

## Алгоритм распознавания малоразмерных воздушных целей по траекторным признакам в полуактивной РЛС

Дао Ван Лук<sup>1✉</sup>, А. А. Коновалов<sup>2</sup>, Ле Минь Хоанг<sup>1</sup>

<sup>1</sup>Государственный технический институт им. Ле Куи Дона, Ханой, Вьетнам

<sup>2</sup>НИИ "Прогноз", Санкт-Петербург, Россия

✉ [daolucvtl01@gmail.com](mailto:daolucvtl01@gmail.com)

### Аннотация

**Введение.** В последние несколько лет бурное развитие и широкое применение беспилотных воздушных средств (БВС) для решения самых разных задач формирует и новые угрозы. Особую значимость приобретает проблема обеспечения безопасности, особенно в зоне критически важных охраняемых объектов или в местах со сложной орнитологической обстановкой (аэропорты, объекты ветроэнергетики). В связи с этим возрастает актуальность обнаружения малоразмерных воздушных целей, распознавания их типа и степени опасности. В данной статье приведен алгоритм распознавания воздушных целей по траекторным признакам на основе технологии искусственного интеллекта. Представлены результаты сравнительного анализа качества методов классификации БВС и птиц на основе их траекторных признаков.

**Цель работы.** Разработка алгоритма распознавания малоразмерных воздушных целей по траекторным признакам на основе методов машинного обучения. Реализация и оценка качества методов принятия решения в заданной задаче распознавания.

**Материалы и методы.** Используются экспериментальные данные траекторий БВС и птиц, полученные в полуактивной радиолокационной системе (РЛС). Рассчитаны траекторные параметры целей, их статистические характеристики, сформирован набор признаков для распознавания. С помощью пакета MATLAB разработана программа для реализации алгоритма распознавания и анализа качества методов принятия решения.

**Результаты.** Представлен алгоритм распознавания воздушных целей на основе технологии искусственного интеллекта. Проведен сравнительный анализ шести наиболее распространенных методов распознавания на основе машинного обучения (наивный байесовский метод, решающие деревья, метод  $k$ -ближайших соседей, нейросетевой алгоритм распознавания, метод опорных векторов, метод случайных лесов), который показал, что в условиях данной задачи наиболее эффективными являются метод  $k$ -ближайших соседей и метод опорных векторов.

**Заключение.** Полученные результаты свидетельствуют о том, что предложенные методы позволяют определить класс целей по набору отметок их траекторий. Дальнейшие исследования будут направлены на разработку и реализацию алгоритма распознавания в реальном времени.

**Ключевые слова:** радиолокационное распознавание, алгоритм распознавания, машинное обучение, малые БВС, траекторные признаки, полуактивная РЛС

**Для цитирования:** Дао Ван Лук, Коновалов А. А., Ле Минь Хоанг. Алгоритм распознавания малоразмерных воздушных целей по траекторным признакам в полуактивной РЛС // Изв. вузов России. Радиоэлектроника. 2023. Т. 26, № 5. С. 76–88. doi: 10.32603/1993-8985-2023-26-5-76-88

---

**Конфликт интересов.** Авторы заявляют об отсутствии конфликта интересов.

Статья поступила в редакцию 26.09.2023; принята к публикации после рецензирования 30.10.2023; опубликована онлайн 29.11.2023

---

## Algorithm for Recognition of Small Air Targets by Trajectory Features in Passive Bistatic Radar

Dao Van Luc<sup>1✉</sup>, Aleksandr A. Konovalov<sup>2</sup>, Le Minh Hoang<sup>1</sup>

<sup>1</sup>Le Quy Don Technical University, Ha Noi, Viet Nam

<sup>2</sup>Research Institute "Prognoz", St Petersburg, Russia

✉ lehoang.navy@gmail.com

### Abstract

**Introduction.** In the past few years, the rapid development and widespread use of unmanned aerial vehicles (UAVs) for solving a variety of tasks has created new threats. The problem of ensuring the safety of protected objects, especially in the area of critically important objects or in places with difficult ornithological conditions (airports, wind power facilities), is of particular importance. In this regard, the issue of detecting small air targets and recognizing their type and degree of danger is acquiring greater importance. This paper presents an algorithm for recognizing air targets based on artificial intelligence technology. The results of a comparative analysis of decision-making methods for recognizing small UAVs and birds based on their trajectory features are presented. The results obtained can be used in the development of systems for recognizing classes of small airborne targets in existing and future radar stations.

**Aim.** Development of an algorithm for recognizing small air targets by trajectory features based on machine learning. Implementation and evaluation of the quality of decision-making methods in a given recognition problem.

**Materials and methods.** Experimental data on the trajectories of UAVs and birds obtained in a passive bistatic radar system are used. The trajectory parameters of the targets and their statistical characteristics are calculated; a set of features for recognition is formed. Using the MATLAB software package, a program for implementing the recognition algorithm and analyzing the quality of decision-making methods was developed.

**Results.** An algorithm for recognizing air targets based on artificial intelligence technology is presented. A comparative analysis of the six most common recognition methods based on machine learning (Naïve Bayes, decision trees,  $k$ -nearest neighbors, neural network recognition algorithm, support vector machine, random forests) was carried out, which showed that, under the conditions of this problem, the most effective are  $k$ -nearest neighbor method and support vector machine.

**Conclusion.** The presented methods can be used to directly determine the class of targets from a set of marks of their trajectories. Further research will be aimed at developing and implementing a real-time recognition algorithm.

**Keywords:** radar target recognition, recognition algorithm, machine learning, small UAVs, trajectory features, passive bistatic radar

**For citation:** Dao Van Luc, Konovalov A. A., Le Minh Hoang. Algorithm for Recognition of Small Air Targets by Trajectory Features in Passive Bistatic Radar. Journal of the Russian Universities. Radioelectronics. 2023, vol. 26, no. 5, pp. 76–88. doi: 10.32603/1993-8985-2023-26-5-76-88

**Conflict of interest.** The authors declare no conflicts of interest.

Submitted 26.09.2023; accepted 30.10.2023; published online 29.11.2023

**Введение.** При разработке современных радиолокационных систем особое внимание уделяется обнаружению и распознаванию малоразмерных воздушных целей, таких, как беспилотные воздушные суда (БВС). БВС находят все большее применение в сферах жизнедеятельности человека. Они широко используются для наблюдения за ростом посевов, оперативной доставки грузов даже в труднодоступные участки, отслеживания речных затворов, дорожных

пробок, спасения пострадавших и ликвидации последствий стихийных бедствий, для прогнозирования чрезвычайных ситуаций и постоянного мониторинга потенциально опасных районов и т. д. В военном деле многороторные БВС могут использоваться для разведки и слежения за наземными целями, перехвата воздушных целей, управления огнем и целеуказания, нести забрасываемые передатчики помех или вооружение для атаки целей самостоятельно.

Алгоритм распознавания малоразмерных воздушных целей по траекторным признакам в полуактивной РЛС

Algorithm for Recognition of Small Air Targets by Trajectory Features in Passive Bistatic Radar

Однако технический прогресс в области подобных разработок имеет и другую сторону – за последние несколько лет существенно возросла опасность причинения вреда с применением БВС, например появление БВС-нарушителя на взлетно-посадочной полосе, террористические атаки БВС по объектам инфраструктуры. С использованием беспилотных средств совершившие их лица смогли причинить потерпевшим большие финансовые убытки, нанести потери стратегическим объектам [1–3].

Таким образом, все вышеперечисленное делает задачу обнаружения и противодействия БВС актуальной и насущной. Способы противодействия угрозам БВС классифицируют следующим образом [4]:

- превентивно-профилактические ограничения на полеты БВС;
- обнаружение и распознавание (или идентификация) БВС;
- локализация беспилотного аппарата и его оператора;
- нейтрализация (прекращение функционирования) беспилотного аппарата.

Для мониторинга воздушного пространства, обнаружения и распознавания таких малых целей предпочтительным и эффективным средством являются радиолокационные системы (РЛС). В настоящее время особое внимание уделяется полуактивным РЛС, которые имеют ряд преимуществ, обусловленных отсутствием собственного передатчика, а именно: экономичность, высокая скрытность, отсутствие помех другим радиотехническим устройствам.

В настоящее время исследования в области распознавания малоразмерных целей фокусируются в основном на анализе сигнальных признаков (например, микродоплеровских характеристик). Однако использование этих признаков во многих случаях оказывается неэффективным [5–7]. По этой причине анализ траекторных признаков представляется полезным альтернативным подходом, который можно интегрировать с анализом сигнальных признаков. При распознавании воздушных целей могут быть использованы такие траекторные признаки, как высота полета, скорость, ускорение, курс, скорость поворота, рывок [8].

В данной статье приведены результаты разработки алгоритма распознавания малоразмерных целей с применением технологии искусственного интеллекта. Предлагаемый алгоритм осуществляет классификацию БВС и птиц на основе траекторных признаков. Проведена оценка качества методов принятия решения при распознавании малоразмерных воздушных целей.

#### Материалы и методы исследований.

В данном исследовании используются экспериментальные данные в виде траекторий, записанных полуактивной РЛС. На рис. 1 и 2 приведены примеры траекторий птицы и БВС в прямоугольной системе координат.

Блок-схема алгоритма распознавания малозаметных радиолокационных целей (РЛЦ) по траекторным признакам показана на рис. 3.

Принцип работы алгоритма заключается в следующем. Входной информацией алгоритма являются первичные отметки, сформированные устройством обнаружения. Они подвергаются предварительной обработке в ходе траекторного сопровождения (обнаружение траектории, отождествление, фильтрация), результатом которой являются траектории объектов, свобод-

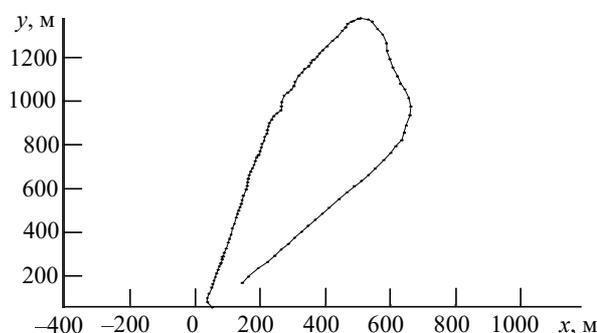


Рис. 1. Траектория полета БВС

Fig. 1. UAV trajectory

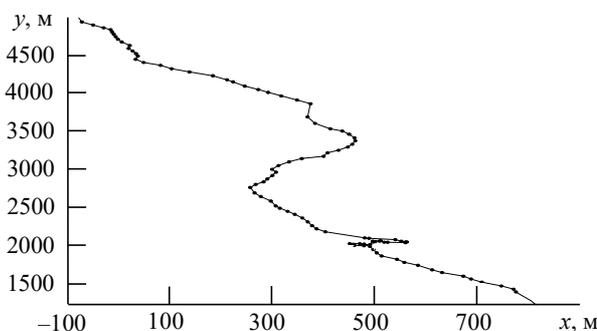


Рис. 2. Траектория полета птицы

Fig. 2. Bird trajectory

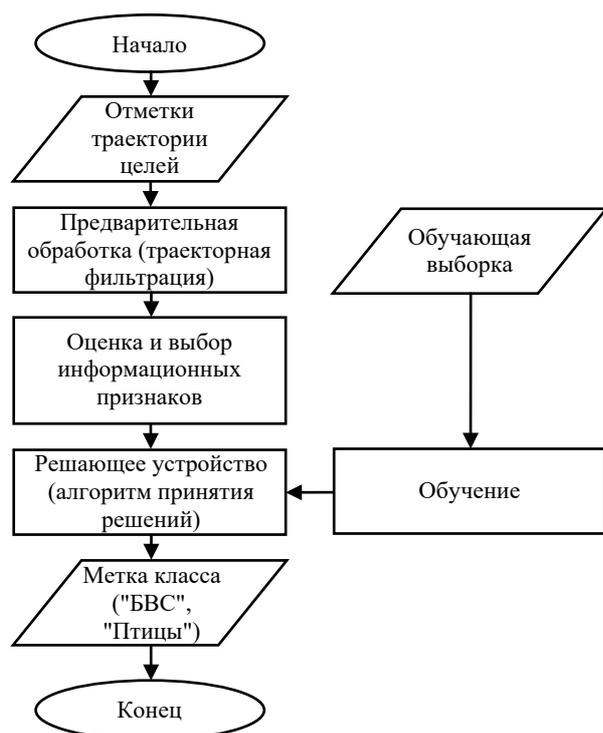


Рис. 3. Блок-схема алгоритма распознавания малоразмерных целей по траекторным признакам  
 Fig. 3. A block diagram of the recognition algorithm for small targets by trajectory features

ные от ложных наблюдений и имеющие уточненные значения вектора состояния. После этого выполняется оценка информационных признаков, на основе значений которых решающее устройство, являющееся алгоритмом принятия окончательного решения, относит объект к одному из двух возможных классов. Результат его работы – метка класса, присвоенная данной траектории.

**Предварительная траекторная обработка.** Состояние движущегося объекта описывается набором параметров, образующих вектор состояния: координаты, скорость, ускорение и т. д. В ходе траекторной обработки решаются следующие задачи: обнаружение траектории, отождествление измерений с траекториями, фильтрация, сброс траектории. В простейшем случае, когда существует точная информация о принадлежности каждой отметки к одной из истинных целей, траекторная обработка сводится к фильтрации параметров траекторий [9].

Траекторная фильтрация необходима для исключения выбросов и ошибок измерения, обеспечивает сглаживание траектории. В данном исследовании применен фильтр Калмана, в

котором модели состояния и наблюдения описываются так:

$$\begin{aligned} \mathbf{x}_{k+1} &= F_k \mathbf{x}_k + \mathbf{w}_k; \\ \mathbf{z}_k &= H_k \mathbf{x}_k + \mathbf{v}_k, \end{aligned}$$

где  $\mathbf{x}$  – вектор состояния;  $F$  – переходная матрица;  $\mathbf{w}$  – шум процесса;  $\mathbf{z}$  – вектор измерения;  $H$  – матрица наблюдения;  $\mathbf{v}$  – шум измерения с ковариационной матрицей  $R$ .

Результирующая оценка вектора состояния  $\hat{\mathbf{x}}_k$  и ее ковариационная матрица  $P_k$  на  $k$ -м шаге вычисляются следующим образом:

$$\begin{aligned} \hat{\mathbf{x}}_k &= \hat{\mathbf{x}}_{k|k-1}^k + K_k (\mathbf{z}_k - H \hat{\mathbf{x}}_{k|k-1}); \\ P_k &= (I - K_k H_k) P_{k|k-1}, \end{aligned}$$

где  $\hat{\mathbf{x}}_{k|k-1}^k$  и  $P_{k|k-1}$  – экстраполированная оценка вектора состояния и ее ковариация;  $K_k = P_k H^T R_k^{-1}$  – матричный коэффициент усиления фильтра Калмана ( $t$  – символ транспонирования);  $I$  – единичная матрица.

**Оценка признаков распознавания.** Поведение БВС во время полета мотивировано выполнением поставленных перед ними конкретных задач, таких, как, например, наблюдение или доставка. Поэтому режим полета БВС зависит от сочетания способа выполнения задачи и действия оператора по управлению. Напротив, птицы обладают сознательным поведением, которое тесно связано с их привычками и различается у разных видов. Например, у перелетных и местных птиц есть явные различия в поведении. Птицы одного и того же вида также могут проявлять различные варианты маневрирования при охоте за пищей, поиске ночлега и т. д. Таким образом, учитывая большое количество видов и их разнообразные повадки, у птиц может наблюдаться гораздо больше способов поведения, чем у БВС.

С точки зрения механизма полета, все части БВС жестко связаны между собой, его движение будет достаточно стабильным. Напротив, движение птиц, обусловленное взмахами крыльев, жестким не является. Птицы осуществляют маневры, регулируя положение и характер взмахов крыльев. Аэродинамика доминирует в маневрировании птиц и обычно сложнее, чем у БВС из-за их нежесткости.

Следовательно, даже если птицы и БВС имеют одинаковую скорость полета, из-за присущих им различий в механике полета и поведения статистические значения некоторых траекторных параметров могут различаться. Поскольку птица – живое существо, характеристики ее движения более случайны, интенсивность и диапазон изменения параметров полета птицы будут больше.

Исследование особенностей различных траекторных признаков позволило предложить следующую совокупность параметров для использования при распознавании БВС и птиц [10]:

– средняя скорость цели  $v_c$  и ее СКО  $\sigma_v$ :

$$v_c = \frac{1}{N} \sum_{k=1}^N v_k;$$

$$\sigma_v = \frac{1}{N} \sqrt{\sum_{k=1}^N (v_k - v_c)^2},$$

где  $v_k = \sqrt{v_{x(k)}^2 + v_{y(k)}^2}$  – модуль скорости;  $v_{x(k)} = \frac{x_k - x_{k-1}}{\Delta t_k}$ ;  $v_{y(k)} = \frac{y_k - y_{k-1}}{\Delta t_k}$ ;  $[x_k, y_k]$  – вектор координат цели;  $\Delta t_k$  – время между двумя отметками на  $k$ -м и  $(k-1)$ -м шагах оценивания;

– среднее ускорение  $a_c$  и его СКО:

$$a_c = \frac{1}{N} \sum_{k=1}^N a_k;$$

$$\sigma_a = \frac{1}{N} \sqrt{\sum_{k=1}^N (a_k - a_c)^2}.$$

Здесь  $a_k = \sqrt{a_{x(k)}^2 + a_{y(k)}^2}$  – модуль ускорения на  $k$ -м шаге оценивания;  $a_{x(k)}$ ,  $a_{y(k)}$  вычитаются по вектору скорости;

– курс  $\varphi$  и его СКО:

$$\varphi'_k = \text{tg}^{-1} [v_{x(k)} / v_{y(k)}];$$

$$\varphi_k = \begin{cases} \varphi'_k + 360^\circ, & \text{если } \varphi'_k - \varphi'_{k-1} > 180^\circ; \\ \varphi'_k - 360^\circ, & \text{если } \varphi'_k - \varphi'_{k-1} < -180^\circ; \\ \varphi'_k, & \text{если } -180^\circ < \varphi'_k - \varphi'_{k-1} < 180^\circ, \end{cases}$$

тогда СКО курса  $\varphi$ :  $\sigma_\varphi = \frac{1}{N} \sqrt{\sum_{k=1}^N (\varphi_k - \varphi_c)^2}$ ;

– средняя угловая скорость поворота  $\omega_c$  и ее СКО:

$$\omega_c = \frac{1}{N} \sum_{k=1}^N \omega_k;$$

$$\sigma_\omega = \frac{1}{N} \sqrt{\sum_{k=1}^N (\omega_k - \omega_c)^2}.$$

Здесь  $\omega_k$  – угловая скорость поворота на  $k$ -м шаге оценивания.

**Алгоритмы принятия решения.** Для решения поставленной задачи существует множество алгоритмов классификации, таких, как байесовский алгоритм; дерево решений; метод  $k$ -ближайших соседей; метод случайного леса; метод опорных векторов; нейросетевой алгоритм [11].

*Алгоритмы на основе байесовского подхода.* Для применения байесовского метода необходимо знать распределения вероятностей используемых информативных признаков. Рассмотрим частный случай байесовского подхода к принятию решений на примере, в котором некоторый признак  $X$  используется в качестве информативного признака в задаче распознавания двух классов  $A$  и  $B$ . Априорные вероятности принадлежности цели к этим классам обозначим как  $P(A)$  и  $P(B)$ , тогда  $P(A) + P(B) = 1$ , так как в примере рассматривается только два возможных класса целей. Плотности распределения вероятностей оценки признака целей классов  $A$  и  $B$   $p(X|A)$  и  $p(X|B)$  показаны на рис. 4.

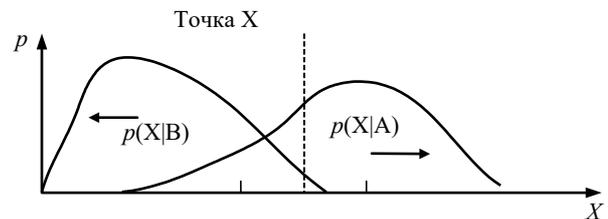


Рис. 4. Плотности распределения вероятностей оценки информативного признака целей двух классов

Fig. 4. Probability distribution densities for estimating the informative feature of targets of two classes

Используется теорема Байеса для вычисления и обновления апостериорных вероятностей принадлежности цели к классам  $A$  и  $B$ :

$$P(A|X) = \frac{p(X|A)P(A)}{p(X|A)P(A) + p(X|B)P(B)};$$

$$P(B|X) = \frac{p(X|B)P(B)}{p(X|A)P(A) + p(X|B)P(B)}.$$

Для принятия решения наиболее часто применяется критерий максимума апостериорной вероятности.

*Дерево решений* – это структурированное иерархическое дерево, включающее в себя элементы двух типов – узлы (node) и листья (leafs). Дерево решений используется для классификации объектов на основе последовательности правил. Узлы содержат правила принятия решений и примеры проверки на соответствие выбранному атрибуту обучающего набора. Лист определяет метку класса для каждого поступающего в него объекта.

Дерево решений – простой и популярный алгоритм, который нашел широкое применение благодаря следующим своим достоинствам:

- модель генерирует правила, которые легко понять исследователю, создавая набор правил, где каждая листовая ветвь является правилом дерева;
- в алгоритме не требуется нормализация или создание фиктивных переменных;
- может работать как с числовыми, так и с категориальными и с большими данными;
- модель можно проверить с помощью статистических тестов.

На данный момент существует много алгоритмов генерации деревьев, таких, как CART; CHAID; ID3; C4.5; C5.0 и т. д. В каждом алгоритме построения критерии, рассматриваемые для выбора наилучшего признака, обеспечивающего лучшее разделение, могут быть разными. Например, алгоритм CART использует индекс примесей Джини для определения наилучшего признака, обеспечивающего наилучшее разделение. Аналогично, ID3 и C4.5 используют прирост информации (выбор признака, для которого энтропия минимальна, а информационная выгода максимальна). Значение информационной энтропии вычисляется по формуле

$$H = - \sum_{k=1}^n \frac{N_k}{N} \log_2 \left( \frac{N_k}{N} \right),$$

где  $N_k$  – число объектов  $k$ -го класса;  $N$  – общее число объектов в подмножестве;  $n$  – число классов в исходном подмножестве.

В данной статье используется алгоритм генерации CART. Чтобы построить дерево решений, следует рассчитать индекс Джини для каждого признака. Индекс Джини используется для определения степени разделения дерева решений. Этот индекс используется для измерения и оценки того, является ли разделение в узле условия хорошим или нет. Он основан на возведении в квадрат вероятностей членства для каждой целевой категории в узле. Его значение приближается к минимуму (нулю), когда каждый экземпляр узла попадает в одну целевую категорию. Формула для расчета индекса Джини имеет вид [11, 12]

$$\text{Gini}(Q) = 1 - \sum_{i=1}^n p_i^2,$$

где  $Q$  – результирующее множество;  $n$  – число классов в нем;  $p_i$  – вероятность  $i$ -го класса. Лучшим разбиением будет то, у которого минимальное значение индекса Джини.

*Метод  $k$ -ближайших соседей.* Метод  $k$ -ближайших соседей (англ.  $k$ -Nearest Neighbors Algorithm – KNN) – широко известный традиционный метод со статистическим подходом. При необходимости распознавания нового объекта алгоритм определяет расстояние (может применять формулы расстояния) всех объектов относительно этого объекта, чтобы найти  $k$ -ближайших объектов, так называемых  $k$ -ближайших соседей, а затем использовать эти расстояния для взвешивания всех классов. Вес класса представляет собой сумму всех указанных выше расстояний объектов в  $k$ -соседях, имеющих одну и ту же метку данного класса. Затем классы будут отсортированы по уменьшению значению веса, класс с самым высоким весом будет выбран в качестве результата. В статье используется метрика Минковского, число ближайших соседей равно 5 [13, 14].

*Метод опорных векторов* (англ. Support Vector Machine – SVM). Метод опорных векторов – это семейство методов, основанных на функциях ядра для минимизации риска оценки. Основная идея этого алгоритма заключается в том, что при наличии обучающего набора, представленного в векторном пространстве, где каждый объект является точкой, находится плоскость решения, которая может наилучшим

образом разделить точки в пространстве на 2 отдельных слоя. Разделяющая классы функция представляет собой разделяющую гиперплоскость. Качество этой гиперплоскости определяется расстоянием (называемым границей) ближайшей точки данных каждого слоя от этой плоскости. Чем больше граничное расстояние, тем лучше плоскость принятия решения и тем точнее классификация. Цель алгоритма SVM – найти наибольшее граничное расстояние [12, 15]. В работе используется радиальная основная функция в качестве разделяющей гиперплоскости.

*Нейросетевой алгоритм распознавания.* Применение нейросетевого алгоритма является одним из наиболее перспективных путей для решения задачи распознавания РЛЦ. Искусственная нейронная сеть, часто сокращаемая до нейронной сети, – это вычислительная модель, построенная на основе биологических нейронных сетей. Нейронные сети различаются числом слоев, функцией активации, алгоритмом обучения.

Одной из самых первых и популярных искусственных нейронных сетей является сеть, построенная на многослойном перцептроне (англ. Multilayer Perceptron – MLP), которая позволяет распознавать объект в соответствии с предварительным обучением сети [11]. Нейронная сеть состоит из нескольких слоев, которые подразделяются на 3 типа: входной слой (представляет входные данные), выходной слой (выполняет задачу распознавания) и скрытый слой, представляющий процесс обработки информации и вывода в сети. Он будет получать входную информацию на входе и возвращать результаты на выходе через функцию активации. В процессе обучения MLP автоматически извлекают признаки, определяют их важность и выстраивают связи между ними. На рис. 5 показана структура типичного многослойного перцептрона.

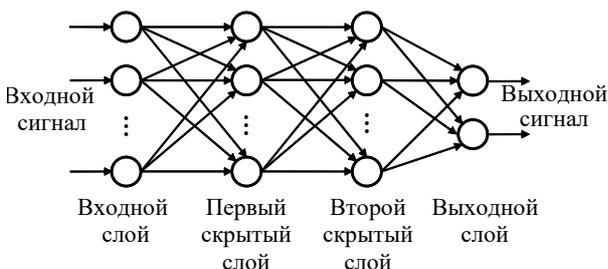


Рис. 5. Структура типичного многослойного перцептрона  
Fig. 5. Structure of a typical multilayer perceptron

В данной статье применяется MLP, состоящий из трех скрытых слоев со 100 нейронами в каждом, для активации используется сигмовидная функция.

*Метод случайного леса.* Термином "случайный лес" (Random Forest) определяют семейство методов машинного обучения, включающее различные алгоритмы для создания набора деревьев решений, такие, как алгоритм леса Бреймана. Суть алгоритма случайного леса заключается в том, что он может комбинировать несколько деревьев решений вместо того, чтобы принимать выбор на основе решения одного дерева. Таким образом, метод случайного леса может уменьшить ошибку и улучшить производительность прогнозирования. Этапы обучения включают построение набора деревьев решений, каждое из которых основано на "начальном" подмножестве из исходного обучающего набора, т. е. используя принцип упаковки, и метод индукции дерева, называемый случайным деревом. Такой алгоритм индукции обычно основан на алгоритмах дерева классификации и регрессии. Метод случайного леса включает в себя следующие этапы [16, 17]:

1. Для  $i = 1, 2, \dots, N$  (здесь  $N$  – количество деревьев в ансамбле): сформировать бутстреп-выборку  $S$  размера  $l$  по исходной обучающей выборке  $D$ , по бутстреп-выборке  $S$  индуцировать неусеченное дерево решений  $T_i$ . После выполнения первого этапа получаем набор деревьев решений  $\{T_i\}_1^N$ .

2. Предсказание новых наблюдений выполнять следующим образом: пусть  $k_i(x) \in \{k_1, k_2, \dots, k_n\}$  – класс, предсказанный деревом решений  $T_i$ , т. е.  $T_i(x) = k_i(x)$ ; тогда  $k_{rf}^N(x)$  – класс большинства голосов во множестве  $\{k_b(x)\}_1^N$ .

Метод случайного леса позволяет осуществлять параллельное обучение на основе нескольких деревьев решений, которые построены случайным образом и обучены с использованием множества подмножеств, содержащих разные выборки. Каждое дерево в лесу обучается подмножеством со случайно распределенными данными по принципу бэггинга, а

также имеет случайные признаки. Окончательные результаты представляют собой среднее значение каждого дерева решений для задачи регрессии или определяются по результату большинства для задачи классификации данных.

**Метрики оценки качества распознавания.** Первым критерием качества является аккуратность (accuracy) – доля правильно классифицированных объектов [12, 18]:

$$A = \frac{TP + TN}{TP + FP + TN + FN},$$

где TP – число целей, для которых алгоритм принятия решения верно определил принадлежность к текущему классу; TN – число целей, для которых алгоритм принятия решения верно определил, что они не принадлежат к текущему классу; FP – ложно-положительные решения; FN – ложно-отрицательные решения.

Для оценки качества работы алгоритма на каждом из классов по отдельности введем метрики *точность* и *полнота*:

– точность (precision) рассчитывается по следующей формуле:

$$P = \frac{TP}{TP + FP};$$

– полнота (recall):

$$R = \frac{TP}{TP + FN}.$$

**Результаты и их обсуждение.** Экспериментальные расчеты проводились на ПК с процессором Intel Core i5-9400H, 8 Гбайт. Выбран язык программирования MATLAB, так как в библиотеке среды MATLAB поддерживается множество функций для технологии искусственного интеллекта. Разработанная программа позволяет анализировать качество методов распознавания траекторий малоразмерных воздушных объектов.

Результат сравнительного анализа качества распознавания целей различными алгоритмами принятия решения  
Accuracy comparison for recognition algorithms of small targets by trajectory features

Классификатор	Метрика		
	Аккуратность (Accuracy), %	Точность (Precision), %	Полнота (Recall), %
Наивный байесовский алгоритм	93.0	78.6	98.2
Решающие деревья (CART)	95.6	92.6	89.3
Метод $k$ -ближайших соседей	97.9	94.7	96.4
Метод опорных векторов (SVM)	97.9	94.7	96.4
Многослойный перцептрон	96.1	92.7	91.7
Метод случайных лесов	97.4	94.6	94.6

Результат сравнения качества распознавания целей при использовании различных методов представлен в таблице.

Каждый метод строится и рассчитывается на обучающей выборке, затем на тестовой выборке оценивается качество классификации. Обучающая выборка включает в себя 283 участка траекторий; тестовая выборка – 229 участков.

Траекторные признаки, используемые в качестве входных данных для методов распознавания: средняя скорость, среднее ускорение, курса, средняя скорость поворота, и их среднеквадратические отклонения. На рис. 6 показан график СКО скорости и курса в качестве признака распознавания.

На рис. 7 приведена матрица ошибок при распознавании БВС и птиц разными методами принятия решения.

На практике для оценки качества метода распознавания помимо критериев точности, также важны критерии времени расчета и времени принятия решения. На рис. 8 приведено сравнение времени обучения и принятия решения для разных методов распознавания.

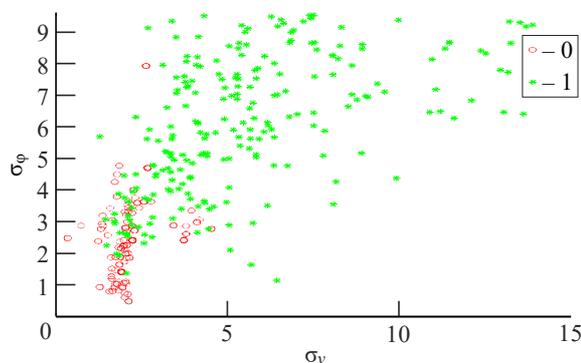


Рис. 6. СКО скорости и СКО курса в качестве признака распознавания (класс 1: птицы, класс 0: БВС)

Fig. 6. RMS of speed and heading as recognition features (class 1: birds, class 0: UAV)

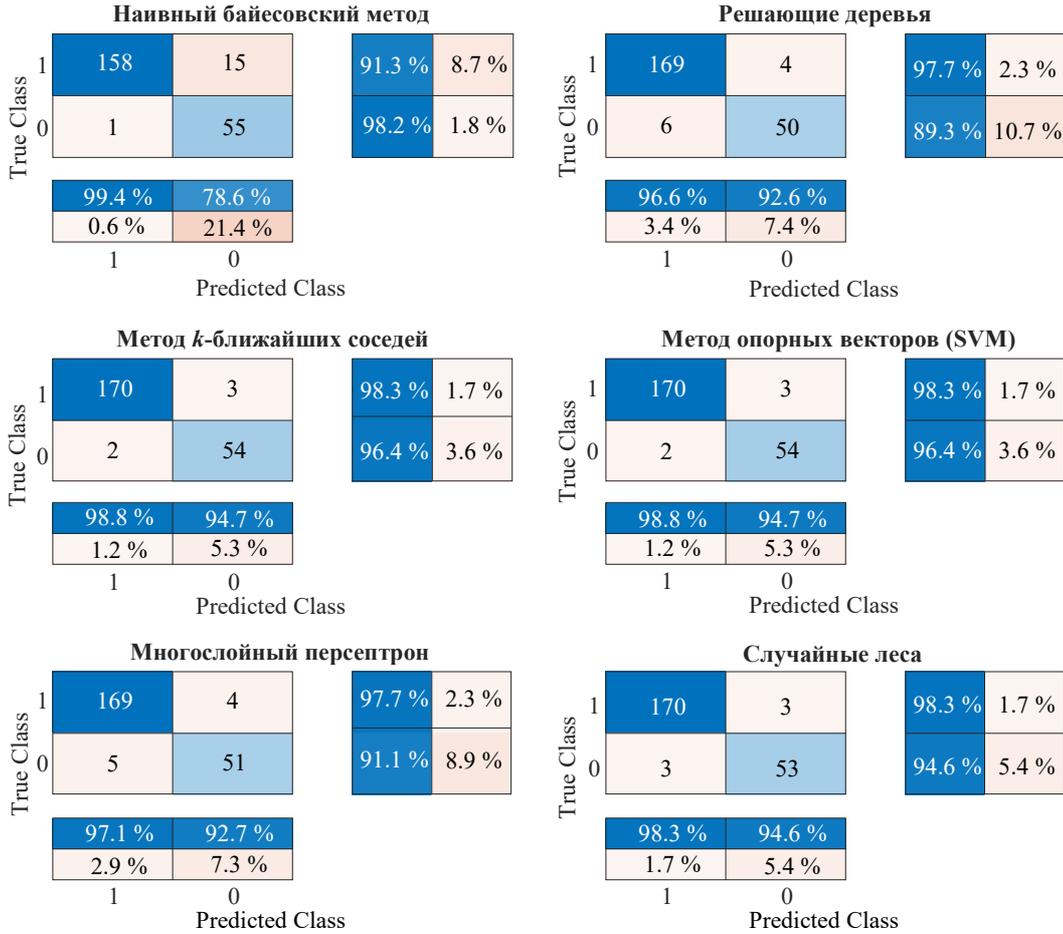


Рис. 7. Матрица ошибок различных алгоритмов принятия решения при распознавании БВС и птиц по траекторным признакам (класс 1: птицы, класс 0: БВС)

Fig. 7. Confusion matrix for recognition algorithms of small targets by trajectory features

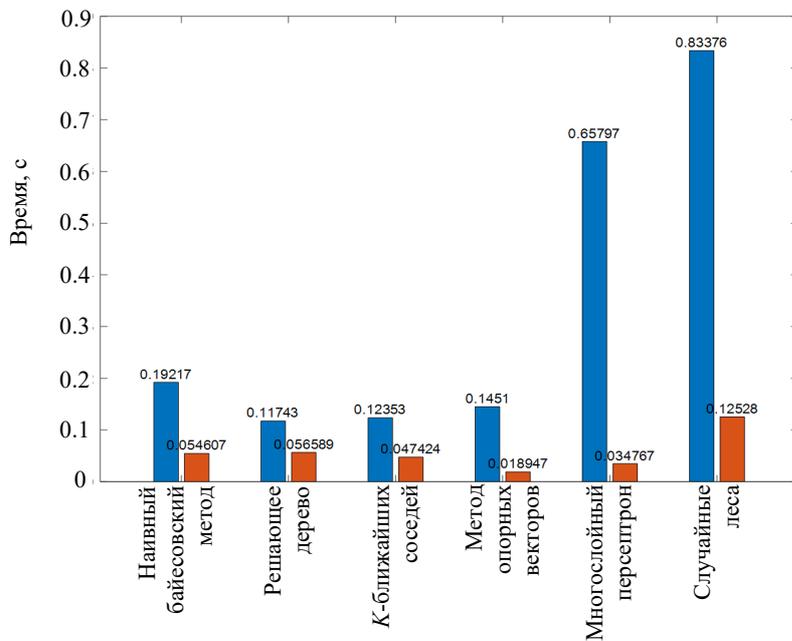


Рис. 8. Сравнение времени обучения и вычисления алгоритмов принятия решения (синий: обучение, оранжевый: вычисление)

Fig. 8. Comparison of training and calculation time for recognition algorithms (blue: learning, orange: calculation)

Таким образом, все рассмотренные в статье методы в той или иной степени применимы для решения поставленной задачи. Оценка качества распознавания показала, что значения метрик распознавания (тестовый набор данных состоит из 229 траекторий) находятся в диапазоне 78...98 % правильных ответов, аккуратность всех методов превышает 90 %, причем наилучший результат показали метод  $k$ -ближайших соседей и метод опорных векторов. Нейросетевой алгоритм дает высокую точность, при этом ожидается лучший результат с большей обучающей выборкой. Точность распознавания целей байесовским методом уступила точности распознавания при использовании других методов по причине трудности определения плотности распределения вероятностей оценки информативного признака.

Случайный лес строится на основе использования большого ансамбля решающих деревьев. Качество распознавания метода случайного леса превзошло результат решающего дерева, но для своей реализации случайный лес требует значительного объема вычислительных ресурсов и занимает много времени на обучение и вычисление.

Выигрыш по времени обучения обеспечивают наивный байесовский метод, решающие деревья, метод  $k$ -ближайших соседей, метод опорных векторов.

В данном исследовании используется определенный набор траекторных параметров (скорость, ускорение, курс, угловая скорость поворота и их СКО), по которым проводится распознавание воздушных целей. Его можно расширить и дополнить новыми параметрами в зави-

симости от метода анализа данных, тактико-технических характеристик РЛС и типа целей.

**Заключение.** В данном исследовании предложен алгоритм классификации низколетящих малоразмерных целей на основе их траекторных характеристик. Ключевым подходом для решения задачи является применение методов искусственного интеллекта. Первичные отметки, используемые в процессе обучения, предварительно обработаны алгоритмом траекторной фильтрации с целью оптимизации оценок параметров движения цели. Представлен результат сравнения эффективности шести методов классификации (байесовский метод, решающее дерево, метод  $k$ -ближайших соседей, нейросетевой алгоритм, метод случайных лесов, метод опорных векторов), который показал, что наиболее эффективными являются методы  $k$ -ближайших соседей и опорных векторов.

Таким образом, анализ качества методов принятия решений показал перспективность использования траекторных признаков в задаче распознавания малоразмерных воздушных целей. Вероятность правильного распознавания может достигать 98 %. Время распознавания типа объекта составляет 20–30 обзоров РЛС.

Результаты, полученные в данном исследовании, могут быть использованы при разработке и совершенствовании систем радиолокационного распознавания малых воздушных целей на основе траекторных признаков.

Возможными направлениями дальнейших исследований являются разработка и реализация алгоритма распознавания целей для работы в реальном времени, а также объединение результатов работы нескольких классификаторов, например по траекторным и по сигнальным признакам.

### Список литературы

1. UAV Target Detection Algorithm Using GNSS-Based Bistatic Radar / H. Zeng, H. Zhang, J. Chen, W. Yang // IGARSS 2019 – IEEE Intern. Geoscience and Remote Sensing Symp., Yokohama, Japan, 28 July – 02 Aug. 2019. IEEE, 2019. P. 2167–2170. doi: 10.1109/IGARSS.2019.8898935
2. Макаренко С. И. Противодействие беспилотным летательным аппаратам СПб.: Научно-технологические исследования, 2020. 204 с.
3. Magnitude and spectrum of electromagnetic wave scattered by small quadcopter in X-band / A. V. Khristenko, M. O. Konovalenko, M. Rovkin, V. Khlusov, A. V. Marchenko, A. A. Sutulin, N. Maluyutin // IEEE Trans. on

Antennas and Propagation. 2018. Vol. 66, № 4. P. 1977–1984. doi: 10.1109/TAP.2018.2800640

4. Как противодействовать применению беспилотных летательных аппаратов в террористических целях. URL: <https://www.tbforum.ru/blog/kak-protivodejstvovat-primeneniyu-bespilotnyh-letatelnyh-apparatov-v-terroristicheskikh-celyah> (дата обращения 23.05.2023)

5. Воробьев Е. Н. Исследование сигнальных признаков распознавания малых БПЛА в полуактивной РЛС // Вестн. Новгородского гос. ун-та им. Ярослава Мудрого. 2019. № 4 (116). С. 72–77. doi: 10.34680/2076-8052.2019.4(116).72-77

6. Алгоритм распознавания малоразмерных воздушных объектов на основе анализа радиолокационных спектральных портретов / И. Д. Петров, В. П. Шкодырев, А. А. Сенцов, С. А. Иванов // Т-Comm: Телекоммуникации и транспорт. 2022. Т. 16, № 3. С. 4–10. doi: 10.36724/2072-8735-2022-16-3-4-10

7. Dinevich L., Leshem Y. Algorithmic system for identifying bird radio-echo and plotting radar ornithological charts // The Ring. 2007. Vol. 29, № 1–2. С. 3–39. doi: 10.2478/v10050-008-0040-z

8. Liu J., Xu Q. Y., Chen W. S. Classification of Bird and Drone Targets Based on Motion Characteristics and Random Forest Model Using Surveillance Radar Data // IEEE Access. 2021. Vol. 9. С. 160135–160144. doi: 10.1109/access.2021.3130231

9. Коновалов А. А. Основы траекторной обработки радиолокационной информации. Ч. 2. СПб.: Изд-во СПбГЭТУ "ЛЭТИ", 2014. 180 с.

10. Dao L. V., Konvalov A. A., Le H. M. Analysis of Trajectory Features for Small UAVs Recognition // 2022 Conf. of Russ. Young Researchers in Electrical and Electronic Engineering (ElConRus). IEEE, 2022. P. 1341–1345. doi: 10.1109/ElConRus54750.2022.9755753

11. Дао В. Л. Распознавание малоразмерных воздушных РЛЦ по траекторным признакам с использованием методов машинного обучения // СПбНТОРЭС: тр. ежегодной НТК. 2023. № 1. С. 58–61.

12. Субботин С. А. Построение деревьев решений для случая малоинформативных признаков // Радио-

электроника, информатика, управления. 2019. № 1 (48). С. 122–131. doi: 10.15588/1607-3274-2019-1-12

13. Бородинов А. А., Мясников В. В. Сравнение алгоритмов классификации радарных изображений при различных методах предобработки на примере базы MSTAR // Сб. тр. IV Междунар. конф. и молодежной школы "Информационные технологии и нанотехнологии" (ИТНТ-2018). Самара: Новая техника, 2018. С. 586–594.

14. Barbaresco F., Brooks D., Adnet C. Machine and Deep Learning for Drone Radar Recognition by Micro-Doppler and Kinematic criteria // IEEE Radar Conf. (RadarConf20), Florence, Italy, 21–25 Sept. 2020. IEEE, 2020. P. 1–6. doi: 10.1109/RadarConf2043947.2020.9266371

15. Донской В. И. Алгоритмические модели обучения классификации. Симферополь: ДИАЙПИ, 2014. 228 с.

16. Чистяков С. П. Случайные леса: обзор // Тр. Карельского науч. центра Российской академии наук. 2013. № 1. С. 117–136.

17. Dietterich T. G. An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization // Machine learning. 2000. Vol. 40, № 2. P. 139–157. doi: 10.1023/A:1007607513941

18. Machine Learning Metrics: How to Measure the Performance of a Machine Learning Model. URL: <https://www.altexsoft.com/blog/machine-learning-metrics/> (дата обращения 23.05.2023)

### Информация об авторах

**Дао Ван Лук** – специалист по направлению "Радиоэлектронные системы и комплексы" (2016), аспирант Государственного технического института им. Ле Куй Дона, Ханой, Вьетнам. Автор пяти научных публикаций. Сфера научных интересов – радиолокация; радиолокационное распознавание; вторичная и третичная обработка радиолокационной информации.

Адрес: Государственный технический институт им. Ле Куй Дона, ул. Хоанг Куок Вьет, д. 236, район Бак Ты Лиен, Ханой, Вьетнам

E-mail: [daolucvt101@gmail.com](mailto:daolucvt101@gmail.com)

<https://orcid.org/0000-0001-8006-3076>

**Коновалов Александр Анатольевич** – кандидат технических наук (2015), старший научный сотрудник НИИ "Прогноз". Автор более 60 научных работ. Сфера научных интересов – вторичная и третичная обработка радиолокационной информации; объединение данных; многопозиционная радиолокация; бистатические радиотехнические системы.

Адрес: НИИ "Прогноз", ул. Профессора Попова, д. 5 Ф, Санкт-Петербург, 197002, Россия

E-mail: [al\\_an\\_kon@mail.ru](mailto:al_an_kon@mail.ru)

<https://orcid.org/0009-0004-1943-5394>

**Ле Минь Хоанг** – специалист по направлению "Радиоэлектронные системы и комплексы" (2017), аспирант Государственного технического института им. Ле Куй Дона, Ханой, Вьетнам. Автор пяти научных публикаций. Сфера научных интересов – радиолокация; вторичная и третичная обработка радиолокационной информации.

Адрес: Государственный технический институт им. Ле Куй Дона, ул. Хоанг Куок Вьет, д. 236, район Бак Ты Лиен, Ханой, Вьетнам

E-mail: [lehoang.navy@gmail.com](mailto:lehoang.navy@gmail.com)

<https://orcid.org/0000-0001-8913-3296>

## References

1. Zeng H., Zhang H., Chen J., Yang W. UAV Target Detection Algorithm Using GNSS-Based Bistatic Radar. IGARSS 2019 – IEEE Intern. Geoscience and Remote Sensing Symp. Yokohama, Japan, 28 July – 02 Aug. 2019. IEEE, 2019, pp. 2167–2170. doi: 10.1109/IGARSS.2019.8898935
2. Makarenko S. I. *Protivodeistvie bespilotnim letatel'nykh apparatam* [Countermeasures Against Unmanned Aerial Vehicles]. SPb, Naukoemkie tekhnologii, 2020, 204 p. (In Russ.)
3. Khristenko A. V., Konovalenko M. O., Rovkin M., Khlusov V., Marchenko A. V., Sutulin A. A., Malyutin N. Magnitude and Spectrum of Electromagnetic Wave Scattered by Small Quadcopter in X-band. IEEE Trans. on Antennas and Propagation. 2018, vol. 66, no. 4, pp. 1977–1984. doi: 10.1109/TAP.2018.2800640
4. How to Counter the Use of Unmanned Aerial Vehicles for Terrorist Purposes. Available at: <https://www.tbforum.ru/blog/kak-protivodejstvovat-primeneniyu-bespilotnykh-letatel'nykh-apparatov-v-terroristicheskikh-celyah> (accessed 23.05.2023) (In Russ.)
5. Vorobyov E. N. Investigation of Distinctive Features for Recognition of Small UAVs in Passive Radar. Vestnik NovSU. Iss.: Engineering Sciences. 2019, no. 4 (116), pp. 72–77. doi: 10.34680/2076-8052.2019.4(116).72-77 (In Russ.)
6. Petrov I. D., Shkodyrev V. P., Sentsov A. A., Ivanov S. A. Algorithm for Recognition of Small Sized Aerial Objects Based on Analysis of Spectrums Obtained by Radar. T-Comm. 2022, vol. 16, no. 3, pp. 4–10. doi: 10.36724/2072-8735-2022-16-3-4-10 (In Russ.)
7. Dinevich L., Leshem Y. Algorithmic System for Identifying Bird Radio-Echo and Plotting Radar Ornitho-Logical Charts. The Ring. 2007, vol. 29, no. 1–2, pp. 3–39. doi: 10.2478/v10050-008-0040-z
8. Liu J., Xu Q. Y., Chen W. S. Classification of Bird and Drone Targets Based on Motion Characteristics and Random Forest Model Using Surveillance Radar Data. IEEE Access. 2021, vol. 9, pp. 160135–160144. doi: 10.1109/access.2021.3130231
9. Konovalov A. A. *Osnovy traektor'noy obrabotki ra-diolo-katsyonnoy informatsii* [Basic of the Radar Target Tracking]. Part 2. SPb, Izd-vo SPbGETU "LETI", 2014, 180 p. (In Russ.)
10. Dao L. V., Konovalov A. A., Le H. M. Analysis of Trajectory Features for Small UAVs Recognition. 2022 Conf. of Russ. Young Researchers in Electrical and Electronic Engineering (EIConRus). IEEE, 2022, pp. 1341–1345. doi: 10.1109/EIConRus54750.2022.9755753
11. Dao V. L. *Raspoznavaniye malorazmernukh voz-dusnukh RLS po traektor'nim priznakam s is-pol-zovanyem metodov masinnovo obucheniya* [Recognition of Small Air Radars by Trajectory Features Using Machine Learning Methods]. SPbNTORES: trudi ezegodnoi NTK. 2023, no. 1, pp. 58–61. (In Russ.)
12. Subbotin S. A. Construction of Decision Trees for the Case of Uninformative Features. Radioelektronika, informatika, upravleniya. 2019, no. 1 (48), pp. 122–131. doi: 10.15588/1607-3274-2019-1-12 (In Russ.)
13. Borodinov A. A., Myasnikov V. V. *Sravnheniye al-goritmov klassifikatsyy radarnukh izobrazheniy pri raslichnikh metodakh predobrabotka na primere baza MSTAR* [Comparison of Radar Image Classification Algorithms for Different Preprocessing Methods Using the MSTAR Database as an Example]. Proc. of the IV Intern. Conf. and Youth School "ITNT-2018". Samara: Novaya Tekhnika, 2018, pp. 586–594. (In Russ.)
14. Barbaresco F., Brooks D., Adnet C. Machine and Deep Learning for Drone Radar Recognition by Micro-Doppler and Kinematic criteria. 2020 IEEE Radar Conf. (RadarConf20). Florence, Italy, 21–25 Sept. 2020. IEEE, 2020, pp. 1–6. doi: 10.1109/RadarConf2043947.2020.9266371
15. Donskoy V. I. *Algoritmicheskie modeli obucheniya klassifikatsyy* [Algorithmic Models for Learning Classification]. Simferopol, DYAIPIY, 2014, 228 p. (In Russ.)
16. Chystyakov S. P. *Sluchaynie lesa: obzor* [Random Forests Overview]. Proc. of the Karelian Scientific Center of the Russian Academy of Sciences. 2013, no. 1, pp. 117–136. (In Russ.)
17. Dietterich T. G. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, And Randomization. Machine learning. 2000, vol. 40, no. 2, pp. 139–157. doi: 10.1023/A:1007607513941
18. Machine Learning Metrics: How to Measure the Performance of a Machine Learning Model. Available at: <https://www.altexsoft.com/blog/machine-learning-metrics/> (accessed 23.05.2023)

## Information about the authors

**Dao Van Luc**, Specialist in "Radioelectronic systems and complexes" (2016), Postgraduate student of Le Quy Don Technical University (Hanoi, Vietnam). The author of 5 scientific publications. Area of expertise: radiolocation; secondary and tertiary processing of radar information.

Address: Le Quy Don Technical University, 236, Hoang Quoc Viet St., Bac Tu Liem, Ha Noi, Viet Nam

E-mail: daolucvtl01@gmail.com

<https://orcid.org/0000-0001-8006-3076>

**Aleksandr A. Konovalov**, Cand. Sci. (Eng.) (2015), Senior Researcher of Research Institute "Prognoz" of Saint Petersburg State Electrotechnical University. The author more than 60 scientific publications. Area of expertise: secondary and tertiary processing of radar information; data fusion; multi-position radar; bistatic radio systems.

Address: Research Institute "Prognoz", 5 F, Professor Popov St., St Petersburg 197022, Russia

E-mail: al\_an\_kon@mail.ru

<https://orcid.org/0009-0004-1943-5394>

**Le Minh Hoang**, Specialist in "Radioelectronic Systems and Complexes" (2017), Postgraduate student of Le Quy Don Technical University (Hanoi, Vietnam). The author of 5 scientific publications. Area of expertise: radiolocation; secondary and tertiary processing of radar information.

Address: Le Quy Don Technical University, 236, Hoang Quoc Viet St., Bac Tu Liem, Ha Noi, Viet Nam

E-mail: lehoang.navy@gmail.com

<https://orcid.org/0000-0001-8913-3296>

---