

УДК 004.8

**ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ
КЛАССИФИКАЦИИ ДИНАМИЧЕСКИХ ОБЪЕКТОВ
В ОКОЛОЗЕМНОМ ПРОСТРАНСТВЕ
ПО ДАННЫМ ОПТИЧЕСКИХ НАБЛЮДЕНИЙ**

А.А. Щукин, М.Д. Поляк

А.А. Щукин; М.Д. Поляк (ГУАП)

В данной работе решается задача классификации объектов на серии кадров звездного неба, заключающаяся в разделении зарегистрированных объектов на фоновые звезды и движущиеся космические тела. Разработанные алгоритмы имеют критически важное значение для обеспечения безопасности пилотируемых космических полетов, поскольку позволяют автоматически выявлять потенциально опасные объекты космического мусора и астероиды, сближающиеся с орбитальными станциями. Основное внимание уделяется сравнительному анализу двух подходов: метода опорных векторов (SVM) и нейросетевого метода на основе архитектуры U-Net. В качестве признаков для SVM используется траектория движения объектов, в то время как нейросеть обрабатывает траектории объектов и выделяет признаки автоматически.

Ключевые слова: метод опорных векторов, U-Net, классификация, распознавание образов

Intelligent Methods for Classifying Dynamic Objects in Near-Earth Space Based on Optical Observations. A.A. Shchukin, M.D. Polyak

The paper addresses the problem of classifying objects in a video sequence of the starry sky, specifically the task of distinguishing registered background stars from moving cosmic bodies. The developed algorithms are of crucial importance for ensuring the safety of manned space missions as they allow revealing automatically potentially dangerous space debris and asteroids approaching to the orbital stations. The main focus is on a comparative analysis of two approaches: the Support Vector Machine (SVM) method and a neural-network method based on U-Net architecture. For SVM, object motion trajectories are used as features, while the neural network processes these trajectories and extracts features automatically.

Keywords: support vector machine, U-Net, classification, image recognition

Постановка задачи

Обеспечение безопасности пилотируемых космических полетов является одним из приоритетных направлений современной космонавтики. Критически важной задачей становится своевременное обнаружение и классификация объектов в околоземном пространстве, представляющих потенциальную угрозу для экипажей орбитальных станций и космических кораблей. По данным Европейского космического агентства, в настоящее время на орбите

Земли находится свыше 130 млн фрагментов космического мусора размером более 1 мм [1], что создает серьезную опасность для пилотируемых миссий.

В данной работе рассматривается применение методов машинного и глубокого обучения для автоматического распознавания и классификации объектов на последовательных панорамных астрономических изображениях, полученных с наземных телескопов. Основная задача заключается в идентификации объектов, представляющих интерес для научных исследований и обеспечения безопасности космических полетов с последующим разделением их на две категории: стационарные объекты (фоновые звезды) и динамические объекты (космический мусор, астероиды, искусственные спутники), перемещающиеся относительно звездного фона. Решение данной задачи необходимо для построения траекторий движения и последующего вычисления элементов орбит потенциально опасных космических объектов.

Предполагается, что разработанные алгоритмы смогут автоматически определять координаты объектов на каждом изображении в координатной системе приемника. Эти координаты могут быть впоследствии переведены в сферическую систему координат, что позволит решить задачу отождествления наблюдаемых объектов и проводить их дальнейшую идентификацию для оценки степени опасности.

В отличие от стандартных алгоритмов, нейросети способны выявлять скрытые закономерности в данных и обобщать полученную ранее информацию, что полезно при идентификации нетипичных объектов или фрагментов космического мусора нестандартной формы, которые могут быть упущены традиционными методами обнаружения.

Анализ существующих методологических подходов к решению задачи

Современные системы космического мониторинга используют различные подходы для автоматического обнаружения движущихся объектов на астрономических изображениях.

В статье [2] описывается разработка двух методов для решения задачи обнаружения космических объектов:

– НТ (англ. *Hough Transform*): алгоритм для обнаружения линий на изображении, основанный на преобразовании Хафа. Используется для выявления линейных траекторий объектов. Результаты метрик: Precision = 0,92; Recall = 0,88; F1 = 0,90.

– LSD (англ. *Line Segment Detector*): современный алгоритм для обнаружения локальных линейных сегментов с высокой точностью и скоростью. Результаты метрик: Precision = 0,95; Recall = 0,91; F1 = 0,93.

В работе [3] рассматривается метод автоматического обнаружения малоразмерных искусственных космических объектов (спутников и космического мусора) на оптических изображениях звездного неба с использованием

сверточных нейронных сетей (англ. *Convolutional Neural Networks, CNN*). Авторы используют предобученные модели TinyYOLO (англ. *You Only Look Ones*) для ускорения обучения и повышения точности на ограниченных наборах данных. Для выделения объектов от фона применяется пороговая сегментация. Достигнутые результаты: Precision = 0,94; Recall = 0,89; F1 = 0,91.

Исследование [4] посвящено применению методов глубокого обучения для автоматического обнаружения объектов дальнего космоса (англ. *Deep Sky Objects, DSO*) на изображениях, полученных с помощью смарт-телескопов. Рассматривались различные модели CNN, архитектуры VGG и ResNet с 50 слоями, оптимизированные для задачи обнаружения, а также YOLO. Также в статье рассматривается классификация, основанная на традиционных техниках обработки изображений, таких как фильтрация и сегментация, с последующим определением рамок вокруг оставшихся объектов. Результаты показали следующую эффективность:

- обработка изображений и выявление объектов – Precision = 0,45; Recall = 0,36; F1 = 0,40.
- YOLOv7 – Precision = 0,79; Recall = 0,51; F1 = 0,62.
- ResNet50 – Precision = 0,68; Recall = 0,41; F1 = 0,51.

В работе [5] также применяется модель YOLOv7 для обработки изображений астрономических объектов. Результаты: Precision = 0,79; Recall = 0,51; F1 = 0,62.

Работа [6] представляет решение для автоматического обнаружения и определения расстояния до космических объектов (КО) в околоземном пространстве, включая среднюю околоземную орбиту (СОО) и выше (до 40 000 км). Авторы используют преобразование Хафа для идентификации траекторий КО на длинноэкспозиционных изображениях после фильтрации шума и вычисляют параллакс объектов на основе синхронизированных наблюдений с двух пунктов.

Исследовательская часть

SVM. Первый рассматриваемый метод машинного обучения в данной работе – SVM [7–10].

Суть данного метода заключается в построении такой разделяющей гиперплоскости, которая эффективно разделяет классы в признаковом пространстве. Каждый объект имеет совокупность признаков, которые превращаются в координаты данного объекта в пространстве признаков, где оси координат – отдельные искусственно выведенные признаки. На основе обучающих примеров строится разделяющая гиперплоскость, где по разные стороны находятся объекты разных классов.

Ядра модели (например, линейное, полиномиальное, сигмоид, RBF и т. д.) – математические функции, которые влияют на поведение гиперплоскости. Классическая модель использует линейную гиперплоскость, однако

при выборе других ядерных функций гиперплоскость может принимать произвольные нелинейные формы.

В данной работе в качестве ключевых признаков было выделено два основных параметра: *относительная скорость и угол движения объекта* по сравнению с остальными объектами на изображении. Для каждого объекта вычисляется траектория его перемещения и сравнивается со средним значением угла и движения всех объектов на изображении: если объект движется заметно быстрее остальных и в другом направлении, то он классифицируется как движущийся космический объект, а не фоновая звезда.

SVM-классификатор требует тщательной предварительной обработки входных признаков, поскольку наличие выбросов или некорректных данных может существенно повлиять на качество классификации.

Для предварительной обработки видеоданных и последующей классификации объектов необходимо на первом этапе определить координаты значимых объектов с исключением фоновых элементов изображения. С этой целью применяется алгоритм субтракции фона MOG2 (англ. *Mixture of Gaussians 2*), который на основе истории кадров строит модель фона и вычитает ее из текущего изображения. В результате формируется бинарная маска, содержащая только движущиеся и потенциально значимые объекты сцены [11, 12].

На следующем этапе для каждого из выделенных объектов рассчитывается вектор перемещения между двумя последовательными кадрами (t и $t+1$) с использованием метода оптического потока Лукаса – Канаде [13]. Полученные характеристики движения (например, величина и направление перемещения) используются в качестве признаков для формирования многомерного признакового пространства. После этого данные объектов сопоставляются с построенной ранее разделяющей гиперплоскостью метода опорных векторов. На основании положения объекта в признаковом пространстве принимается решение о его принадлежности к одному из классов. Схематическое представление последовательности обработки и классификации приведено на рис. 1.

В данной работе использовался SVM-классификатор с RBF-ядром, который показал следующие метрики на тестовой выборке.

В табл. 1 представлены значения метрик Precision (точность), Recall (полнота) и F1-Score, посчитанные на тестовой выборке.

Таблица 1

Метрики SVM-классификатора

Название	Значение
Precision	0,985
Recall	0,985
F1-Score	0,98

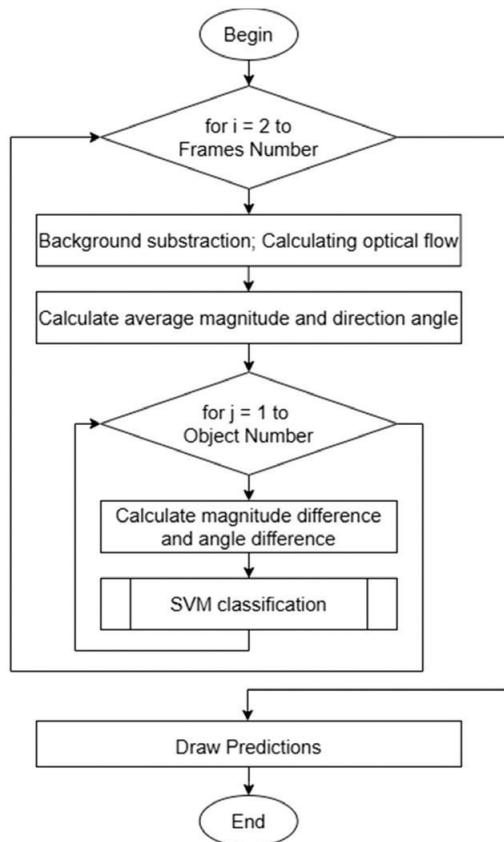


Рис. 1. Блок-схема работы классификатора

Несмотря на высокие значения метрик, продемонстрированные классификатором SVM, данный метод обладает рядом существенных ограничений, снижающих его универсальность при решении прикладных задач анализа астрономических изображений.

Во-первых, эффективность SVM напрямую зависит от качества выделенных признаков, формируемым вручную. Это делает модель чувствительной к выбору признакового пространства и существенно ограничивает ее переносимость между различными наборами данных. Даже при визуально качественных признаках существует риск, что они не отражают ключевые характеристики объектов, что может привести к некорректной классификации.

Во-вторых, метод SVM слабо адаптируется к изменениям структуры входных данных. Алгоритм демонстрирует нестабильные результаты при переменном количестве кадров в последовательности. Это ограничивает возможность его использования в реальных условиях мониторинга космических объектов, когда длина временного окна может варьироваться в зависимости от условий съемки или характеристик оборудования.

Нейросетевой подход. Реализация модели U-Net. Нейросетевая модель архитектуры U-Net позволяет избежать проблем, возникающих при использовании метода опорных векторов. В отличие от SVM, нейросеть способна автоматически извлекать информативные признаки из данных, не требуя ручного формирования признакового пространства. Кроме того, такие модели обладают высокой адаптивностью и способны эффективно обрабатывать данные с переменным числом входных изображений [14].

Для решения данной задачи была выбрана архитектура U-Net, получившая свое название благодаря характерной симметричной U-образной структуре:

- энкодер (сжимающая часть);
- декодер (восстанавливающая часть);
- бутылочное горлышко (англ. bottleneck, ядро принятия решений) [15, 16].

На рис. 2 представлена схема архитектуры модели.

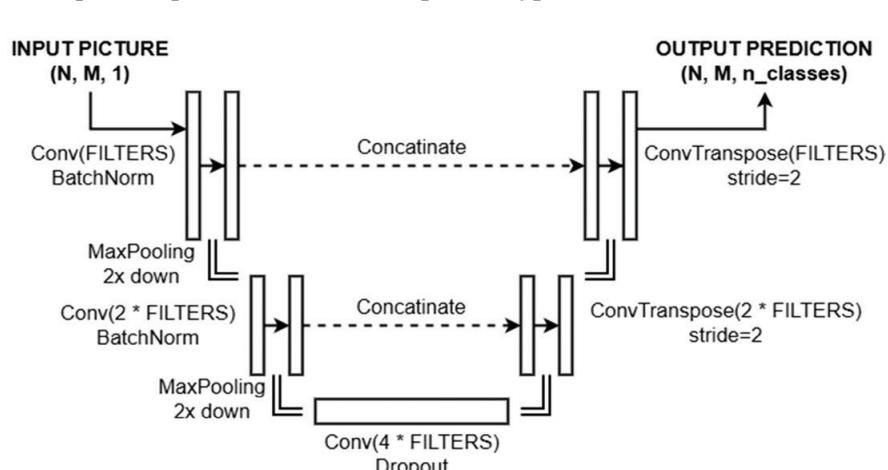


Рис. 2. Схема модели архитектуры U-Net

Энкодер состоит из серии блоков, каждый из которых включает сверточный слой для извлечения признаков и слой MaxPooling, уменьшающий пространственное разрешение изображения в два раза. Его основная задача – формирование обобщенного представления содержимого входного изображения.

На рис. 3 показан пример операции свертки: локальный фрагмент изображения умножается поэлементно на сверточный фильтр, а сумма произведений формирует значение одного пикселя выходной карты признаков [17]. Использование разнообразных фильтров позволяет выявлять характерные паттерны и текстурные особенности изображений.

Центральной частью модели является «бутылочное горлышко» – слой, на вход которого поступает максимально сжатое представление изображения.

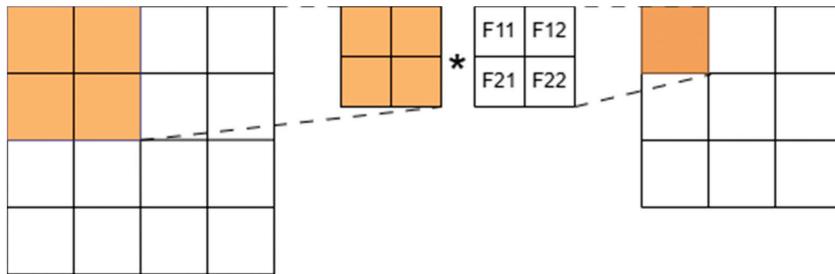


Рис. 3. Пример свертки изображения

В этой части задействуется наибольшее количество фильтров, что позволяет модели извлекать наиболее информативные и обобщенные признаки. Для предотвращения переобучения (англ. *overfitting*) на данном этапе применяется метод регуляризации (англ. *dropout*), снижающий зависимость модели от отдельных нейронов.

Декодер осуществляет развертку признаков до исходного разрешения и восстанавливает пространственную структуру изображения. Для точного восстановления локальных особенностей используются пропускающие соединения (англ. *skip connections*) с соответствующими уровнями энкодера, что способствует сохранению контекстной информации и улучшению точности сегментации.

На выходе модели формируется двумерная матрица размером $N \times M$, где значения элементов интерпретируются как вероятности принадлежности соответствующего пикселя к определенному классу.

Поскольку архитектура U-Net не является рекуррентной моделью, было принято решение создавать изображения типа МНІ (англ. *Motion History Image*), представляющие собой суперпозицию нескольких последовательных кадров [18]. На таких изображениях можно наглядно отследить перемещение объектов, при этом снизив вычислительную нагрузку за счет объединения нескольких изображений в одно. На рис. 4 представлен пример МНІ.



Рис. 4. Пример МНІ

Для обучения модели использовались искусственно сгенерированные видеоряды звездного неба, содержащие как фоновые звезды, так и движущиеся космические объекты. Различия между видеорядами заключаются, в частности, в скорости смещения звездного фона. Каждый видеоряд сопровождается аннотированным файлом в формате MATLAB, содержащим координаты центроидов объектов на каждом кадре. Набор данных был создан при помощи симулятора звездного поля, разработанного в Центре космических полетов имени Джорджа Маршалла [19]. В отличие от реальных снимков, сгенерированные видеоданные менее зашумлены, однако отражают динамику реальных наблюдаемых объектов. Всего для обучения модели использовалось два видеоряда или 4500 кадров, для создания МН выбиралась окна с переменным размером в пределах 25–50 кадров для увеличения устойчивости работы. Было сформировано 88 батчей, 70 из которых использовались для обучения, 18 – для тестирования модели. Каждый батч состоял из 50 картинок и 50 матриц с ответами, соответственно, для каждой картинки.

В силу того, что модель осуществляет пиксельную классификацию, в выборке наблюдается значительный дисбаланс классов – большинство пикселей соответствует фону, в то время как объекты (как стационарные, так и движущиеся) занимают небольшую часть изображения. Для повышения количества малочисленных классов был реализован алгоритм аугментации: маски объектов отражались по горизонтали, вертикали и обеим осям, создавая копии объектов на изображении, что позволило увеличить разнообразие обучающей выборки без искажения семантики.

Для обучения и валидации модели была реализована специальная функция потерь, которая игнорировала фоновые пиксели при решении задачи классификации. Предсказания для пикселей фона не учитывались при вычислении функции качества, поэтому модель училась концентрировать внимание на классификации объектов, игнорируя фоновые области.

Для решения задачи была выбрана трехуровневая архитектура U-Net. Количество фильтров в сверточных блоках составляло 16, 32 и 64 соответственно. Общая численность параметров модели составила 51 217. Модель обучалась в течение пяти эпох. Обучение модели проводилось в вычислительной среде, не оснащенной графическими ускорителями, все операции обучения выполнялись исключительно с использованием центрального процессора. Это существенно увеличило продолжительность обучения, полное обучение модели заняло около 15 часов. Обучение модели можно ускорить посредством увеличения вычислительных мощностей.

Для модели U-Net метрики точности, полноты и F1-меры вычислялись с учетом маски фона, в табл. 2 представлены результаты значений метрик, которые показывают насколько хорошо модель справляется с решением задачи классификации.

Таблица 2

Метрики U-Net

Название	Значение
Precision	0,8944
Recall	0,9872
F1-Score	0,9385

Ввиду того, что нейросеть обучалась на искусственно сгенерированных данных, необходимо было проверить ее работоспособность на реальных астрономических снимках.

Реальные астрономические изображения, использованные в данной работе, были предоставлены Крымской астрофизической обсерваторией. Снимки получены в прямом фокусе 2,6-метрового зеркального телескопа им. Г.А. Шайна (ЗТШ). Фокусное расстояние составляет 10 метров. Отмеченные объекты характеризуются медленным угловым движением – порядка нескольких угловых секунд в минуту.

На рис. 5 представлен результат обработки серии кадров российской космической рентгеновской обсерватории «Спектр-РГ». Обсерватория выведена на гало-орбиту вокруг точки Лагранжа L2, находящейся на расстоянии 1,5 млн км от Земли. Наблюдения получены 25 февраля 2025 г. в течение 74 мин. Космический аппарат имел скорости видимого движения 0,1 и $-2,1$ угл. сек/мин по прямому восхождению и склонению соответственно. Блеск составлял 18,5 зв. величины.

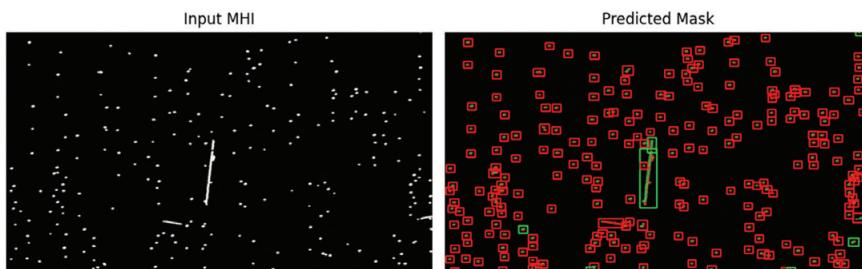


Рис. 5. Результат анализа объекта 44432

На рис. 6 и 7 представлен результат обработки серии кадров астероидов, сближающихся с Землей из списка NEO Confirmation Page [20].

Коллективные наблюдения подтвердили подлинность объектов, привели к их каталогизации. Астероид CCWF1R2 получил временное обозначение 2025 CE13. Наблюдения получены 25 февраля 2025 г. в течение 18 минут. Скорости видимого движения составили $V_{RA} = 3,30$ и $V_{DC} = -1,01$ угл. сек/мин.

Второй объект, P226SDx, оказался периодической кометой, получил обозначение P/2025 D3. Наблюдения получены 25 февраля 2025 г. в течение 24 мин. Скорости видимого движения составили $V_{RA} = -0,38$ и $V_{DC} = 0,26$ угл. сек/мин.

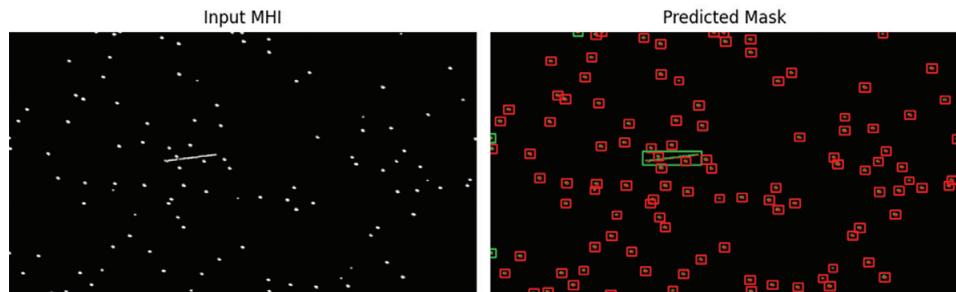


Рис. 6. Результат анализа объекта CCWF1R2

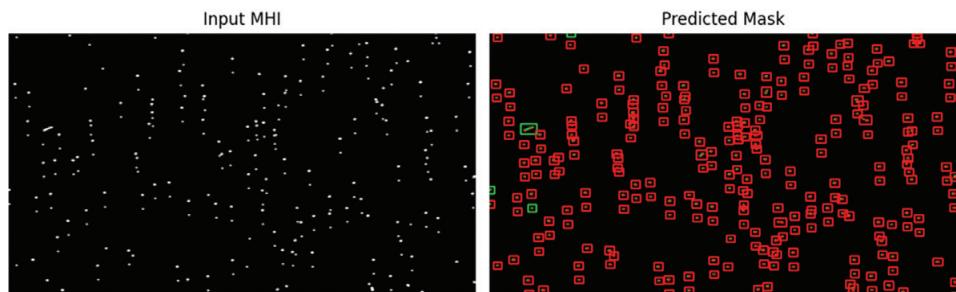


Рис. 7. Результат анализа P226SDx

На рис. 8 представлен пример, когда на снимке отсутствуют объекты. Данный пример показывает, что нейросеть работает с примерами, когда на изображениях объекты отсутствуют вовсе.

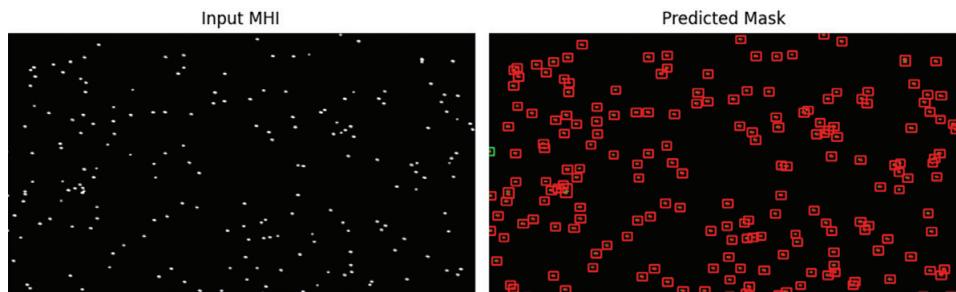


Рис. 8. Пример отсутствия движущихся объектов

Выше в табл. 1 представлены значения метрик Precision, Recall и F1-Score, посчитанные на представленных выше изображениях (см. рис. 5–8).

По результатам тестирования на реальных данных (табл. 3), модель продемонстрировала высокое значение метрики Recall, что свидетельствует о том, что она успешно обнаружила все реальные целевые объекты. Низкое значение Precision указывает на значительное количество ложных срабатываний. Модель целесообразно использовать в качестве инструмента первичного

выявления кандидатов, результаты работы которого требуют дополнительной постобработки.

Таблица 3

Метрики U-Net на реальных данных

Название	Значение
Precision	0,200
Recall	1,000
F1-Score	0,333

Выводы

В данной работе решена задача классификации объектов на последовательных изображениях звездного неба с целью их разделения на статичные (фоновые звезды) и движущиеся объекты (космический мусор, астероиды, искусственные спутники). Разработанные методы имеют важное значение для обеспечения безопасности пилотируемых космических полетов, поскольку позволяют заблаговременно выявлять потенциально опасные объекты и планировать соответствующие маневры уклонения.

Рассмотрены два подхода: метод SVM и нейросетевой метод с использованием модели архитектуры U-Net. Метод SVM продемонстрировал высокие значения метрик классификации при использовании вручную заданных признаков, таких как скорость и угол движения объектов. Однако эффективность данного метода снижается при изменении длины видеопоследовательности, качество работы SVM существенно зависит от качества выделенных признаков и алгоритма предварительной обработки.

Нейросетевая модель архитектуры U-Net автоматически выделяет информативные признаки без влияния субъективного человеческого фактора, поэтому ее эффективность ограничена только полнотой обучающих примеров. Модель демонстрирует устойчивость к вариациям длины входной последовательности и показывает высокие значения метрик точности и полноты.

Практическая значимость работы заключается в возможности интеграции разработанных алгоритмов в существующие системы космического мониторинга для повышения безопасности пилотируемых миссий. В условиях изменчивости наблюдательных данных и при необходимости создания универсального и адаптивного инструмента для анализа астрономических изображений нейросетевые методы, и в частности архитектура U-Net, являются более перспективным и практически применимым решением по сравнению с классическими алгоритмами машинного обучения. Разработанный подход может рассматриваться как элемент гибридной интеллектуальной системы поддержки принятия решений при наблюдениях околоземного пространства.

ЛИТЕРАТУРА / REFERENCES

1. ESA Space Environment Report 2025. – Текст: электронный // European Space Agency Space Debris Office: [website]. – 2025. – URL: https://www.esa.int/Space_Safety/Space_Debris/ESA_Space_Environment_Report_2025 (date of request 07.10.2025).
2. Automatic Space Object Detection on All-Sky Images from a Synoptic Survey Synthetic Telescope Array / Felipe I. San Martín, Claudio A. Perez, Juan E. Tapia, Shahzad Virani, Marcus J. Holzinger // Advances in Space Research. – 2020. – Vol. 65, Issue 1. – P. 337–350.
3. Применение сверточных нейронных сетей для автоматической селекции малоразмерных искусственных космических объектов на оптических изображениях звездного неба / А.К. Цицулин, А.И. Бобровский, А.В. Морозов, В.А. Павлов, [и др.] // Оптический журнал. – 2019. – Том 86, № 10. – С. 30–38.
Application of Convolutional Neural Networks for Automatic Selection of Small-sized Artificial Space Objects in Optical Images of the Starry Sky / A.K. Tsitsulin, A.I. Bobrovsky, A.V. Morozov, V.A. Pavlov [et al.] // Optical Journal. – 2019. – Vol. 86, No 10. – P. 30–38.
4. Parisot, O. Deep Sky Objects Detection with Deep Learning for Electronically Assisted Astronomy / O. Parisot, M. Jaziri // Luxembourg Institute of Science and Technology. – 2024. – P. 122–138.
5. Parisot, O. DeepSpaceYoloDataset: Annotated Astronomical Images Captured with Smart Telescopes / O. Parisot. – DOI 10.1007/978-3-031-83210-9_12 // Luxembourg Institute of Science and Technology. – 2024. – Vol. 2346. – P. 153–163.
6. Danescu, Radu. A Low Cost Automatic Detection and Ranging System for Space Surveillance in the Medium Earth Orbit Region and Beyond / Radu Danescu, Anca Ciurte, Vlad Turcu // Sensors. – 2014. – P. 2704–2731.
7. Хайкин, С. Нейронные сети: полный курс, 2-е издание. – Москва: Вильямс, 2006. – 1104 с.
Khaikin, S. Neural Networks: A Complete Course, 2nd Edition. – Moscow: Williams, 2006. – 1104 p.
8. Вапник, В.Н. Распознавание образов при помощи обобщенных портретов / В.Н. Вапник, А.Я. Лerner // Автоматика и телемеханика. – 1963. – № 6. – С. 774–780.
Vapnik, V.N. Pattern Recognition Using Generalized Portraits / V.N. Vapnik, A.Ya. Lerner // Automation and Telemechanics. – 1963. – No 6. – P. 774–780.
9. Cortes, C. Support-Vector Networks / C. Cortes, V. Vapnik. – DOI: 10.1007/BF00994018 // Machine Learning. – 1995. – Vol. 20, No 3. – P. 273–297.
10. Siji, J. Object Tracking Using HOG and SVM / Joseph Siji, Arun Pradeep. – DOI 10.14445/22315381/IJETT-V48P257 // International Journal of Engineering Trends and Technology. – 2017. – Vol. 48, No 6. – 5 p.
11. Tiehan, Lv. A Real-Time Background Subtraction Method with Camera Motion Compensation / Lv. Tiehan, Burak Ozer, Wayne Wolf. – DOI 10.1109/ICME.2004.1394196 // Proceedings of the 2004 IEEE International Conference on Multimedia and Expo, ICME 2004, 27–30 June 2004, Taipei, Taiwan. – Vol. 1. – P. 331–334.

12. Zivkovic, Z. Efficient Adaptive Density Estimation Per Image Pixel for the Task of Background Subtraction / Z. Zivkovic, Ferdinand van der Heijden. – DOI 10.1016/j.patrec.2005.11.005 // Pattern Recognition Letters. – 2006. – Vol. 27, No 7. – P. 773–780.
13. Gaur, V. Lucas-Kanade Optical Flow Machine Learning Implementations / V. Gaur. – DOI 10.47611/jsrhs.v11i3.2957 // Jurnal of Student Research. – 2022. – Vol. 11, No 3. – 19 p.
14. Поляк, М.Д. Модель стохастической искусственной нейронной сети в задачах распознавания образов // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика, телекоммуникации и управление. – 2013. – № 1. – С. 63–69.
Polyak, M.D. Model of a Stochastic Artificial Neural Network in Pattern Recognition Polytechnical University. Computer Science, Telecommunications and Control. – 2013. – No 1. – P. 63–69.
15. Ronneberger, O. U-Net: Convolutional Networks for Biomedical Image Segmentation / O. Ronneberger, P. Fischer, T. Brox. – DOI 10.1007/978-3-319-24574-4_28 // Medical Image Computing and Computer-Assisted Intervention. – MICCAI 2015. – Munich: Springer, 2015. – Vol. 9351. – P. 234–241.
16. Шквиро, С.А. Применение U-Net для выделения рядов виноградника по данным дистанционного зондирования Земли / С.А. Шквиро, М.Д. Поляк // V Международная конференция по нейронным сетям и нейротехнологиям (NeuroNT'2024): Сборник докладов конференции, Санкт-Петербург, 20 июня 2024 года. – Санкт-Петербург: Санкт-Петербургский государственный электротехнический университет ЛЭТИ им. В.И. Ульянова (Ленина), 2024. – С. 106–109.
Shkviro, S.A. Application of U-Net for Identification of Vineyard Rows Based on Earth Remote Sensing Data / S.A. Shkviro, M.D. Polyak // V International Conference on Neural Networks and Neurotechnologies (NeuroNT'2024): Conference Proceedings, Saint Petersburg, June 20, 2024. – Saint Petersburg: Saint Petersburg State Electro-technical University LETI Named After V.I. Ulyanov (Lenin), 2024. – P. 106–109.
17. Николенко, С. Глубокое обучение / С. Николенко, А. Кадурин, Е. Архангельская. – Санкт-Петербург: Питер, 2018. – 480 с.
Nikolenko, S. Deep Learning / S. Nikolenko, A. Kadurin, E. Arkhangelskaya. – Saint Petersburg: Peter, 2018. – 480 p.
18. Tsai, Du.M. Optical Flow-Motion History Image (OF-MHI) for Action Recognition. Signal, Image and Video Processing / Du.M. Tsai, W.Ya. Chiu, M.H. Lee. – DOI 10.1007/s11760-014-0677-9 // Springer Nature: an Electronic Journal. – 2014. – Vol. 9, No 8. – P. 1897–1906.
19. A Robust Vision-based Algorithm for Detecting and Classifying Small Orbital Debris Using On-board Optical Cameras // Github.com: [website]. – URL: <https://github.com/nnategh/AMOS2019> (date of request 07.10.2025).
20. NEO Confirmation Page // The Minor Planet Center: [website]. – URL: https://minorplanetcenter.net/iau/neo/toconfirm_tabular.html (date of request 07.10.2025).