radar, taking into account the forecast of their change, as well as making an operational report to the command post of the radar on the reasons for the decrease in functional readiness according to the pop-up tips about the faulty element and the degree of its influence on the functional characteristics.

*Keywords:* RLC, artificial intelligence, forecasting, energy potential, radiated power, machine learning.

*Citation:* Osipov A.V., Timoshenko A.V., Perlov A.Yu., Lvov K.V. Intelligent system for supporting functional characteristics of radar monitoring based on failure prediction. Computational Technologies. 2020; 25(6):95–103. DOI:10.25743/ICT.2020.25.6.006. (In Russ.)

**References**

1. **Boev S.F.** Upravlenie riskami proektirovaniya i sozdaniya radiolokatsionnykh stantsiy dal’nego obnaruzheniya [Risk management in design and construction of early warning radars]. Moscow: Izdatel’stvo Moskovskogo gosudarstvennogo tekhnicheskogo universiteta im. N. E. Baumana; 2017: 430. (In Russ.)



2. **Logovsky A.S., Maltzev G.N., Rakhmanov A.A., Timoshenko A.V.** Technical and economic indicator of the early warning radar creation effectiveness. *Armament and Economics*. 2020; 2(52):9–23.
3. **Skolnik M.I.** Radar handbook. N.Y.: McGraw-Hill; 2008: 680.
4. **Belotzerkovskiy G.B.** Osnovy radiolokatsii i radiolokatsionnye ustroystva [Fundamentals of radiolocation and radars]. Moscow: Sovetskoe radio; 1975: 336. (In Russ.)
5. **Baptista M., Sankararaman S., de Medeiros I.P., Nascimento C., Prendinger H., Henriques E.M.** Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modelling. *Computers & Industrial Engineering*. 2018; (115):41–53.
6. **Carvalho T.P., Soares F.A.A.M.N., Vita R., da Francisco P.R., Basto J.P., Alcala S.G.S.** A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*. 2019; (1):1–12.
7. **Antoshina B.M., Zager I.B., Logovsky A.S., Lvov K.V., Perlov A.Yu.** A simulation model of data on the technical condition of the functional systems of the radar when solving the problem of forecasting failures. *Elektromagnitnye Volny i Elektronnyye Sistemy*. 2019; 24(5):11–16. (In Russ.)
8. **Kalinov I.A., Kochkarov A.A., Matveeva S.S.** Basic principles of machine learning methods application for the evaluation of the functioning of radar stations. *Radiotekhnika*. 2018; 10:18–23. DOI:10.18127/j00338486-201810-02. (In Russ.)