

УДК 004.896

DOI: 10.52531/1682-1696-2025-25-3-121-127

Научная статья

EDN: TXIRFO

РАСПОЗНАВАНИЕ РАДИОЛОКАЦИОННЫХ СТАНЦИЙ ПО РАДИОТЕХНИЧЕСКИМ ПАРАМЕТРАМ СИГНАЛОВ С ПОМОЩЬЮ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

Е.В. Вагапов,
А.Н. Никулина, Е.В. Рябикина
АО «ЦНИРТИ им. академика
А.И. Берга», Москва, Российская Федерация

Original article

RECOGNITION OF RADAR STATIONS BY RADIO TECHNICAL SIGNAL PARAMETERS USING MACHINE-LEARNING METHODS

E.V. VAGAPOV,
A.N. NIKULINA, E.V. RYABIKINA
JSC «CENTRAL RADIO-RESEARCH INSTITUTE
NAMED AFTER ACADEMICIAN A.I. BERG»,
MOSCOW, RUSSIAN FEDERATION

В ходе решения задачи радиоэлектронного наблюдения остро встает вопрос классификации обнаруженных радиосигналов. Классические методы классификации, основанные на сравнении полученных данных об обнаруженных станциях с эталонными априорно-известными параметрами станций, не позволяют получить результат с высокой степенью достоверности, поэтому для решения данного вопроса мы обратились к технологиям машинного обучения.

КЛЮЧЕВЫЕ СЛОВА: машинное обучение, распознавание радиолокационных станций, классификация сигналов по радиотехническим параметрам, поиск выбросов

ВВЕДЕНИЕ

В ходе решения задачи радиоэлектронного наблюдения встает вопрос классификации обнаруженных радиосигналов. Классические методы классификации, основанные на сравнении полученных данных об обнаруженных станциях с эталонными априорно-известными параметрами станций, не позволяют получить результат с высокой степенью достоверности, поэтому для решения данного вопроса мы обратились к методам машинного обучения, которые на сегодняшний день используются повсеместно.

Данные методы имеют серьезное практическое преимущество в сравнении с классическими методами классификации сигналов. На выполнение данной задачи ручным способом без автоматизации с участием нескольких операторов может потребоваться много времени и ресурсов. В то же время рассмотренным методом машинного обучения может понадобиться чуть больше десяти минут, чтобы классифицировать свыше миллиона сигналов. Это делает методы машинного обучения мощным инструментом в руках оператора.

In the course of solving the problem of electronic surveillance, the issue of classification of detected radio signals arises. Classical classification methods based on comparison of the obtained data on detected stations with reference a priori known parameters of stations do not allow obtaining a result with a high degree of reliability, therefore, to solve this issue, we turned to machine learning methods, which are currently used everywhere. In this paper, such machine learning methods as random forest, multilayer perceptron, gradient boosting, convolutional NN, local emission level method were considered. In addition, sequential binary classification method for determining emissions was developed in the test sample.

KEY WORDS: machine learning, recognition of radar stations, classification of signals by radio parameters, search for outliers

Нами были рассмотрены различные методы машинного обучения и модели нейронных сетей (НС), применяемые в задачах многомерной классификации.

В ходе решения задачи распознавания типа и назначения радиолокационных станций (РЛС) по радиотехническим параметрам сигналов (РТПС) были выполнены следующие этапы:

- 1) подготовка исходных данных (создание математической модели генерации исходных данных с добавлением шума);
- 2) выбор метода стандартизации исходных данных;
- 3) выбор метода классификации, позволяющий определить тип РЛС;
- 4) разработка метода, позволяющего определить выбросы (сигналы от тех типов РЛС, которых не было в обучающей выборке);

5) разработка метода, позволяющего определить значение РАС у сигналов, отмеченных как выбросы.

В данной работе были рассмотрены такие методы машинного обучения, как: случайный лес, многослойный перцептрон, градиентный бустинг, сверточная НС, метод локального уровня выбросов. Кроме того, нами был разработан метод последовательной бинарной классификации для определения выбросов в тестовой выборке.

КЛАССИФИКАЦИЯ СИГНАЛОВ

На основе методов машинного обучения и моделей НС, применяемых в задачах многомерной классификации, был создан классификатор, позволяющий определить принадлежность сигнала к типу РАС с определенной вероятностью. Для его обучения использовался специальный набор размеченных данных – обучающая выборка. Обучающая выборка – совокупность пар «объект классификации, метка класса», где между объектом классификации и меткой класса есть зависимость, которая может быть выявлена в ходе обучения НС.

Чтобы сформировать обучающую выборку, необходимо провести отбор признаков, которые будут в полной мере характеризовать каждый объект в выборке. Также признаки должны быть информативными. Избыточное количество признаков может помешать переобучению, что в свою очередь приведет к менее эффективной работе классификатора. Переобучение – это явление, при котором обучаемая модель хорошо распознает примеры из обучающей выборки, но не распознает или плохо распознает любые другие примеры, которых не было в обучающей выборке. Это происходит из-за того, что параметры модели чрезмерно подгоняются к зависимостям обучающей выборки. Плохо сформированная обучающая выборка может привести к нечеткому разделению классов, из-за чего эффективность классификатора также уменьшится.

Для того, чтобы разработать алгоритм классификации сигналов, необходимо определить, по каким параметрам будет происходить классификация и формат входных данных. Определим, что каждому типу РАС соответствует отдельный класс и диапазоны значений по трем признакам: частоте, периоду и длительности импульса сигнала. Тогда входными данными будет являться массив векторов, содержащих 3 значения по каждой характеристике сигнала (частота, период, длительность импульса сигнала).

Некоторые методы машинного обучения чувствительны к нормализации данных. Она позволяет масштабировать данные и приводить признаки к единому виду, чтобы обучение было более эффективным. Были рассмотрены следующие виды нормализации данных:

1) стандартная нормализация

Для каждого признака x (предполагается, что x

Е.В. ВАГАПОВ,
А.Н. НИКУЛИНА, Е.В. РЯБИКИНА
РАСПОЗНАВАНИЕ РАДИОЛОКАЦИОННЫХ СТАНЦИЙ
ПО РАДИОТЕХНИЧЕСКИМ ПАРАМЕТРАМ СИГНАЛОВ
С ПОМОЩЬЮ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ

имеет нормальное распределение) каждое его значение на i -ом объекте преобразуется по формуле:

$$x_i^{new} = \frac{x_i - \mu}{\sigma} \quad (1)$$

где $\mu = \frac{1}{N} \sum_{i=1}^N x_i$ – среднее значение признака x ;

$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2}$ – стандартное отклонение признака x ;

N – длина выборки.

После такого преобразования каждый признак имеет среднее значение равное нулю и дисперсию равную единице, то есть осуществляется переход от нормально распределенной величины к величине со стандартным нормальным распределением;

2) линейная нормализация

$$x_i^{new} = \frac{x_i - x_{min}}{x_{max} - x_{min}}, \quad (2)$$

где x_{min} , x_{max} – минимальное и максимальное значение признака x соответственно.

После такого преобразования минимальное значение каждого признака будет отображено в ноль, а максимальное в единицу;

3) робастная нормализация

Для нормализации значения каждого признака используется межквартильный диапазон

$$x_i^{new} = \frac{x_i - Q_1(x)}{Q_3(x) - Q_1(x)}, \quad (3)$$

где $Q_1(x)$ и $Q_3(x)$ – первая и третья квартили признака x соответственно.

Перед созданием классификатора используется математическая модель для генерации исходных данных, на основе которых были созданы обучающая и тестовая выборки.

К значениям параметров сигналов в исходных данных добавлены случайные нормально распределенные ошибки, с нулевым математическим ожиданием и среднеквадратическим отклонением, равным единичному значению ошибки по параметру, умноженному на коэффициент шума (КШ).

Для оценки результатов применения различных методов нормализаций к исходным данным при классификации сигналов воспользуемся метрикой F_1 -мерой, где базовым классификатором является многослойный перцептрон. Метрика рассчитывается следующей формулой:

$$F_1 = \frac{2}{\sum_{i=1}^k w_i} \times \frac{\sum_{i=1}^k (\text{precision}_i \times w_i) \times \sum_{i=1}^k (\text{recall}_i \times w_i)}{\sum_{i=1}^k (\text{precision}_i \times w_i) \times \sum_{i=1}^k (\text{recall}_i \times w_i)} \quad (4)$$

где k – количество классов; i – номер класса; precision – точность; recall – полнота; w_i – весовой ко-

эффект i -го класса, рассчитывается как доля объектов i -го класса в обучающей выборке.

Точность (precision) – это доля данных, действительно принадлежащих классу, относительно всех данных, которые метод отнес к этому классу. Полнота (recall) – это доля найденных классификатором данных, принадлежащих классу, относительно всех данных этого класса в тестовой выборке. Точность и полнота определяются следующим образом:

$$\text{precision} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (6)$$

где TP – истинно-положительное решение; FP – ложно-положительное решение; FN – ложно-отрицательное решение.

В таблице 1 представлены результаты применения различных методов нормализаций к исходным данным при классификации сигналов посредством метода многослойного персептрона.

По результатам исследования для нормализации данных лучше всего подходит робастная нормализация.

Для классификации сигналов по типам РЛС были рассмотрены следующие методы машинного обучения:

- случайный лес [5];
- многослойный персептрон [3];
- градиентный бустинг [7].

Стоит отметить, что в отличие от многослойного персептрона, случайный лес и градиентный бустинг не чувствительны к нормализации.

Для оценки работы методов воспользуемся метрикой F_1 -мерой, так как она в полной мере представляет собой совместную оценку точности и полноты.

Для проверки качества работы классификатора создается тестовая выборка, которая состоит из объектов классификации и не используется непосредственно в процессе обучения классификатора.

ТАБЛИЦА 1.

Значение F_1 -меры при классификации сигналов РЛС с помощью многослойного персептрона для разных видов нормализации данных с различным уровнем КШ

КШ	Значение F_1 -меры для разных видов нормализации данных		
	линейная	стандартная	робастная
0	0,72	0,75	0,87
1	0,69	0,77	0,83
2	0,7	0,78	0,83
5	0,7	0,77	0,81
10	0,69	0,76	0,77

Подготовив обучающую и тестовую выборки с n -ым количеством наборов формуляров сигналов (ФС) с тремя признаками (частота, период, длительность импульса сигнала), проведем тестирование методов классификации.

На рисунке 1 представлена оценка результатов тестирования методов классификаций на обучающей выборке.

Можно сделать вывод, что классификатор на основе многослойного персептрона недообучен при объеме обучающей выборки $n=100$ и требует большего объема исходных данных для обучения по сравнению с методами случайного леса и бустинга.

На рисунке 2 представлена оценка результатов тестирования методов классификаций на тестовой выборке.

По результатам, приведенным на рисунке 2, видно, что у всех методов машинного обучения при $n>500$ вероятность верного определения типа РЛС больше 95%. При этом лучше всего работают методы случайного леса и бустинга, вне зависимости от объема обучающей выборки.




Рис. 1.

Оценка результатов тестирования методов классификаций на обучающей выборке




Рис. 2.

Оценка результатов тестирования методов классификаций на тестовой выборке

Проведем эксперимент, где объем обучающей выборки равен $n=500$, и добавим шум к исходным данным. Сначала проведем эксперимент с малым количеством шума, затем с большим.

На рисунке 3 представлены оценки результатов тестирования методов классификаций на тестовой выборке с малыми шумами.

На рисунке 4 представлены оценки результатов тестирования методов классификаций на тестовой выборке с большими шумами.

Согласно представленным оценкам, наилучшие результаты классификации при малых шумах достигаются с помощью случайного леса и многослойного персептрона.

Несмотря на то, что многослойный персептрон превосходит метод случайного леса при $KШ > 0,05$, он имеет серьезные недостатки. Многослойный персептрон может легко переобучиться, качество обучения зависит от объема обучающей выборки (рис. 2), чувствителен к масштабированию и аномалиям исходных данных. Случайный лес, наоборот, имеет устойчивость к переобучению, высокую точность, не чувствителен к аномалиям исходных данных и масштабированию исходных данных, имеет высокую скорость обучения в сравнении с многослойным персептроном. Поэтому, несмотря на не столь сильное снижение качества определения типа РЛС при повышении шума параметров сигналов, метод случайного леса остается наилучшим методом для решения данной задачи.

ПОИСК ВЫБРОСОВ

В тестовую выборку могут попасть выбросы – сигналы тех типов РЛС, которых не было в обучающей выборке. В таком случае классификатор все равно отнесет ФС к тому или иному типу РЛС из обучающей выборки с определенной вероятностью. Для таких ситуаций необходимо разработать метод, который позволит определять выбросы.

Для поиска выбросов был разработан метод последовательной бинарной классификации, основанный на принципе «один против всех», и рассмотрен метод




РИС. 3.

Оценка результатов тестирования методов классификаций на тестовой выборке с малыми шумами

локального уровня выбросов [6] с робастной нормализацией.

В методе последовательной бинарной классификации для каждого типа РЛС формируется свой классификатор, который предсказывает, принадлежит ли ФС данному типу или нет. Если классификатор возвращает 1, значит данный ФС принадлежит данному классу и не является выбросом, -1 – не принадлежит данному классу и является выбросом. Получается матрица размерностью (n, m) , где m – количество объектов в одном классе. Если сумма матрицы по некоторому столбцу отличается от значения $-m + 2$, то объект с индексом, равным номеру выбранного столбца, считается выбросом.

Метод локального уровня выбросов относится к методам машинного обучения без учителя. В процессе обучения производится оценка плотности распределения объектов обучающей выборки. На основании полученной в процессе обучения информации делается вывод о том, является ли рассматриваемый объект выбросом.

Для оценки работы методов был рассчитан коэффициент корреляции Мэтьюса (mcc), который определяется следующим образом:

$$mcc = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (7)$$

где TP – истинно-положительное решение; TN – истинно-отрицательное решение; FP – ложноположительное решение; FN – ложноотрицательное решение.

mcc используется как показатель качества бинарной классификации, который изменяется в диапазоне от -1 до 1 . $mcc = 1$ указывает на идеальную классификацию, когда фактический и предсказанный классы полностью совпадают и ложноположительные (FP) и ложноотрицательные (FN) результаты отсутствуют. Значение $mcc = 0$ соответствует случайному предсказанию. $mcc = -1$ указывает на расхождение между фактическим и предсказанным значениями класса (классификатор предсказывает обратное событие),




РИС. 4.

Оценка результатов тестирования методов классификаций на тестовой выборке с большими шумами

истинно положительное (TP) и истинно отрицательное (TN) в этом случае отсутствуют.

Оценить качество его работы можно следующим образом:

- создать обучающую и тестовую выборки таким образом, чтобы в тестовой были типы РЛС, которых нет в обучающей выборке;
- обучить классификатор на основе созданной выборки;
- провести тестирование на основе тестовой выборки;
- рассчитать коэффициент корреляции Мэтьюса.

Чтобы провести тестирование, подготовили тестовую выборку, которая состоит из ФС тех типов РЛС, которые были в обучающей выборке во время обучения, и ФС тех типов РЛС, которых не было в обучающей выборке и являются выбросами. Выборка содержит 80 классов. В данном случае под классом понимается тип РЛС. Будем последовательно убирать по одному классу из обучающей выборки, затем обучать метод, проверять его на тестовой выборке и возвращать убранный класс обратно в обучающую выборку до тех пор, пока не пройдем таким образом все классы.

На рисунке 5 отображены результаты тестирования метода определения выбросов.

По результатам тестирования можно сделать вывод, что метод последовательной бинарной классификации справляется с задачей лучше и определил выбросы в тестовой выборке. Однако при большем количестве классов обучение и хранение множества бинарных классификаторов может потребовать значительных вычислительных ресурсов.

РАСПОЗНАВАНИЕ НЕИЗВЕСТНЫХ РЛС

Для сигналов, отмеченных как выбросы, можно попробовать определить назначение РЛС посредством сравнения общих скрытых черт (паттернов) внутри ФС известных и неизвестных типов РЛС.

Идея метода определения назначения у неизвестных типов РЛС состоит в способности сверточной НС к обобщению и выделению скрытых математических зависимостей между входными и выходными данными, а также в предположении о наличии общих характеристик у различных типов РЛС, принадлежащих одному классу.

Возьмем для сравнения метод случайного леса, так как он устойчив к переобучению и показывает хорошие результаты классификации. Главным недостатком этого метода является то, что при попытке определить класс объекта, которого не было в обучающей выборке, он не учитывает контекст импульса в ФС. Результаты, полученные методом случайного леса, не дадут представление о назначении РЛС, поэтому необходим такой метод, который смог бы находить общие черты (паттерны) в ФС. Для решения данной задачи была рассмотрена сверточная НС.




РИС. 5.

Значение коэффициента корреляции Мэтьюса в зависимости от класса

Сверточная НС – специальная архитектура НС, изначально нацеленная на эффективное распознавание изображений. Такая НС основана на процедуре свертки матриц. Свертка – операция над парой матриц A (размера $n_x \times n_y$) и B (размера $m_x \times m_y$), результатом которой является матрица $C = A \times B$ размера $(n_x - m_x + 1) \times (n_y - m_y + 1)$. Каждый элемент результата вычисляется как скалярное произведение матрицы B и некоторой подматрицы матрицы A такого же размера.

На рисунке 6 показано передвижение матрицы B по матрице A и в каждом положении считается скалярное произведение матрицы B и той части матрицы A , на которую она сейчас наложена, результат записывается в соответствующий элемент результата C .

Логический смысл свертки – чем больше величина элемента свертки, тем больше эта часть матрицы A была похожа на матрицу B (похожа в смысле скалярного произведения). Поэтому матрицу A называют изображением, а матрицу B – фильтром или образцом.

Рассмотрев сверточные НС, можно выделить ее преимущества и недостатки. Сверточная НС обладает возможностью выявить скрытые паттерны между параметрами сигналов внутри одного ФС, но для этого необходимо большое изображение, а малый размер обрабатываемого изображения не позволяет воспользоваться всеми преимуществами этого метода.

Входными данными являются двумерный массив 3×8 , в котором находятся 8 импульсов с 3 параметрами сигналов (частота, период, длительность импульса). Для оптимизации обучающей выборки проведем коррекцию кратных периодов и удаление импульсов с нулевыми периодами (предобработка).

Проведем тестирование, посредством создания тестовой выборки. Для оценки результатов работы будем рассчитывать следующие значения: TP – процент верно определившихся классов у ФС, принадлежащих к неизвестным РЛС, TN – процент верно определившихся классов у ФС известных РЛС. Будут тестироваться одномерные и двумерные сверточные

НС. Также вновь воспользуемся коэффициентом корреляции Мэтьюса.

В таблице 2 представлена итоговая таблица результатов работы алгоритмов определения назначения у РАС с неизвестными типами РАС различными методами с предобработкой и без.

По результатам тестирования видно, что предобработка оказала положительное влияние на работу методов распознавания назначения неизвестных РАС. Метод случайного леса показал самый высокий уровень точности определения класса РАС сигнала, но делает он это без учета контекста сигнала в ФС, в отличие от сверточных НС, которые учитывают контекст входных данных и позволяют находить скрытые математические зависимости. Согласно результатам, отраженным в таблице 2, двумерная сверточная НС показывает лучшие результаты распознавания назначения неизвестных РАС в сравнении с одномерной сверточной НС.

Чтобы проверить работоспособность сверточной НС, необходимо большое количество верно размеченных данных в виде двумерных массивов 3×8 , в которых находятся 8 импульсов с 3 параметрами сигналов (частота, период, длительность импульса). Тем не менее, использование сверточных НС остается перспективной технологией.

ЗАКЛЮЧЕНИЕ

В рамках решения задач классификации сигналов были рассмотрены следующие модели НС и методы машинного обучения:

- случайный лес;
- градиентный бустинг;
- многослойный перцептрон.

Было проведено моделирование обучающей выборки, которая представляет из себя набор сигналов с тремя параметрами (частота, период, длительность импульса сигнала).




РИС. 6.

Работа свертки

ТАБЛИЦА 2.

Результатов работы алгоритмов определения назначения у РЛС с неизвестным типом

Вид предобработки	С предобработкой			Без предобработки		
Метод МО	TP (%)	TN (%)	мсс	TP (%)	TN (%)	мсс
Случайный лес	46,58	98,87	0,3095	44,63	98,51	0,2939
Одномерная сверточная НС	30	88,16	0,0083	33	87,26	0,00542
Двумерная сверточная НС	43,88	94,45	0,2429	43,02	90,68	0,1963

Были исследованы различные виды нормализаций данных:

- стандартная нормализация;
- линейная нормализация;
- робастная нормализация.

Для решения задачи поиска выбросов были рассмотрены следующие методы машинного обучения:

- последовательная бинарная классификация;
- метод локального уровня выбросов.

Для решения задачи распознавания неизвестных РЛС была рассмотрена сверточная НС.

Также для повышения эффективности обучения и работы НС была применена предобработка коррекции кратных периодов и удаления импульсов с нулевым периодом (предобработка 1).

Проведено тестирование моделей НС и методов машинного обучения с использованием робастной нормализации и предобработок для достижения наилучших результатов классификации. После тестирования методов была проведена оценка работы каждого из методов машинного обучения. Для оценки была рассмотрена средневзвешенная метрика F1-мера, коэффициент корреляции Мэтьюса.

По результатам оценки можно сделать следующие выводы. Для классификации сигналов по параметрам радиотехнических сигналов (частота, период, длительность импульса) лучше всего подходит метод случайного леса.

При решении задачи поиска выбросов лучшие результаты достигаются с помощью метода последовательной бинарной классификации. Использование этого метода позволяет эффективно выделять объекты, принадлежащие к типам РЛС, которые отсутствовали в обучающей выборке.

Для распознавания неизвестных РЛС была применена двумерная сверточная НС с предварительной предобработкой данных. Это дало возможность определить назначение РЛС, ФС которых были отмечены как выбросы, с помощью выявления общих скрытых черт (паттернов). Сверточная НС позволяет находить паттерны внутри ФС неизвестных типов РЛС и определять их назначение, поэтому она остается перспективным методом анализа радиотехнических сигналов.

ЛИТЕРАТУРА

1. Айвазян С.А., Мхитарян В.С. Прикладная статистика и основы эконометрики, М.: Юнити, 1998. 1022 с.
2. Воронцов В. Математические методы обучения по прецедентам (теория обучения машин). М., 2011.
3. Головкин В.А. Нейронные сети: обучение, организация и применение: учеб. пособие. Под общ. ред. А.И. Галушкина. М., 2001. 256 с.
4. Николенко Б.Б., Кузнецов Д.И., Подковкин В.А., Попов П.Б., Никулина А.Н. Использование методов искусственного интеллекта

для распознавания радиолокационных станций по радиотехническим параметрам сигналов с фильтрацией сигналов неучтенных в обучающей выборке радиолокационных станций // Радиотехника. 2024. № 5. 15–27 с.

5. BREIMAN L. Random forests. Machine learning, 2001. V. 45. №. 1. P. 5–32.
6. BREUNIG M.M., KRIEGLER H.-P., NG R. T., SANDER J.R. LOF: Identifying Density-based Local Outliers. Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data, 2000. 12 с.
7. CHEN T., GUESTRIN C. XGBoost: A Scalable Tree Boosting System. <https://arxiv.org/abs/1603.02754>. DOI: 10.1145/2939672.2939785, 2016, 13 с.
8. HASTIE T., TIBSHIRANI R., FRIEDMAN J. The Elements of Statistical Learning. Springer, 2009. 764 с.

REFERENCES

1. AYVAZYAN S.A., MKHITARYAN V.S. Applied Statistics and Foundations of Econometrics. Moscow: Unity, 1998:1022. (In Russian).
2. VORONTSOV V. Mathematical Methods of Precedents-Based Learning (Machine Learning Theory). Moscow, 2011. (In Russian).
3. GOLOVKO V.A. Neural Networks: Training, Organization, and Application: A Textbook. General Editor A.I. Galushkin. Moscow, 2001:256. (In Russian).
4. NIKOLENKO B.B., KUZNETSOV D.I., PODKOVKIN V.A., POPOV P.B., NIKULINA A.N. Using Artificial Intelligence Methods for Recognizing Radar Stations Based on Signal Radiotechnical Parameters with Filtering Out Signals Not Accounted for in the Training Set of Radar Stations. Radiotekhnika. 2024;5:15–27. (In Russian).
5. BREIMAN L. Random Forests. Machine Learning, 2001;45;1:5–32.
6. BREUNIG M.M., KRIEGLER H.-P., NG R.T., SANDER J.R. LOF: Identifying Density-Based Local Outliers, Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data, 2000:12.
7. CHEN T., GUESTRIN C. XGBoost: A Scalable Tree Boosting System. <https://arxiv.org/abs/1603.02754>. DOI: 10.1145/2939672.2939785, 2016:13.
8. HASTIE T., TIBSHIRANI R., FRIEDMAN J. The Elements of Statistical Learning. Springer, 2009:764.

Вагапов Егор Владиславович, техник 1 категории АО «ЦНИРТИ им. академика А.И. Берга»

✉ e-mail: vevagapov@mail.ru

Никулина Александра Николаевна, ведущий специалист АО «ЦНИРТИ им. академика А.И. Берга»

✉ e-mail: alex.post-x@yandex.ru

Рябикова Елена Владимировна, инженер-программист 1 категории АО «ЦНИРТИ им. академика А.И. Берга»

✉ 107078, г. Москва, ул. Новая Басманная, д. 20, стр. 9, 107078, Moscow, Novaya Basmannaya St., 20, building 9, тел.: +7 (968) 723-81-32, e-mail: essarabia@yandex.ru