

УДК: 621.3797

DOI: 10.53816/23061456_2022_9–10_43

**МЕТОДИКА КЛАССИФИКАЦИИ СОСТОЯНИЯ КОСМИЧЕСКОГО ОБЪЕКТА
ПО РЕЗУЛЬТАТАМ ОПТИЧЕСКИХ ИЗМЕРЕНИЙ
С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ**

**METHOD OF SPACE OBJECT STATE CLASSIFICATION BASED
ON OPTICAL MEASUREMENTS USING MACHINE LEARNING METHODS**

Канд. техн. наук А.Н. Нестечук, канд. техн. наук К.А. Крупский, канд. воен. наук С.Г. Хлебников

Ph.D. A.N. Nestechuk, Ph.D. K.A. Krupsky, Ph.D. S.G. Khlebnikov

Военно-космическая академия им. А.Ф. Можайского

Классификация состояния космического объекта по результатам оптических измерений является задачей наблюдения и контроля состояния космических объектов. В статье описываются распространенные алгоритмы классификации, разработанная методика классификации и результаты ее апробации. Исходными данными для классификации космических объектов являлись смоделированные данные измерений блеска, полученные с помощью программного модуля оценивания некоординатной информации о космических объектах наземными средствами системы контроля космического пространства.

Целью статьи является обзор методов классификации состояния космического объекта, сравнение методов решения задачи классификации, а также выбор оптимальных алгоритмов для разработанной методики.

Ключевые слова: алгоритм, анализ данных, классификация, космический объект, машинное обучение, оптические измерения.

The classification of the state of a space object based on the results of optical measurements is the task of observing and controlling the state of space objects. The article describes common classification algorithms, the developed classification technique and the results of its testing. The initial data for the classification of space objects were simulated brightness measurement data obtained using a software module for estimating non-coordinate information about space objects by ground-based means of a space monitoring system.

The purpose of the article is to review the methods for classifying the state of a space object, to compare methods for solving the classification problem, and to select the optimal algorithms for the developed methodology.

Keywords: algorithm, data analysis, classification, space object, machine learning, optical measurements.

Введение

Непрерывные изменения, происходящие в околоземном космическом пространстве, связанные с ростом числа космических объектов (КО), при-

водят к возрастанию значимости своевременной идентификации их состояния за счет автоматического наблюдения и контроля за КО, выполняемых информационной системой — системой мониторинга околоземного космического пространства.

Система мониторинга околоземного космического пространства включает радиотехнические, радиолокационные и оптические средства. В случае отсутствия телеметрической информации основным источником по объему и качеству получаемой информации является оптико-электронный комплекс, в задачи которого входит автоматическое обнаружение неизвестных КО, получение и накопление по этим объектам координатных и некоординатных измерений [1]. При этом наиболее информативными данными для определения динамических, габаритных и отражательных характеристик КО являются данные наблюдений оптико-электронными средствами (ОЭС), а признаком отнесения КО к управляемому КО — космическому аппарату является его стабилизированное положение во время орбитального движения.

Классификация состояния КО (управляемого или неуправляемого) возможна в результате интеллектуального анализа некоординатной измерительной информации, а именно фотометрических характеристик (блеска) КО [2]. В настоящее время такой анализ проводится методом экспертных оценок и требует накопления достаточного объема однородных данных, а в условиях постоянного роста числа КО сложность задачи идентификации состояния КО за определенное время возрастает многократно. Одним из способов решения указанной проблемы является применение технологий искусственного интеллекта, основанных на моделях эвристических алгоритмов распознавания.

Основной целью процесса распознавания технического состояния военно-технических систем является построение эффективных программно-алгоритмических средств для отнесения формализованных описаний ситуаций и технических состояний к соответствующим классам. В основе этого процесса лежит получение некоторой агрегированной оценки ситуации из ее описания, построенного на основе заданного набора признаков.

Постановка задачи

Задача классификации [3] формулируется следующим образом.

Дано.

M — множество космических объектов $\{m_i\}$, на котором имеется разбиение на конечное число

подмножеств (классов) Y_k , $M = \bigcup_{k=1}^2 Y_k$, где k — номер класса. Разбиение M определено не полностью. Задана лишь некоторая обучающая информация I_0 о классах Y_k .

Космические объекты задаются значениями некоторых параметров их блеска x_j , где $j=1, N$ (этот набор всегда один и тот же для всех КО).

Совокупность значений параметров блеска КО, полученных по результатам оптических измерений x_j , определяет описание состояния каждого КО:

$$I(m) = \{x_1, x_2, \dots, x_N\}.$$

Информация о вхождении некоторого КО m в какой-либо класс представляется в виде информационного вектора $I(m) = \{I_1(m), \dots, I_k(m)\}$, где $I_k(m)$ несет информацию о принадлежности КО m к классу Y_k

$$I_k(m) = \begin{cases} 1, & m \in Y_k; \\ 0, & m \notin Y_k, \end{cases}$$

Найти.

Оптимальный классификатор состояния КО по результатам оптических измерений S^* , позволяющий с максимальной точностью отнести КО к одному из классов Y_k , применяя описание $I(m)$ состояния КО и обучающую информацию о классах КО $I_0(Y_1, Y_2)$

$$\tilde{N}^* = \arg \max_{m \in Y_k} P_k[(C(I_0(Y_1, Y_2), I(m))], \quad (1)$$

где P_k — значение предиката принадлежности m к классу Y_k .

При следующих ограничениях и допущениях:

1) модель космического объекта, состоящая из n геометрических тел, каждое из которых характеризуется положением в пространстве и углами поворотов вокруг осей системы координат, связанной с центром масс объекта [4];

2) выделяются два вида состояния КО: управляемый и неуправляемый. В связи с чем все состояния КО делятся на два класса: класс 1, характеризующийся тем, что наблюдаемый КО стабилизирован и остаётся управляемым, и класс 2, характеризующийся тем, что наблюдаемый КО неуправляемый, без стабилизации (вращается по какой-либо оси) [5].

Схема методики классификации состояния космического объекта по результатам оптических измерений с использованием методов машинного обучения

Решение задачи классификации состояния КО можно разделить на четыре последовательных этапа: получение данных, предварительная обработка и анализ данных, построение и обучение классификатора, оценка качества классификации.

1 этап. Получение данных для построения модели машинного обучения.

Для обучения классификатора идентификации состояния КО требуется большой объем размеченных данных. В качестве исходных данных была использована выборка, сгенерированная программным модулем [6], объемом 33 746 измерений блеска КО. Программный модуль позволяет сформировать измерительную информацию, которая учитывает динамические, оптико-геометрические характеристики космических объектов, а также позволяет смоделировать различные варианты фоноцелевой обстановки и технические характеристики информационных средств. Были смоделированы различные ситуации, характерные для двух классов состояний КО — управляемые КО и неуправляемые.

При наблюдении за состоянием КО особенностью получаемых данных о блеске КО является то, что невозможно судить о состоянии КО по одному статическому значению в текущий момент времени, а значит обучение классификатора должно основываться на совокупности свойств набора блеска КО, которые меняются с течением времени и содержат в себе информацию о таких изменениях. Поэтому было принято решение в набор данных для классификации включить дополнительно числовые значения о скорости изменения блеска v , а также о его ускорении a . Таким образом, была сформирована номенклатура входного вектора X , состоящего из значения блеска s , изменения скорости блеска v , изменения ускорения блеска a .

2 этап. Предварительная обработка и анализ данных.

Одна из наиболее распространенных форм предварительной обработки состоит из простого линейного масштабирования входных переменных. Конечно, разница в масштабе входных переменных влияет не на все алгоритмы машинного

обучения (деревья решений, случайный лес), но когда используются расстояние или скалярные произведения между предикторами (k -ближайших соседей, метод опорных векторов), необходима процедура нормализации. Нормализация данных представляет собой масштабирование данных из исходного диапазона таким образом, чтобы все значения находились в пределах нового диапазона от 0 до 1, а нормируемое значение вычисляется как:

$$x_{\text{norm}} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}},$$

где x_i — текущее значение диапазона x ;

$x_{\min}, x_{\max}$ — минимальное и максимальное значение диапазона x соответственно

Среди существующих классических методов классификации можно выделить следующие группы: линейные, логические, метрические и вероятностные. При выборе конкретного алгоритма классификации следует учитывать особенности каждого из них. Каждая группа методов имеет свои преимущества и недостатки, а также область применения. С целью выбора наиболее подходящего классификатора для решения поставленной задачи был проведен анализ имеющихся данных с помощью построенных матриц разброса (рис. 1) и корреляции (рис. 2).

Анализ полученной матрицы разброса показывает, что, возможно, переменные v и a могут иметь нормальное или гауссово распределение, а переменная s почти гауссово распределение, что указывает на возможность применения методов машинного обучения, которые предполагают гауссово одномерное распределение по входным переменным.

Матрица корреляции дает представление о том, насколько связаны изменения между двумя переменными. Анализ полученной матрицы корреляции показывает, что переменные v и a имеют сильную корреляцию друг с другом, а значит некоторые алгоритмы машинного обучения, такие как линейная и логистическая регрессия, могут иметь низкую производительность.

По результатам проведенного анализа принято решение провести эксперименты со следующими алгоритмами классификации:

- наивный байесовский классификатор;
- метод k -ближайших соседей;




Рис. 1. Матрица разброса значений блеска космического объекта

- метод опорных векторов;
- деревья принятия решений;
- случайный лес;
- методы дискриминантного анализа:
 - а) линейный дискриминантный анализ;
 - б) квадратичный дискриминантный анализ.

3 этап. Построение и обучение классификатора.

Согласно поставленной задаче (1), рассмотрим модели алгоритмов классификаторов, применяемых в исследовании.

1. Наивный байесовский классификатор (NBC) относится к вероятностным методам классификации. Данный метод основан на использовании теоремы Байеса с априорным предположением о независимости исследуемых параметров выборки. Наивная байесовская классификация определяет принадлежность к классу, если вероятность, связанная с прогнозом переменной, превышает 0,5. Для входного вектора x наивная байесовская классификация оценивает вероятность того, что выходная переменная принадлежит классу m в виде

$$P(Y = m | x) = \frac{P(Y = m)P(x | Y = m)}{P(x)} = \frac{P(Y = m) \prod_{i=1}^N P(x_i | Y = m)}{P(x)},$$




Рис. 2. Матрица корреляции значений блеска космического объекта

где $P(Y = m)$ — априорная вероятность того, что состояние КО отнесено к классу m ;

$P(x | Y = m)$ — вероятность того, что состояние КО, представленное вектором его блеска x , находится в классе m ;

$P(x)$ — вероятность того, что состояние КО можно представить в виде вектора его блеска x .

2. Метод k -ближайших соседей (KNN) — метрический метод распределения данных по классам. Классификатор k -ближайших соседей можно рассматривать как присваивающий

k -ближайшим соседям вес $1/k$, а всем остальным нулевой вес. Условная вероятность принадлежности x классу m оценивается как

$$P_m(X) = P(Y = m | X = x) = \frac{1}{k} \sum_{i=1}^k I(y_i = m),$$

где k — количество ближайших соседей (значений блеска КО);

$I(y_i = m)$ — индикатор, определяемый как:

$$I(y_i = m) = \begin{cases} 1, & y_i = m \\ 0, & y_i \neq m \end{cases}.$$

3. Метод опорных векторов (SVC) относится к линейным методам классификации. Классификатор SVC разделяет набор бинарно размеченных обучающих данных гиперплоскостью, удаленной от каждого класса максимально. С помощью тренировочной выборки данных N , метод опорных векторов строит пороговый классификатор $a(x)$ вида

$$a(x) = \text{sign} \left[\sum_{i=1}^N \lambda_i y_i \psi(x_i, x) - b \right],$$

где $\psi(x_i, x)$ — ядро классификатора;

λ_i — вес, выражающий степень важности ядра классификатора;

b — вспомогательный параметр (скалярный порог).

4. Дерево решений (DTC) — логический метод классификации. Данный алгоритм генерирует ациклический граф на основе обучающих данных. Согласно сформированному графу, производится последовательный переход от одного узла к другому, реализуя таким образом классификацию в соответствии со значениями параметров блеска КО. При достижении одного из листьев дерева (конечного узла) определяется класс, которому принадлежит набор параметров блеска КО.

5. Классификатор случайный лес (RFC) — состоит из множества деревьев решений, каждое дерево из которого строится на основе случайной выборки из исходного набора данных. После обучения значение вектора x может быть получено путем усреднения прогнозов по всем отдельным деревьям классификации (B), используя классификатор $a(x)$ вида

$$a(x) = \frac{1}{B} \sum_{b=1}^B f_b(x),$$

где $f_b(x)$ — отдельное решающее дерево случайного леса.

Дискриминантный анализ предполагает, что классы данных определяются на основе различных распределений Гаусса. Дискриминант может быть линейным или квадратичным.

6. Линейный дискриминантный анализ (LDA) использует теорему Байеса для оценки вероятностей. Для входного вектора x вероятность того, что выходная переменная принадлежит классу m , оценивается в LDA как

$$P_m(X) = P(Y = m | X = x) = \frac{\pi_m f_m(x)}{\sum_{i=1}^m \pi_i f_i(x)},$$

где π_m — априорная вероятность того, что значение x принадлежит классу m ;

$f_m(x)$ — функция плотности X .

Предполагая, что $f_m(x)$ является нормальным или гауссовым, π_m можно выразить как

$$P_m(X) = P(Y = m | X = x) = \frac{\pi_m \frac{1}{\sigma_m \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_m^2}(x - \mu_m)^2\right)}{\sum_{i=1}^m \pi_i \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{1}{2\sigma_i^2}(x - \mu_i)^2\right)},$$

где μ_m — среднее значение наблюдений в классе m ;

σ_m — дисперсия наблюдений в классе m .

7. Квадратичный дискриминантный анализ (QDA) похож на LDA в присваивании входному вектору класса m . Однако QDA предполагает, что каждый класс имеет свою собственную ковариационную матрицу. Таким образом, граница между классами является линейной в LDA и квадратичной в QDA.

Для реализации и оценки способности к классификации КО перечисленных алгоритмов машинного обучения использовалась библиотека Scikit-Learn языка программирования Python [7, 8].

4 этап. Оценка качества классификации.

Перед построением классификатора исходная выборка (100 %) была случайным образом

поделена на обучающую выборку (тренировочную) (70 %) и тестовую (30 %). Обучающая выборка используется для обнаружения потенциальных прогностических взаимосвязей, а данные тестовой используются для проверки достоверности прогнозной модели. Преимуществами этого подхода являются:

- возможность протестировать модель машинного обучения на данных, которые не являются частью модели обучения;

- оценивание возможности применения техники машинного обучения для набора данных.

Разделение данных на обучающий набор и тестовый набор предотвращает переобучение модели [9]. Обучающий набор используется для создания модели прогнозирования на основе рассмотренных методов классификации, а точность модели прогнозирования оценивается с помощью тестового набора.

Для тестирования и сравнения алгоритмов классификации воспользуемся стандартной методикой десятикратной перекрестной проверки [10], результаты которой представлены на рис. 3.

Таким образом, на основе данных проведенной перекрестной проверки можно произвести выбор в пользу алгоритмов RFC, SVC, DTC.

Для оценки качества работы бинарных классификаторов воспользуемся ROC-кривой (кривая ошибок). Анализ классификаций с применением ROC-кривых представлен на рис. 4.

Таким образом, исходя из визуального сравнения ROC-кривых, а также принимая во внима-

ние размер площади под кривыми (area), можно произвести выбор в пользу алгоритма RFC (случайный лес).

Заключение

Применение методов машинного обучения классификации состояния КО по результатам оптических измерений, а также в организации информационного обеспечения планирования применения наземных ОЭС позволит значительно усовершенствовать научно-методический аппарат обработки измерительной информации в интересах решения задачи автоматического наблюдения и контроля состояния космических объектов.

При разработке методики в статье рассмотрены следующие наиболее распространенные методы построения и обучения классификатора: наивный байесовский классификатор, метод k -ближайших соседей, метод опорных векторов, деревья принятия решений, случайный лес, методы линейного и квадратичного дискриминантного анализа. Лучший результат из рассмотренных методов для решения задачи классификации состояния космического объекта по результатам оптических измерений показал алгоритм «случайный лес». Согласно результатам проведенного эксперимента, точность полученной модели более 80 % в определении состояния КО по данным наблюдения наземных ОЭС.

Дальнейшее развитие методики классификации состояния КО по результатам оптических




Рис. 3. Средние показатели перекрестной проверки на тестовом наборе для исследуемых моделей алгоритмов классификации космического объекта




Рис. 4. ROC-анализ исследуемых моделей алгоритмов классификации космического объекта

измерений будет направлено на построение адаптивного классификатора на основе искусственных нейронных сетей.

Литература

1. Котяшов Е.В., Кудинов М.Г., Шавин А.С. Постановка задачи классификации состояния геостационарного космического аппарата после столкновения с неизвестным космическим аппаратом // Труды Военно-космической академии им. А.Ф. Можайского. 2016. Вып. 652. С. 76–82.
2. Крупский К.А., Кудинов М.Г., Шавин А.С., Исупов А.А. Методический подход к решению задачи классификации состояния космических объектов по данным наблюдений наземными измерительными средствами // Вопросы радиоэлектроники. Техника телевидения. 2020. Вып. 2. С. 55–62.
3. Журавлёв Ю.И. Об алгебраическом подходе к решению задач распознавания или классификации // Проблемы кибернетики. 1978. Вып. 33. С. 5–68.
4. Шавин А.С. Алгоритм расчета площади отражающих поверхностей в геометрической модели космического объекта в интересах оценивания фотометрических характеристик // Труды Военно-космической академии им. А.Ф. Можайского. 2018. Вып. 661. С. 32–37.
5. Нестечук А.Н., Шавин А.С., Хлебников С.Г. Нейросетевая модель идентификации состояния космического объекта по результатам оптических измерений // Оборонный комплекс научно-техническому прогрессу России. 2022. № 1. С. 37–42.
6. Шавин А.С., Кудинов М.Г., Крупский К.А. и др. Свидетельство о государственной регистрации программы для ЭВМ № 2019617824. Программный модуль оценивания некоординатной информации о космических объектах наземными средствами системы контроля космического пространства. Заявка № 2019616828. Дата поступления 5 июня 2019 г. Зарегистрировано в Реестре программ для ЭВМ 20 июня 2019 г.
7. Jiangang Hao, Tin Kam Ho. Machine Learning Made Easy: A Review of Scikit-learn Package in Python Programming Language // Journal of Educational and Behavioral Statistics. 2019. Vol. XX. No. X. Pp. 1–14.

8. Paper David. Hands-on Scikit-Learn for Machine Learning Applications: Data Science Fundamentals with Python /Logan, UT, USA. 2020. 242 p.

References

1. Kotyashov E.V., Kudinov M.G., Shavin A.S. Setting the task of classifying the state of a geostationary spacecraft after a collision with an unknown spacecraft // Proceedings of the Military Space Academy named after A.F. Mozhayskogo. 2016. Issue 652. Pp. 76–82.
2. Krupsky K.A., Kudinov M.G., Shavin A.S., Isupov A.A. Methodological approach to solving the problem of classifying the state of space objects according to observations by ground-based measuring means // Radio electronics issues. Television technique. 2020. Issue 2. Pp. 55–62.
3. Zhuravlev Yu.I. On an algebraic approach to solving problems of recognition or classification// Problems of cybernetics. 1978. Issue 33. Pp. 5–68.
4. Shavin A.S. Algorithm for calculating the area of reflecting surfaces in the geometric model of a space object in the interests of assessing photometric characteristics // Proceedings of the A.F. Mozhayskogo Military Space Academy. 2018. Issue 661. Pp. 32–37.
5. Nestechuk A.N., Shavin A.S., Khlebnikov S.G. Neural network model for identifying the state of a space object based on the results of optical measurements // Defense complex scientific and technical progress of Russia. 2022. No. 1. Pp. 37–42.
6. Shavin A.S., Kudinov M.G., Krupsky K.A. et al. Certificate of state registration of computer program No. 2019617824. Program module for assessment of non-coordinate information on space objects by ground-based means of the space control system. Application No. 2019616828. Date of receipt June 5, 2019 Registered in the Computer Program Register on June 20, 2019.
7. Jiangang Hao, Tin Kam Ho. Machine Learning Made Easy: A Review of Scikit-learn Package in Python Programming Language // Journal of Educational and Behavioral Statistics. 2019. Vol. XX. No. X. Pp. 1–14.
8. Paper David. Hands-on Scikit-Learn for Machine Learning Applications: Data Science Fundamentals with Python /Logan, UT, USA. 2020. 242 p.