

doi: 10.17586/2226-1494-2022-22-2-385-391

УДК 623.746.-519

Обнаружение поломки винта квадрокоптера методами машинного обучения

Иван Игоревич Кириленко¹✉, Екатерина Андреевна Косарева²,
 Александр Андреевич Николаев³, Артемий Михайлович Зенкин⁴,
 Яна Михайловна Селезнева⁵, Николай Анатольевич Николаев⁶

^{1,2,3,4,5,6} Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация

¹ Ivan009ki@gmail.com✉, <https://orcid.org/0000-0001-9416-8645>

² e.kosareva@itmo.ru, <https://orcid.org/0000-0002-5388-4597>

³ nikolaev7aleksandr@gmail.com, <https://orcid.org/0000-0001-6551-8896>

⁴ a.zenkin@itmo.ru, <https://orcid.org/0000-0002-8871-3835>

⁵ yanaselezneva97@mail.ru, <https://orcid.org/0000-0001-9534-7258>

⁶ nanikolaev@itmo.ru, <https://orcid.org/0000-0002-8835-5142>

Аннотация

Предмет исследования. Представлено исследование вариантов обнаружения поломки или дефекта винта беспилотной авиационной системы (квадрокоптера) с использованием методов машинного обучения. Выполнена оригинальная оценка точности известных алгоритмов с применением на практике получаемых данных с квадрокоптера в условиях его полета. **Метод.** Предложенный метод основан на классификации трех состояний винтов (исправные винты, один винт искусственно деформирован, один винт сломан) с использованием алгоритмов машинного обучения. Исходной информацией являются данные, получаемые с измерительной системы квадрокоптера в реальном времени: скорость, ускорение и угол поворота относительно трех осей. Для корректной работы представленного алгоритма выполнена предварительная обработка данных с разделением на временные интервалы и применением к полученным интервалам быстрого преобразования Фурье. На основе обработанных данных проведено обучение алгоритмов машинного обучения с использованием метода опорных векторов, алгоритма k -ближайших соседей, алгоритма дерева решений и многослойного перцептрона. **Основные результаты.** Выполнено сравнение полученных значений точности предложенных методов. Показано, что применение методов машинного обучения позволяют обнаруживать и классифицировать состояния винта с точностью до 96 %. Наилучший результат достигнут с использованием алгоритма дерева решений. **Практическое значение.** Результаты исследования могут иметь практическое значение для систем обнаружения дефектов и поломок винтов беспилотных летательных аппаратов в реальном времени. Получена возможность прогнозирования с высокой точностью износа винта, повышать стабильность и безопасность полета.

Ключевые слова

беспилотная авиационная система, квадрокоптер, машинное обучение, детектирование поломки винта, метод опорных векторов, дерево решений, k -ближайших соседей, многослойный перцептрон

Ссылка для цитирования: Кириленко И.И., Косарева Е.А., Николаев А.А., Зенкин А.М., Селезнева Я.М., Николаев Н.А. Обнаружение поломки винта квадрокоптера методами машинного обучения // Научно-технический вестник информационных технологий, механики и оптики. 2022. Т. 22, № 2. С. 385–391. doi: 10.17586/2226-1494-2022-22-2-385-391

Detection of quadcopter propeller failure by machine learning methods

Ivan I. Kirilenko¹✉, Ekaterina A. Kosareva², Aleksandr A. Nikolaev³,
 Artemii M. Zenkin⁴, Iana M. Selezneva⁵, Nikolay A. Nikolaev⁶

^{1,2,3,4,5,6} ITMO University, Saint Petersburg, 197101, Russian Federation

¹ Ivan009ki@gmail.com✉, <https://orcid.org/0000-0001-9416-8645>

² e.kosareva@itmo.ru, <https://orcid.org/0000-0002-5388-4597>

© Кириленко И.И., Косарева Е.А., Николаев А.А., Зенкин А.М., Селезнева Я.М., Николаев Н.А., 2022

³ nikolaev7aleksandr@gmail.com, <https://orcid.org/0000-0001-6551-8896>

⁴ a.zenkin@itmo.ru, <https://orcid.org/0000-0002-8871-3835>

⁵ yanaselezneva97@mail.ru, <https://orcid.org/0000-0001-9534-7258>

⁶ nanikolaev@itmo.ru, <https://orcid.org/0000-0002-8835-5142>

Abstract

The paper presents a study of options for detecting a failure or defect in the propeller of an unmanned aircraft system (quadcopter) using machine learning methods. An original accuracy evaluation of the known algorithms using in practice the data obtained from the quadcopter in its flight conditions is performed. The proposed method is based on the classification of three propeller states (serviceable propellers, one propeller artificially deformed, one propeller broken) using machine learning algorithms. The input information is the data obtained from the quadcopter measuring system in real time: speed, acceleration and rotation angle relative to three axes. For the correct work of the presented algorithm, data was preprocessed with division into time intervals and applying to the obtained intervals the fast Fourier transform. Based on the processed data, machine learning algorithms were trained using the reference vector method, k -nearest neighbor algorithm, decision tree algorithm, and multilayer perceptron. The obtained accuracy values of the proposed methods are compared. It is shown that the application of machine learning methods can detect and classify the propeller states with an accuracy of up to 96 %. The best result is achieved using the decision tree algorithm. The results of the study can be of practical importance for real-time systems to detect propeller defect and breakage for unmanned aerial vehicles. It is possible to predict with high accuracy the propeller wear; it is possible to improve the stability and safety of the flight.

Keywords

UAS, quadcopter, machine learning, propeller failure detection, support vector method, decision tree, k -nearest neighbors, multilayer perceptron

For citation: Kirilenko I.I., Kosareva E.A., Nikolaev A.A., Zenkin A.M., Selezneva I.M., Nikolaev N.A. Detection of quadcopter propeller failure by machine learning methods. *Scientific and Technical Journal of Information Technologies, Mechanics and Optics*, 2022, vol. 22, no. 2, pp. 385–391 (in Russian). doi: 10.17586/2226-1494-2022-22-2-385-391

Введение

Беспилотные авиационные системы (БАС) все чаще применяются в различных областях, например, для мониторинга местности [1], детектирования природных пожаров [2] или автоматической доставки мелкогабаритных грузов [3]. Квадрокоптеры — одни из самых распространенных БАС, так как имеют малые габариты и массу, являются достаточно маневренными, имеют простую конструкцию и математическую модель, что упрощает работу с ними.

Основная часть конструкции квадрокоптера — крестовидная рама с малогабаритными бесколлекторными двигателями на ее концах, в центре которой располагается необходимая аппаратура: микроконтроллер, датчики, питающий элемент и полезная нагрузка. Вращение двигателей выбрано таким образом, чтобы их вращающий момент был максимально скомпенсирован. При этом одна пара двигателей вращается против часовой стрелки, а вторая — по часовой, что предполагает деление на переднюю и заднюю части, относительно которых ориентировано движение БАС.

Распространенной причиной нестабильного поведения или падения квадрокоптера является поломка винта. Такая поломка, как правило, происходит после столкновения с другими объектами, при неудачной посадке или попадании стороннего предмета непосредственно в винт. К сожалению, не всегда удается заметить неисправность и своевременно заменить винт. Неисправность винта может привести к неустойчивому поведению квадрокоптера в воздухе и невозможности решения полетной задачи, а также к падению БАС и его механическому разрушению. В связи с этим в настоящее время ведутся активные работы, связанные с обеспечением безопасности БАС. Один из вариантов обеспечения безопасности системы — синтез ал-

горитмов управления БАС в аварийных ситуациях, связанных с неисправностью двигателей [4]. Также важная задача контроля безопасности — состояние винтов, которые возможно контролировать с помощью визуального осмотра или с использованием оптических измерительных систем [5].

В настоящей работе выполнено исследование, которое направлено на решение задачи поиска дефектов и поломок винта во время полета. Рассмотрена задача определения повреждения винта по косвенным признакам (по изменению поведения квадрокоптера в воздухе). Одним из таких признаков может служить вибрационная активность БАС, так как поврежденный винт вызывает вибрации [6]. Данную задачу сложно решить аналитически, как показано в работах [7, 8]. Необходимо иметь точную математическую модель самого квадрокоптера и действующих на него внешних воздействий, поэтому в последнее время более релевантно использовать методы машинного обучения [9].

В настоящей работе предложено развитие методов, рассмотренных в работах [6, 10], где выполнен сбор данных с БАС и их анализ на основе метода опорных векторов. Данный метод один из самых простых, но может обеспечить достаточную точность в отличие от аналогов [11].

Также для подобных задач в подходах, предложенных в [12–14], используют нейронные сети с высокими структурной и вычислительной сложностями. Рассматриваемые в работе методы значительно проще, что позволяет быстрее обучать алгоритмы и прогнозировать поломку винта в реальном времени.

В результате работы получен оригинальный набор данных (далее датасет) с квадрокоптера Tello при различных состояниях винтов. Выполнен анализ состояния винта при помощи разных методов машинного обучения, что позволило с большой точностью сравнить

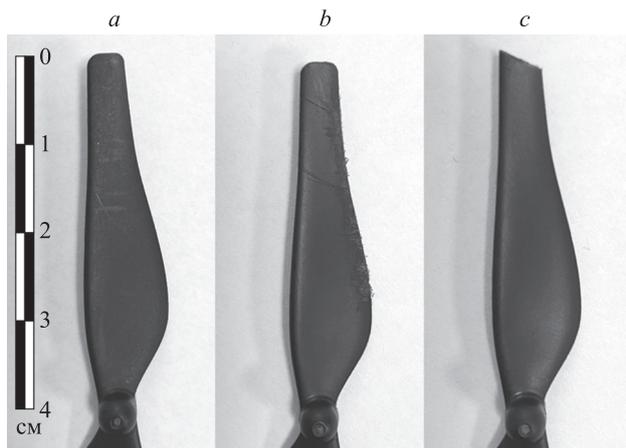


Рис. 1. Три вида исследуемых состояний винтов: полностью целый винт (a); винт с дефектами на краях лопасти (b); винт с обломанной лопастью (c)

Fig. 1. Three types of propeller states under study: a completely intact propeller (a), a propeller with defects on the edges of the blade (b), a propeller with a broken blade (c)

эффективность обучения и работы разных алгоритмов для поставленной задачи.

Объект исследования и сбор данных

В качестве объекта исследования выбран популярный квадрокоптер Tello, выпускаемый совместно компаниями Ryze, DJI и Intel. Выбранный БАС имеет возможность измерения ускорений, скоростей и углов наклона по всем осям. Квадрокоптер осуществлял полет при управлении с пульта в воздухе. Данные для датасета снимались в три этапа. На первом этапе со стандартным исправным набором винтов, на втором — один винт был незначительно поврежден, а на третьем — лопасть винта имела значительное механическое повреждение (рис. 1). На каждом этапе выполнены измерения скорости, ускорения и углов относительно трех осей.

Предварительная обработка данных

Большинство алгоритмов машинного обучения принимают на вход конечный вектор параметров. В связи с этим выполняется предварительная обработка непрерывного потока данных с датчиков квадрокоптера и выделяется конечный вектор характеристик, т. е. массив параметров, который подается на вход анализируемых алгоритмов. В начале обработки данные были разделены на интервалы с шагом в 0,5 с между началами

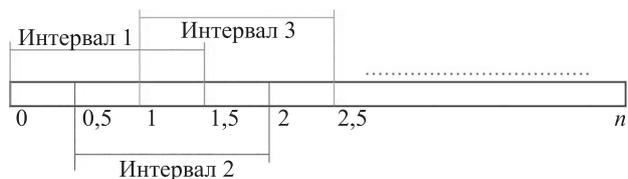


Рис. 2. Алгоритм выделения интервалов длиной 1,5 с

Fig. 2. Algorithm for extracting 1.5 s intervals

интервалов, как показано на рис. 2 (интервалы длиной 1,5 с), где n — время проведения эксперимента в секундах. При этом для исследования эффективности алгоритмов выбраны интервалы длиной в 0,5, 1, 1,5, 2, 2,5 и 3 с.

Известно, что дефекты винтов приводят к изменению вибросостояния БАС, которое можно обнаружить, применив быстрое преобразование Фурье, как показано в работе [6]. В настоящей работе решения, основанные на быстром преобразовании Фурье [6, 10], улучшены с помощью повышения точности данного метода. Для этого к полученным данным применен не простейший алгоритм опорных векторов, а его аналоги: алгоритм k -ближайших соседей, алгоритм дерева решений и многослойный персептрон. При этом на вход алгоритмов подается конечный вектор характеристик колебаний, поэтому для каждой преобразованной величины были взяты максимальные, минимальные, средние, медианные значения и среднеквадратические отклонения.

Алгоритмы машинного обучения

С точки зрения машинного обучения поставленная задача сводится к классификации трех состояний винта. Из множества алгоритмов классификации [15, 16] для решения данной задачи выбран метод опорных векторов [17, 18], заключающийся в нахождении гиперповерхности в гиперпространстве характеристик, которая разделяет объекты на классы. Например, если входными величинами для алгоритма являются две характеристики объекта, тогда можно найти кривую (гиперплоскость) в двумерном пространстве этих характеристик, чтобы объекты разных классов находились по разные стороны этой кривой. Форма поверхности задается математической функцией. На рис. 3 приведен график сравнения точности алгоритма в зависимости от заданной математической функции и длины исследуемого интервала для собранного датасета. Заметим, что лучше всего справился алгоритм на основе функции Гаусса, поэтому в дальнейшем выбран именно он.

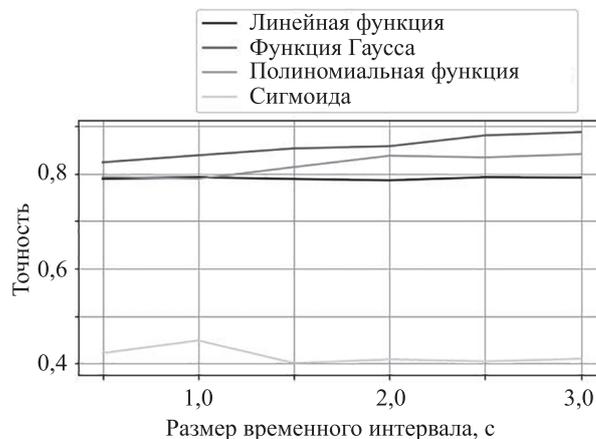


Рис. 3. График сравнения точности метода опорных векторов с разными формами поверхности

Fig. 3. Graph comparing the accuracy of the support vector method with different surface shapes

Метод опорных векторов используют из-за его простоты и скорости, однако для данной задачи он может быть не так эффективен, как его аналоги. Проверим данную гипотезу, сравнив результат выбранного алгоритма с алгоритмом k -ближайших соседей, алгоритмом дерева решений и простейшей нейронной сетью. Рассмотрим каждую модель более подробно.

Алгоритм k -ближайших соседей — алгоритм, основанный на том, что объекты одного класса должны располагаться в гиперпространстве характеристик ближе друг к другу, чем к объектам другого класса [19]. Иначе говоря, при классификации нового объекта идет поиск k -ближайших соседей (уже классифицированных объектов). Найденному новому объекту присваивается класс большинства представителей одного класса из этих k объектов. Значение k подбирается эмпирическим путем, так как при слишком маленьком или большом значениях точность алгоритма будет уменьшаться [20]. Особенность данного алгоритма — практически нулевое время обучения, так как он не подбирает коэффициенты, а имеет известную базу объектов из датасета. Заметим, что на больших датасетах скорость классификации падает, так как необходимо считать расстояние до каждого объекта [21]. В данной работе эмпирически выбран $k=5$, а за расстояние для нахождения соседних объектов было взято расстояние Минковского $D(\mathbf{X}, \mathbf{Y})$, которое для двух векторов \mathbf{X} и \mathbf{Y} размера n рассчитывается следующим образом:

$$\mathbf{X} = (x_1, x_2, \dots, x_n), \mathbf{Y} = (y_1, y_2, \dots, y_n),$$

$$D(\mathbf{X}, \mathbf{Y}) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{1/p},$$

где x, y — характеристики конечных векторов; p — порядок расстояния Минковского.

Алгоритм дерева решений [22] основан на построении графа в виде бинарного дерева, в котором каждый узел является условием по одной из характеристик, которое переводит алгоритм вниз по дереву, у листьев которого назначается класс объекта. На рис. 4 представлена визуализация первых узлов дерева, по которой видно, что при входе алгоритм сравнивает параметр `yaw_mean` (среднее значение для угла рысканья) и отправляет объект в зависимости от величины этого параметра дальше по дереву. Данный алгоритм простой

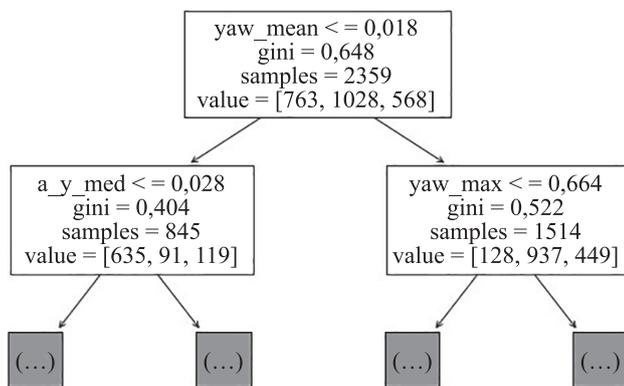


Рис. 4. Первые узлы дерева решений
Fig. 4. The first nodes of the decision tree

для построения и быстрый в процессе классификации новых объектов [23].

Последний рассматриваемый алгоритм — многослойный перцептрон — модель простейшей нейронной сети. Обычный перцептрон состоит из трех связанных между собой слоев нейронов, в первый слой записывается вектор объекта, а на последнем слое предсказываются вероятности отнесения объекта к классу. Средний слой называется скрытым, в нем количество нейронов может быть любое, в каждом из них задается функция активации с весовым коэффициентом. В настоящей работе использована наиболее популярная в настоящее время функция активации — сигмоида. Многослойный перцептрон отличается наличием нескольких скрытых слоев, которые связаны последовательно. В процессе обучения в каждом нейроне, который участвовал в правильном определении объекта, коэффициент функции увеличивался, а также увеличивалась вероятная активация следующих связанных нейронов. Если нейрон участвовал в ошибочной классификации, то коэффициент, наоборот, уменьшался.

Главный недостаток нейронной сети по сравнению с предыдущими алгоритмами — время обучения, так как приходится менять коэффициенты большого количества функций. Тем не менее процесс классификации просчитывается достаточно быстро, а скорость процесса обучения и точность зависят от количества скрытых слоев и нейронов в них [24]. На рис. 5 изображена схема многослойного перцептрона с тремя скрытыми слоями по 40 нейронов в каждом, использованного в работе.

Результаты и анализ

Для детектирования поломки винта на собранном датасете использованы четыре метода машинного обучения: метод опорных векторов с функцией Гаусса в качестве ядра, алгоритм k -ближайших соседей, дерево решений и многослойный перцептрон. На рис. 6 видна зависимость точности определения состояния винта от алгоритма обучения и от длины исследуемого временного интервала. Видно, что точность всех алгоритмов растет при увеличении исследуемого интервала време-

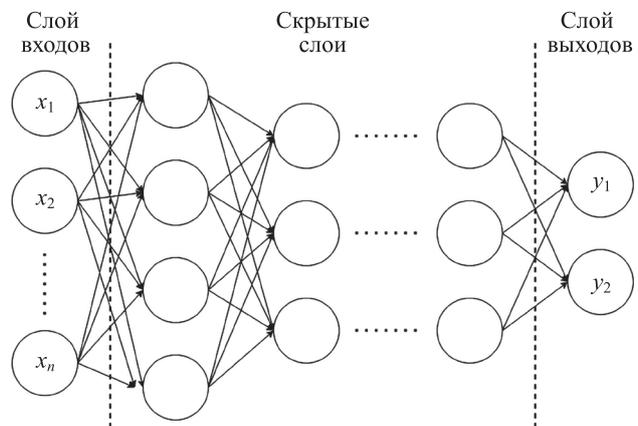


Рис. 5. Схема многослойного перцептрона
Fig. 5. Schematic of a multilayer perceptron

Таблица. Показатели точности алгоритмов машинного обучения, %
Table. Accuracy figures of machine learning algorithms

Алгоритм машинного обучения	Длина исследуемого интервала, с					
	0,5	1,0	1,5	2,0	2,5	3,0
Метод опорных векторов	82,4	83,9	85,4	85,8	88,1	88,8
k -ближайших соседей	83,0	85,0	87,9	90,1	92,1	93,7
Дерево решений	89,3	91,2	92,7	93,5	94,7	95,9
Многослойный перцептрон	84,5	88,7	90,5	92,0	93,5	95,3

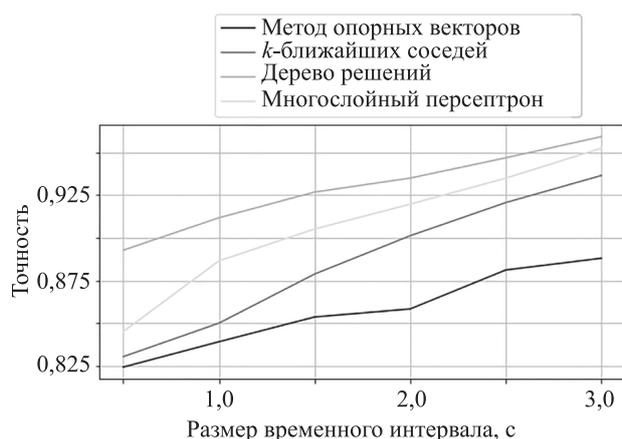


Рис. 6. График сравнения точности различных алгоритмов машинного обучения

Fig. 6. Graph comparing the accuracy of different machine learning algorithms

ни, но лучше всего при всех значениях справляется с задачей метод дерева решений.

В результате проведенных исследований собран оригинальный датасет данных с квадрокоптера Tello во время полета с целым, поврежденным и сломанным винтами. На основе полученного датасета исследованы четыре метода машинного обучения. Из полученных результатов можно сделать вывод о том, что часто используемый для таких задач метод опорных векторов, является хоть и простым, но не самым точным решением, так как остальные три алгоритма справились с поставленной задачей лучше (таблица). Отметим метод

дерева решений, точность которого при исследуемом интервале не менее 1 с выше 90 %, а при интервале в 3 с — 96 %.

Таким образом предложенный метод анализа состояния винтов состоит из следующих шагов: сбор данных с измерительной системы БАС, предобработка исходных данных с выделением временных интервалов; быстрое преобразование Фурье к предобработанным данным для выявления паразитных колебаний, применение алгоритма дерева решений для классификации состояния винта с наибольшей точностью.

Заключение

В работе представлен метод обработки и анализа получаемых с квадрокоптера данных для детектирования и классификации поломки винта, который является актуальным для диагностики технического состояния винтомоторных установок. Выбор метода обоснован его алгоритмической и вычислительной простотой относительно сложных нейронных сетей. Выполнено сравнение с одним из самых популярных из-за своей простоты методом опорных векторов. Из полученных результатов обучения алгоритмов можно сделать вывод, что наиболее удачным для поставленной задачи является алгоритм дерева решений. В дальнейшем планируется развитие рассмотренного метода с целью увеличения универсальности и точности при помощи рассмотрения других алгоритмов машинного обучения. Исследования содержат практический опыт и могут быть полезны для детектирования поломок беспилотных авиационных систем в режиме реального времени.

Литература

1. Зенкин А.М., Осинкин Е.А., Пачковский К.А. Детектирование границ пожара по камере на вычислительных мощностях беспилотного летательного аппарата // Альманах научных работ молодых ученых Университета ИТМО. Т 2. СПб., 2019. С. 81–83.
2. Цветков В.Я., Ознамец В.В. Мониторинг транспортной инфраструктуры с использованием интеллектуальных БПЛА // Автоматика, связь, информатика. 2020. № 8. С. 18–21.
3. Агеева Е.Г., Евсеев О.В. Перспективы применения БПЛА как средства доставки грузов // Современные проблемы управления внешнеэкономической деятельностью: Материалы международной научной конференции. М.: Всероссийская академия внешней торговли Министерства экономического развития РФ, 2018. С. 161–167.
4. Морозов Ю.В. Экстренное управление квадрокоптером при отказе двух симметричных винтов // Автоматика и телемеханика. 2018. № 3. С. 92–110.

References

1. Zenkin A.M., Osinkin E.A., Pachkovskii K.A. Detection of the fire boundaries by camera using the computing power of an unmanned aerial vehicle. *Almanac of Scientific Works of Young Scientists at ITMO University*. Vol. 2. St. Petersburg, 2019, pp. 81–83. (in Russian)
2. Tsvetkov V., Oznamets V. Monitoring transport infrastructure using intelligent UAVS. *Automation, Communications, Informatics*, 2020, no. 8, pp. 18–21. (in Russian)
3. Ageeva E.G., Evseev O.V. Prospects for the use of UAVs as a means of cargo delivery. *Modern problems of foreign economic activity management: Materials of the International Scientific Conference*. Moscow, Russian Foreign Trade Academy Ministry of economic development of the Russian Federation, 2018, pp. 161–167. (in Russian)
4. Morozov Y.V. Emergency control of a quadcopter in case of failure of two symmetric propellers. *Automation and Remote Control*, 2018, vol. 79, no. 3, pp. 463–478. <https://doi.org/10.1134/S0005117918030062>

5. Зотин Н.А. Разработка оптических средств контроля работы воздушных винтов беспилотных летательных аппаратов // Актуальные проблемы и перспективы развития гражданской авиации: сборник трудов IX Международной научно-практической конференции. Иркутск: Иркутский филиал МГТУ ГА, 2020. С. 237–242.
6. Bondyra A., Gasior P., Gardecki S., Kasinski A. Fault diagnosis and condition monitoring of UAV rotor using signal processing // Proc. of the 21st Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA), 2017. P. 233–238. <https://doi.org/10.23919/SPA.2017.8166870>
7. Rago C., Prasanth R., Mehra R.K., Fortenbaugh R. Failure detection and identification and fault tolerant control using the IMM-KF with applications to the Eagle-Eye UAV // Proc. of the 37th IEEE Conference on Decision and Control (CDC). V. 4. 1998. P. 4208–4213. <https://doi.org/10.1109/CDC.1998.761963>
8. Abbaspour A., Aboutalebi P., Yen K.K., Sargolzaei A. Neural adaptive observer-based sensor and actuator fault detection in nonlinear systems: Application in UAV // ISA Transactions, 2017. V. 67. P. 317–329. <https://doi.org/10.1016/j.isatra.2016.11.005>
9. Abdalla A.S., Marojevic V. Machine learning-assisted UAV operations with the UTM: Requirements, challenges, and solutions // Proc. of the 92nd IEEE Vehicular Technology Conference (VTC), 2020. P. 9348605. <https://doi.org/10.1109/VTC2020-Fall49728.2020.9348605>
10. Phanindra B.R., Pralhad R.N., Raj A.A. B. Machine learning based classification of ducted and non-ducted propeller type quadcopter // Proc. of the 6th International Conference on Advanced Computing and Communication Systems (ICACCS), 2020. P. 1296–1301. <https://doi.org/10.1109/ICACCS48705.2020.9074307>
11. Baskaya E., Bronz M., Delahaye D. Fault detection & diagnosis for small UAVs via machine learning // Proc. of the 36th IEEE/AIAA Digital Avionics Systems Conference (DASC), 2017. P. 8102037. <https://doi.org/10.1109/DASC.2017.8102037>
12. Yang P., Wen C., Geng H., Liu P. Intelligent fault diagnosis method for blade damage of quad-rotor UAV based on stacked pruning sparse denoising autoencoder and convolutional neural network // Machines, 2021. V. 9. N 12. P. 360. <https://doi.org/10.3390/machines9120360>
13. Chen X.M., Wu C.-X., Wu Y., Xiong N.-X., Han R., Ju B.-B., Zhang S. Design and analysis for early warning of rotor UAV based on data-driven DBN // Electronics, 2019. V. 8. N 11. P. 1350. <https://doi.org/10.3390/electronics8111350>
14. Парфентьев К.В., Жильцов А.И. Разработка интеллектуальной системы оценки состояния беспилотного летательного аппарата на основе нейросетевых технологий // Радиостроение. 2018. № 2. С. 13–28. <https://doi.org/10.24108/rdeng.0218.0000134>
15. Kotsiantis S.B. Supervised machine learning: A review of classification techniques // Frontiers in Artificial Intelligence and Applications, 2007. V. 160. P. 3–24.
16. Вьюгин В. Математические основы машинного обучения и прогнозирования. М.: Изд-во МЦНМО, 2017. 383 с.
17. Toledo-Pérez D.C., Rodríguez-Reséndiz J., Gómez-Loenzo R.A., Jauregui-Correa J.C. Support vector machine-based EMG signal classification techniques: A review // Applied Sciences, 2019. V. 9. N 20. P. 4402. <https://doi.org/10.3390/app9204402>
18. Zhou X., Wu Y., Yang B. Signal classification method based on support vector machine and high-order cumulants // Wireless Sensors Network, 2010. V. 2. N 1. P. 48–52. <https://doi.org/10.4236/wsn.2010.21007>
19. Dhanabal S., Chandramathi S. A review of various k-nearest neighbor query processing techniques // International Journal of Computer Applications, 2011. V. 31. N 7. P. 14–22. <https://doi.org/10.5120/3836-5332>
20. Zhang S., Li X., Zong M., Zhu X., Cheng D. Learning k for kNN classification // ACM Transactions on Intelligent Systems and Technology, 2017. V. 8. N 3. P. 43. <https://doi.org/10.1145/2990508>
21. Guo G., Wang H., Bell D., Bi Y., Greer K. KNN model-based approach in classification // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2003. V. 2888. P. 986–996. https://doi.org/10.1007/978-3-540-39964-3_62
22. Myles A.J., Feudale R.N., Liu Y., Woody N.A., Brown S.D. An introduction to decision tree modeling // Journal of Chemometrics, 2004. V. 18. N 6. P. 275–285. <https://doi.org/10.1002/cem.873>
23. Song Y.-Y., Lu Y. Decision tree methods: applications for classification and prediction // Shanghai Archives of Psychiatry, 2004. V. 18. N 6. P. 275–285. <https://doi.org/10.1002/cem.873>
5. Zotin N.A. Development of the optical means for monitoring the operation of propellers of unmanned aerial vehicles. *Actual problems and prospects for the civil aviation development: Proceedings of the IX International Scientific and Practical Conference*. Irkutsk, Irkutsk Branch of Moscow State Technical University of Civil Aviation, 2020, pp. 237–242. (in Russian)
6. Bondyra A., Gasior P., Gardecki S., Kasinski A. Fault diagnosis and condition monitoring of UAV rotor using signal processing. *Proc. of the 21st Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, 2017, pp. 233–238. <https://doi.org/10.23919/SPA.2017.8166870>
7. Rago C., Prasanth R., Mehra R.K., Fortenbaugh R. Failure detection and identification and fault tolerant control using the IMM-KF with applications to the Eagle-Eye UAV. *Proc. of the 37th IEEE Conference on Decision and Control (CDC)*, Vol. 4, 1998, pp. 4208–4213. <https://doi.org/10.1109/CDC.1998.761963>
8. Abbaspour A., Aboutalebi P., Yen K.K., Sargolzaei A. Neural adaptive observer-based sensor and actuator fault detection in nonlinear systems: Application in UAV. *ISA Transactions*, 2017, vol. 67, pp. 317–329. <https://doi.org/10.1016/j.isatra.2016.11.005>
9. Abdalla A.S., Marojevic V. Machine learning-assisted UAV operations with the UTM: Requirements, challenges, and solutions. *Proc. of the 92nd IEEE Vehicular Technology Conference (VTC)*, 2020, pp. 9348605. <https://doi.org/10.1109/VTC2020-Fall49728.2020.9348605>
10. Phanindra B.R., Pralhad R.N., Raj A.A. B. Machine learning based classification of ducted and non-ducted propeller type quadcopter. *Proc. of the 6th International Conference on Advanced Computing and Communication Systems (ICACCS)*, 2020, pp. 1296–1301. <https://doi.org/10.1109/ICACCS48705.2020.9074307>
11. Baskaya E., Bronz M., Delahaye D. Fault detection & diagnosis for small UAVs via machine learning. *Proc. of the 36th IEEE/AIAA Digital Avionics Systems Conference (DASC)*, 2017, pp. 8102037. <https://doi.org/10.1109/DASC.2017.8102037>
12. Yang P., Wen C., Geng H., Liu P. Intelligent fault diagnosis method for blade damage of quad-rotor UAV based on stacked pruning sparse denoising autoencoder and convolutional neural network. *Machines*, 2021, vol. 9, no. 12, pp. 360. <https://doi.org/10.3390/machines9120360>
13. Chen X.M., Wu C.-X., Wu Y., Xiong N.-X., Han R., Ju B.-B., Zhang S. Design and analysis for early warning of rotor UAV based on data-driven DBN. *Electronics*, 2019, vol. 8, no. 11, pp. 1350. <https://doi.org/10.3390/electronics8111350>
14. Parfentyev K.V., Zhiltsov A.I. Intelligent system development for assessing the unmanned aerial vehicle state based on neural network technologies. *Radio Engineering*, 2018, no. 2, pp. 13–28. (in Russian). <https://doi.org/10.24108/rdeng.0218.0000134>
15. Kotsiantis S.B. Supervised machine learning: A review of classification techniques. *Frontiers in Artificial Intelligence and Applications*, 2007, vol. 160, pp. 3–24.
16. Viugin V. *Mathematical Basics of Machine Learning and Forecasting*. Moscow, MCCME Publ., 2017, 383 p. (in Russian)
17. Toledo-Pérez D.C., Rodríguez-Reséndiz J., Gómez-Loenzo R.A., Jauregui-Correa J.C. Support vector machine-based EMG signal classification techniques: A review. *Applied Sciences*, 2019, vol. 9, no. 20, pp. 4402. <https://doi.org/10.3390/app9204402>
18. Zhou X., Wu Y., Yang B. Signal classification method based on support vector machine and high-order cumulants. *Wireless Sensors Network*, 2010, vol. 2, no. 1, pp. 48–52. <https://doi.org/10.4236/wsn.2010.21007>
19. Dhanabal S., Chandramathi S. A review of various k-nearest neighbor query processing techniques. *International Journal of Computer Applications*, 2011, vol. 31, no. 7, pp. 14–22. <https://doi.org/10.5120/3836-5332>
20. Zhang S., Li X., Zong M., Zhu X., Cheng D. Learning k for kNN classification. *ACM Transactions on Intelligent Systems and Technology*, 2017, vol. 8, no. 3, pp. 43. <https://doi.org/10.1145/2990508>
21. Guo G., Wang H., Bell D., Bi Y., Greer K. KNN model-based approach in classification. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2003, vol. 2888, pp. 986–996. https://doi.org/10.1007/978-3-540-39964-3_62
22. Myles A.J., Feudale R.N., Liu Y., Woody N.A., Brown S.D. An introduction to decision tree modeling. *Journal of Chemometrics*, 2004, vol. 18, no. 6, pp. 275–285. <https://doi.org/10.1002/cem.873>
23. Song Y.-Y., Lu Y. Decision tree methods: applications for classification and prediction. *Shanghai Archives of Psychiatry*, 2004, vol. 18, no. 6, pp. 275–285. <https://doi.org/10.1002/cem.873>

2015. V. 27. N 2. P. 130. <https://doi.org/10.11919/j.issn.1002-0829.215044>
24. Zanyat E.A. Support vector machines (SVMs) versus multilayer perception (MLP) in data classification // *Egyptian Informatics Journal*. 2012. V. 13. N 3. P. 177–183. <https://doi.org/10.1016/j.eij.2012.08.002>
23. Song Y.-Y., Lu Y. Decision tree methods: applications for classification and prediction. *Shanghai Archives of Psychiatry*, 2015, vol. 27, no. 2, pp. 130. <https://doi.org/10.11919/j.issn.1002-0829.215044>
24. Zanyat E.A. Support vector machines (SVMs) versus multilayer perception (MLP) in data classification. *Egyptian Informatics Journal*, 2012, vol. 13, no. 3, pp. 177–183. <https://doi.org/10.1016/j.eij.2012.08.002>

Авторы

Кириленко Иван Игоревич — техник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-9416-8645>, Ivan009ki@gmail.com

Косарева Екатерина Андреевна — техник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0002-5388-4597>, e.kosareva@itmo.ru

Николаев Александр Андреевич — техник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-6551-8896>, nikolaev7aleksandr@gmail.com

Зенкин Артемий Михайлович — младший научный сотрудник, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 6506189455](https://orcid.org/0000-0002-8871-3835), <https://orcid.org/0000-0002-8871-3835>, a.zenkin@itmo.ru

Селезнева Яна Михайловна — аспирант, инженер, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, <https://orcid.org/0000-0001-9534-7258>, yanaselezneva97@mail.ru

Николаев Николай Анатольевич — кандидат технических наук, доцент, доцент, Университет ИТМО, Санкт-Петербург, 197101, Российская Федерация, [sc 13105019100](https://orcid.org/0000-0002-8835-5142), <https://orcid.org/0000-0002-8835-5142>, nanikolaev@itmo.ru

Authors

Ivan I. Kirilenko — Technician, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-9416-8645>, Ivan009ki@gmail.com

Ekaterina A. Kosareva — Technician, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0002-5388-4597>, e.kosareva@itmo.ru

Aleksandr A. Nikolaev — Technician, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-6551-8896>, nikolaev7aleksandr@gmail.com

Artemii M. Zenkin — Junior Researcher, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 6506189455](https://orcid.org/0000-0002-8871-3835), <https://orcid.org/0000-0002-8871-3835>, a.zenkin@itmo.ru

Iana M. Selezneva — PhD student, Engineer, ITMO University, Saint Petersburg, 197101, Russian Federation, <https://orcid.org/0000-0001-9534-7258>, yanaselezneva97@mail.ru

Nikolay A. Nikolaev — PhD, Associate Professor, ITMO University, Saint Petersburg, 197101, Russian Federation, [sc 13105019100](https://orcid.org/0000-0002-8835-5142), <https://orcid.org/0000-0002-8835-5142>, nanikolaev@itmo.ru

Статья поступила в редакцию 31.01.2022
Одобрена после рецензирования 04.03.2022
Принята к печати 29.03.2022

Received 31.01.2022
Approved after reviewing 04.03.2022
Accepted 29.03.2022



Работа доступна по лицензии
Creative Commons
«Attribution-NonCommercial»