

## НЕЙРОННЫЕ СЕТИ ДЛЯ ПОИСКА СИГНАЛОВ МЕТЕОРОВ В ДАННЫХ ОРБИТАЛЬНОГО ТЕЛЕСКОПА “УФ АТМОСФЕРА”

© 2023 г. М. Зотов<sup>1,\*</sup>, Д. Соколинский<sup>2</sup>, А. Арифуллин<sup>2</sup>

<sup>1</sup>Московский государственный университет им. М.В. Ломоносова,  
Научно-исследовательский институт ядерной физики им. Д.В. Скобельцына, Москва, Россия

<sup>2</sup>Московский государственный университет им. М.В. Ломоносова, Москва, Россия

\*E-mail: zotov@eas.sinp.msu.ru

Поступила в редакцию 01.11.2022 г.

После доработки 05.04.2023 г.

Принята к публикации 18.05.2023 г.

На Международной космической станции, начиная с 2019 г., работает российско-итальянский эксперимент “УФ атмосфера” (Mini-EUSO), основным инструментом которого является широкоугольный телескоп, направленный в надир. Главной целью эксперимента является получение карты излучения ночной атмосферы Земли в ультрафиолетовом диапазоне, что является необходимым элементом подготовки крупномасштабного эксперимента по изучению космических лучей предельно высоких энергий с помощью орбитального телескопа. Как и более ранний эксперимент ТУС, прибор “УФ атмосфера” регистрирует сигналы разнообразных процессов, происходящих в атмосфере в УФ диапазоне, и среди них – свечение метеоров. Мы описываем две простые нейронные сети, которые позволяют эффективно выделять сигналы метеоров в общем потоке данных. Реализованный подход может быть применен для поиска трекоподобных сигналов различной природы в данных флуоресцентных и черенковских телескопов.

*Ключевые слова:* телескоп “УФ атмосфера”, нейронные сети, распознавание образов, метеоры

**DOI:** 10.31857/S0004629923060105, **EDN:** VBIJW

### 1. ВВЕДЕНИЕ

Международная научная коллаборация JEM-EUSO, в состав которой входят исследователи из 16 стран, включая Российскую Федерацию, разрабатывает программу по изучению космических лучей предельно высоких энергий (КЛ ПВЭ, энергии  $\geq 50$  ЭэВ) на основе регистрации в ночной атмосфере Земли флуоресцентного и черенковского излучения широких атмосферных ливней (ШАЛ), порождаемых этими КЛ, с помощью орбитального телескопа [1, 2]. Такой телескоп, обладающий широким полем зрения, помимо ШАЛ, может регистрировать и другие процессы, проявляющие себя в виде свечения в ультрафиолетовом (УФ) диапазоне, что было продемонстрировано в 2016–2017 гг. в ходе эксперимента ТУС на борту спутника Ломоносов [3, 4]. К сигналам, регистрация которых возможна в ходе такого орбитального эксперимента, относится и свечение метеоров [5, 6], что также было подтверждено в ходе эксперимента ТУС [7]. С осени 2019 г. на борту российского сегмента (РС) Международной космической станции (МКС) проводится российско-итальянский эксперимент “УФ атмосфера” (Mini-EUSO), целью которого является

получение карты свечения ночной атмосферы Земли в полосе длин волн ближнего ультрафиолета (290–430 нм) в пределах широт, доступных наблюдениям с МКС [8–10]. Эта информация необходима для успешной подготовки и проведения полномасштабных орбитальных экспериментов по изучению космических лучей предельно высоких энергий с помощью телескопов, разрабатываемых коллаборацией JEM-EUSO в рамках проектов КЛПВЭ (K-EUSO) [11] и РОЕММА [12]. При этом, наряду с фоновым излучением атмосферы, в рамках эксперимента регистрируются самые разнообразные сигналы в УФ диапазоне: антропогенное свечение, транзитные атмосферные явления, ШАЛ-подобные события и многие другие. Регистрируется также значительное число сигналов от метеоров [13, 14].

Поскольку данные, получаемые с помощью телескопов, естественно рассматривать как изображения или анимации, одним из популярных инструментов их анализа стали т.н. сверточные нейронные сети (СНС), созданные в первую очередь именно для классификации изображений и продемонстрировавшие в этом классе задач высочайшую эффективность (см., напр., [15, 16]).

Здесь необходимо отметить, что различные методы машинного обучения, включая искусственные нейронные сети (НС), в последние годы находят все более широкое применение в астрономии и астрофизике [17–19], включая исследования, связанные с регистрацией метеоров (см., напр., работы [20–25]). Одной из типичных задач, решаемых в ходе таких исследований, является распознавание сигналов, на поиск которых нацелен тот или иной эксперимент. В простейшей постановке такая задача может сводиться к классификации данных на два класса: данные (“записи”, “события”), в которых содержится сигнал искомого типа, и данные, в которых такого сигнала нет. Ранее мы использовали СНС для распознавания двух типов событий, зарегистрированных в ходе эксперимента ТУС. Оказалось, что даже простейшие СНС при надлежащем представлении данных способны быстро и эффективно решать такую задачу [26, 27]. Более того, нейронные сети, обученные на выборках, подготовленных с помощью традиционных алгоритмов отбора сигналов по определенным заданным признакам, оказались в состоянии обнаруживать сигналы, примеры которых не входили в обучающие наборы данных. В частности, к ним относятся сигналы малой амплитуды с низким соотношением сигнала к шуму. Это позволило существенно расширить наши знания о сигналах рассмотренных типов и дало ответы на некоторые открытые вопросы. При этом важно отметить, что упомянутые результаты были получены с помощью НС, нетребовательных к вычислительным мощностям, что открывает возможность для их реализации в бортовой электронике орбитальных детекторов, которые не обладают высокопроизводительными процессорами.

В данной работе мы рассказываем о нашем опыте разработки нейронных сетей для распознавания сигналов от метеоров в данных орбитального эксперимента “УФ атмосфера”, основным инструментом которого является широкоугольный флуоресцентный телескоп. Мы покажем, какая архитектура нейронных сетей и какие способы организации данных позволили эффективно решить эту задачу. Работа носит методический характер: мы не представляем конкретные астрономические результаты нашего исследования, поскольку экспериментальные данные являются собственностью коллаборации и будут освещены в отдельной публикации. Тем не менее мы надеемся, что она может быть полезна специалистам, занимающимся анализом данных флуоресцентных и черенковских телескопов.

## 2. ЭКСПЕРИМЕНТ “УФ АТМОСФЕРА”

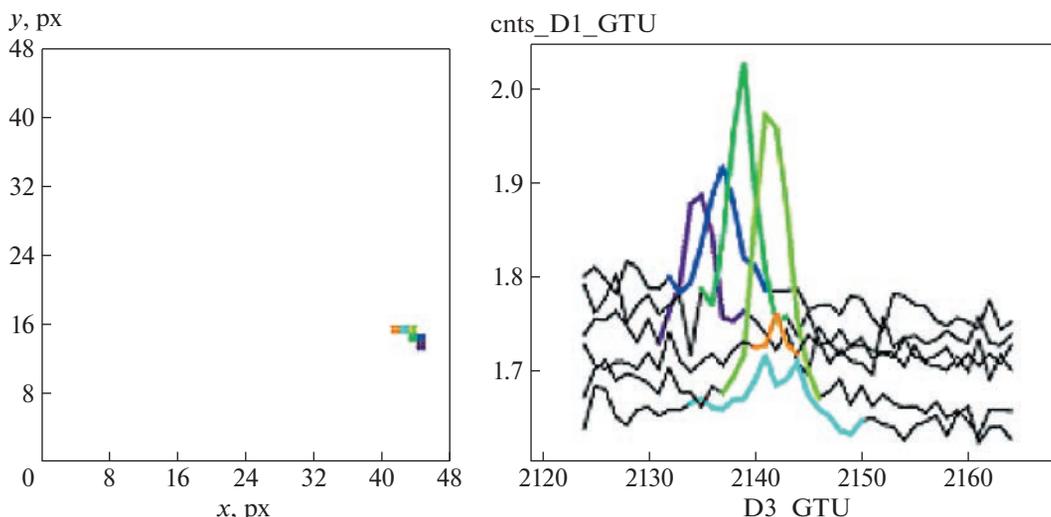
Основными элементами телескопа “УФ атмосфера” являются две линзы Френеля диаметром

25 см и фокальная плоскость (ФП), состоящая из 36 многоанодных ФЭУ (МАФЭУ) Hamamatsu R11265-M64, образующих матрицу размером  $6 \times 6$ . Каждый МАФЭУ имеет  $8 \times 8$  пикселей с размером отдельного пикселя  $2.88 \text{ мм} \times 2.88 \text{ мм}$ ; полное число пикселей на ФП составляет 2304. Фокальное расстояние прибора равняется 300 мм с размером функции рассеяния точки (ФРТ)  $\sim 1.2$  пикселя. МАФЭУ сгруппированы в 9 т.н. блоков элементарных ячеек (elementary cell units), по 4 МАФЭУ в каждом. Все блоки имеют свое питание высокого напряжения, которое регулируется независимо от остальных блоков. Перед каждым МАФЭУ установлен УФ фильтр толщиной 2 мм, изготовленный из материала ВГЗ. Поле зрения прибора составляет  $44^\circ$ , так что с высоты орбиты МКС телескоп обзревает площадь размером примерно  $300 \text{ км} \times 300 \text{ км}$  с разрешением порядка  $6.3 \text{ км} \times 6.3 \text{ км}$  (поле зрения одного пикселя). Все управление прибором осуществляется одноядерным процессором CMX34BT с тактовой частотой 1.33 ГГц. Детальное описание прибора можно найти в работе [8].

Временное разрешение прибора составляет 2.5 мкс. При этом сбор данных реализуется одновременно в трех режимах: с минимальным временным разрешением и длиной каждой записи 128 тактов (режим D1), в режиме с интегрированием сигнала по 128 тактам (D2), и в режиме с интегрированием по  $128 \times 128$  тактам, т.е. с шагом 40.96 мс (D3). В последнем случае запись ведется непрерывно, без триггера. Именно в этом режиме становится возможной запись полных треков метеоров, поэтому ниже мы будем оперировать именно такими данными.

Наблюдения осуществляются через прозрачный для УФ излучения иллюминатор, имеющийся в российском модуле “Звезда”. Сеансы наблюдений проводятся приблизительно два раза в месяц, в зависимости от расписания других экспериментов на РС МКС. Как правило, наблюдения начинаются в районе 18:30 UTC и продолжаются приблизительно 12 ч. Поскольку объем телеметрических данных, передаваемых со станции, ограничен, данные записываются на твердотельные жесткие диски объемом 512 ГБ, по одному диску на каждый сеанс наблюдений. Приблизительно 10% данных, собранных за каждый сеанс, передается на Землю. Это позволяет при необходимости вносить изменения в программное обеспечение прибора. Примерно один раз в год на Землю возвращаются все заполненные диски. В настоящей статье мы используем данные, полученные в течение 5–9 и 11–14 сессий, состоявшихся в период с 19.11.2019 по 01.04.2020 в штатном режиме работы прибора.

На рис. 1 из работы [9] показан пример сигнала метеора, зарегистрированного телескопом



**Рис. 1.** Пример сигнала метеора, зарегистрированного в эксперименте “УФ атмосфера” [9]. Другие сигналы, зарегистрированные одновременно с метеором, не показаны.

“УФ атмосфера”<sup>1</sup>. Слева можно увидеть расположение активных каналов на фокальной плоскости, справа — сигналы в активных каналах. Смещение пиков ломаных на правой панели отражает перемещение сигнала в поле зрения телескопа. Этот рисунок дает представление о характере сигналов, которые нужно найти в экспериментальных данных, однако зарегистрированные одновременно “фоновые” сигналы на рисунке не показаны.

Чтобы понять, почему распознавание сигналов метеоров представляет определенные сложности, взглянем на рис. 2 и 3 из работы [8]. На первом из них схематично показаны формы некоторых типов сигналов, регистрируемых экспериментом “УФ атмосфера”. На втором — пример “фоновой” засветки фокальной плоскости прибора. Видно, что разнообразие возможных форм (“профилей”) сигналов весьма велико, а фон, на котором необходимо выделять интересующие нас сигналы, может быть интенсивным и сильно неоднородным. Применительно к распознаванию сигналов метеоров эти сложности можно сформулировать следующим образом:

- в случае, показанном на рис. 1, сигнал метеора сосредоточен в 6 из 2304 каналов ФП; вследствие низкого пространственного разрешения прибора примерно в 70% случаев количество активных пикселей не превышает 4, что невелико по сравнению с полным числом пикселей и не позволяет получить ясно выраженный трек;

- сигналы от метеоров имеют характерную форму, напоминающую плотность нормального

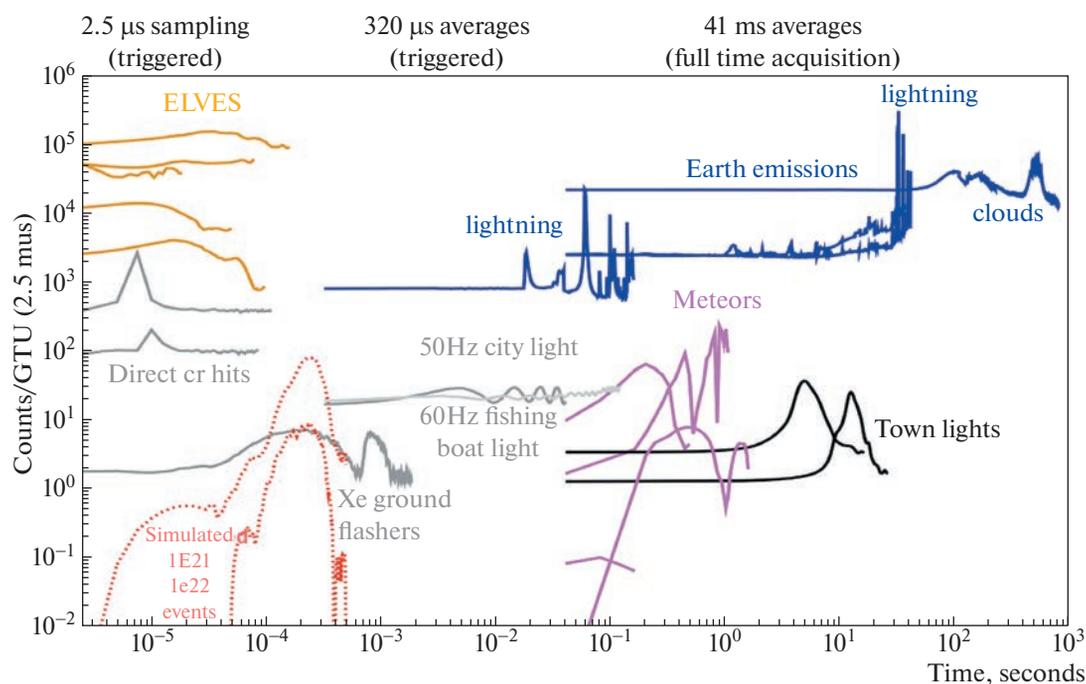
распределения, однако их амплитуда может быть много меньше, чем амплитуда других сигналов, попадающих одновременно с ними на ФП; в частности, это имеет место, когда в поле зрения телескопа оказывается интенсивная антропогенная засветка; кроме этого, некоторые другие вспышки имеют аналогичную форму сигнала;

- поскольку сгорание метеора в атмосфере является сравнительно медленным процессом, вследствие движения МКС фон, на котором регистрируется метеор, не является статичным, а также перемещается, что в некоторых случаях может “маскировать” сигнал метеора;

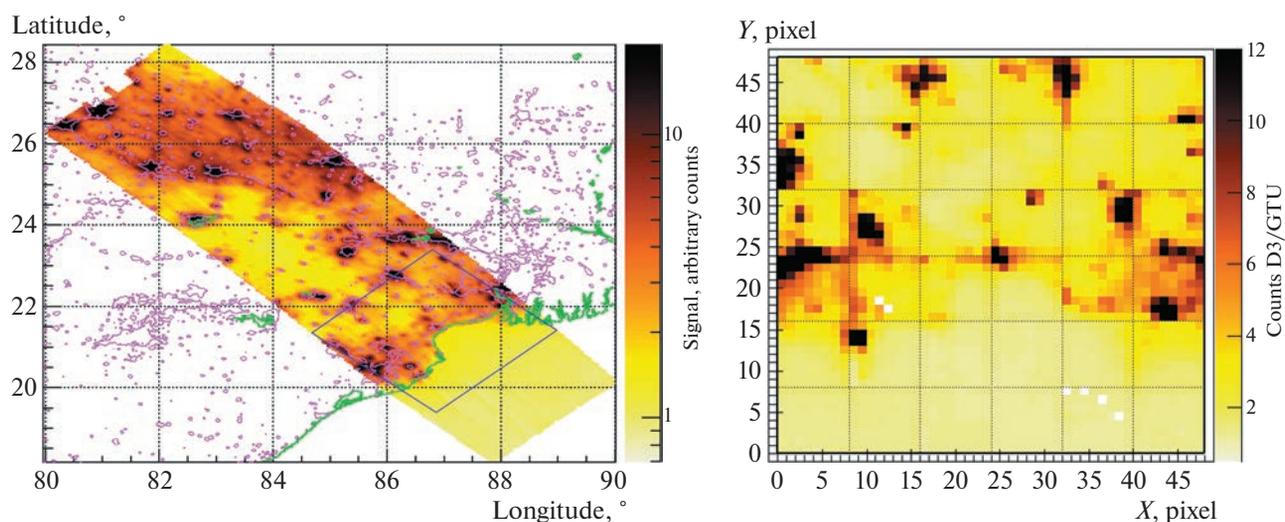
- наблюдения осуществляются при различных фазах Луны, вследствие чего уровень фонового излучения сильно варьируется от одной сессии к другой.

В коллаборации JEM-EUSO было разработано два алгоритма для поиска сигналов метеоров в данных эксперимента “УФ атмосфера”, основанных на традиционных методах анализа данных [13, 14]. Оба алгоритма основаны на упомянутом сходстве формы сигналов, порождаемых метеорами, с плотностью нормального распределения, а также тем фактом, что метеор, перемещающийся в поле зрения телескопа, оставляет на ФП квазилинейный трек, форма и длина которого зависят от угла вхождения метеора в атмосферу, его яркости, пространственного разрешения прибора и размера ФРТ. Алгоритмы заключаются в обнаружении превышения сигнала над фоном на заданную величину в каждом из 2304 каналов ФП, его аппроксимации нормальным распределением и последующем сравнении отобранных событий с ожидаемыми параметрами, а именно, возможной продолжительностью сигнала в каж-

<sup>1</sup> В силу правил коллаборации Mini-EUSO, здесь и ниже мы приводим только примеры уже опубликованных данных.



**Рис. 2.** Возможные формы некоторых типов сигналов, регистрируемых телескопом “УФ атмосфера” [8]: эльфы (ELVES), прямые попадания КЛ (Direct CR hits), смоделированные профили излучения ШАЛ от КЛ ПВЭ с энергиями  $10^{21}$  и  $10^{22}$  эВ (Simulated 1e21, 1e22 events), наземные вспышки ксеноновых импульсных ламп (Xe ground flashers), за-светка от населенных пунктов и рыболовецких судов (50 Hz city light, 60 Hz fishing boat light, Town lights), грозовые разряды (lightnings), метеоры (Meteors), свечение атмосферы (Earth emissions), облака (clouds). По оси абсцисс отложено время, по оси ординат – число отсчетов за один такт времени (2.5 мкс).



**Рис. 3.** Пример сигналов, регистрируемых телескопом “УФ атмосфера”, как они выглядят на фокальной плоскости прибора [8]. Четырехугольник на левой части рисунка обозначает границы поля зрения, показанного справа. Темные области соответствуют более высокому уровню излучения.

дом отдельном канале. Эту величину нетрудно оценить исходя из имеющихся данных о диапазоне возможных скоростей метеоров (с учетом движения МКС). В случае обнаружения в одном из

каналов сигнала, удовлетворяющего заданным параметрам, необходимо проверить наличие аналогичных сигналов в смежных каналах в близкие моменты времени. При обнаружении группы та-

ких каналов надо убедиться в том, что они образуют на ФП квазилинейный трек (с учетом ФРТ) с правильной временной упорядоченностью пиков сигналов в отдельных пикселях. Поскольку данные, получаемые в режиме D3, не имеют триггеров и по сути представляют собой непрерывную анимацию в рамках ночного сегмента орбиты, поиск сигналов метеоров необходимо осуществлять с помощью скользящего окна определенного размера. В результате вся процедура требует значительного вычислительного времени. Так, поиск метеоров в данных одной сессии наблюдений на компьютере с процессором класса Intel i7 с помощью программы, написанной на Python, занимает несколько часов. При этом, вследствие разнообразия регистрируемых сигналов, в отобранных выборках присутствует существенная доля ложноположительных событий – вплоть до 60% всех отобранных событий в зависимости от параметров отбора и особенностей данных конкретной сессии.

### 3. КЛАССИФИКАЦИЯ ДАННЫХ

В дальнейшем мы будем обсуждать искусственные НС двух архитектур: многослойные перцептроны (МСП) и сверточные нейронные сети (СНС). В настоящее время имеется огромное количество учебной литературы, лекций и онлайн-ресурсов по машинному обучению и нейронным сетям, поэтому мы не будем на этом подробно останавливаться, а лишь кратко напомним некоторые основные идеи. Ознакомиться с предметом можно, например, по обзорам [17–19] или книгам [28, 29].

МСП представляет собой разновидность многослойных НС прямого распространения и состоит из трех или более слоев: входного слоя, на который подаются данные для его обучения, выходного слоя, на котором осуществляется принятие решения (классификация или прогноз), и некоторого числа т.н. скрытых слоев, состоящих в свою очередь из узлов (нейронов). Обучение модели происходит в скрытых слоях на основе метода обратного распространения ошибки [30]. Было показано, что многослойные перцептроны могут аппроксимировать практически любую непрерывную функцию с желаемой точностью [31].

Как уже упоминалось выше, СНС были разработаны для обработки изображений [15]. Аналогично тому, как это происходит в МСП, данные сначала попадают на входной слой СНС, после чего передаются на т.н. сверточный слой, в котором вычисляется сходство между небольшими участками поданного на вход изображения, с некоторыми шаблонами (“ядрами свертки”). Затем в объединяющем слое (слое подвыборки) значения близких пикселей группируются, что снижает сложность данных и приводит к выбору при-

знаков, устойчивых к небольшим изменениям. При необходимости слои объединения и сверточные слои повторяются (с другими параметрами), после чего данные передаются на полносвязные слои, аналогичные скрытым слоям МСП. Как и в случае других НС, последовательность слоев происходит многократно с целью обучения модели, и в итоге данные попадают на выходной слой, который осуществляет, например, классификацию исходных изображений.

Для обоих типов сетей мы применяли т.н. “обучение с учителем”, т.е. НС тренировались на некотором предварительном размеченном наборе данных, который называется обучающим и состоит из двух частей: выборки, которая используется непосредственно для обучения (она составляет, как правило, 80–90% от всего набора) и “валидационной” выборки (оставшиеся 10–20%), с помощью которой контролируется процесс обучения. В частности, она позволяет заметить момент, когда НС начинает подстраиваться под конкретный обучающий набор (“переобучается”) без реального повышения качества обучения. Целью процесса обучения является минимизация ошибки между желаемым выходом и выходом нейронной сети путем корректировки весов между слоями НС.

Набор данных, использовавшийся для обучения и тестирования НС, содержал сигналы почти 1100 метеоров, зарегистрированных в течение девяти сессий наблюдений в период с 19.11.2019 по 01.04.2020. Он был составлен на основе двух баз данных, подготовленных группой в коллаборации JEM-EUSO, занимающейся анализом данных эксперимента “УФ атмосфера”, и собственного анализа авторов. Распределение метеоров по сессиям оказалось сильно неравномерным. Так, в данных сессии 9, проведенной 08–09.01.2020 в районе полнолуния, были найдены сигналы всего 4 метеоров, а в данных сессии 6, прошедшей 27–28.11.2019 через сутки после новолуния – 290. Здесь необходимо подчеркнуть, что, вне зависимости от метода анализа, в некоторых случаях не удастся с полной уверенностью определить, вызван ли обнаруженный сигнал прохождением метеора в поле зрения телескопа или каким-либо другим процессом. Это в первую очередь относится к коротким трекам, сосредоточенным в 2–3 пикселях, а также сигналам, зарегистрированным на сильно переменном фоне. Поэтому из набора были исключены все сигналы, относительно которых возникали сомнения в природе их происхождения.

При разработке искусственной НС можно выделить два ключевых момента: выбор, во-первых, архитектуры сети и, во-вторых, способа организации данных. Напомним, что экспериментальные данные “УФ атмосфера”, полученные в

режиме D3 с тактом по времени 40.96 мс, представляют собой трехмерные наборы размера  $F \times F \times T$ , где  $F$  соответствует размеру ФП, а  $T$  – количеству тактов в течение сеанса наблюдений. Задачу распознавания сигналов метеоров мы решали в два этапа: на первом этапе в потоке данных отбирались элементы размера  $M \times M \times N$  (“события”), содержащие какую-либо часть трека (или весь трек) метеора. На втором шаге, рассмотренном в следующем разделе, в каждом из таких наборов выделялись пиксели, содержащие сигнал метеора.

Для решения первой задачи мы протестировали несколько конфигураций сверточных сетей с различными гиперпараметрами, а также т.н. LSTM-сети с памятью, которые часто используются для классификации видео. Входные данные организовывались различными способами с  $M = 4, 6, 8, 12, 16, 24, 48$  и  $N = 6, 8, 16, 32, 48, 64$ . Диапазон изменения величины  $N$  примерно соответствовал диапазону длительностей сигналов метеоров (в единицах числа тактов записи) в имеющемся наборе данных. Наилучшие результаты в наших тестах достигались для  $N = 48$  и  $N = 64$ . Ниже для определенности мы используем первое из этих значений. Элементы размером  $M \times M \times N$  выделялись с помощью плавающего окна. Сдвиг по фокальной плоскости (для  $M < 48$ ) составлял  $M/2$ , сдвиг по времени не превышал  $N/2$ . Списки “не-метеоров”, необходимые для обучения нейронной сети, выбирались из данных случайным образом с учетом списка метеоров. Для того, чтобы приблизить условия обучения нейронной сети к возможным условиям применения в режиме реального времени, данные подвергались лишь минимальной модификации, например, не вычитался фон и не выравнивались чувствительности отдельных каналов ФП. Единственная модификация заключалась в часто рекомендуемой для НС нормировке по формуле  $(X_i - \langle X_i \rangle) / \sigma(X_i)$ , где  $X_i$  – значения сигнала в отдельном канале с номером  $i$ , а  $\langle X_i \rangle$  и  $\sigma(X_i)$  – оценки соответственно среднего значения и среднеквадратического отклонения сигнала в этом канале за  $N$  тактов времени.

Для оценки качества обучения НС преимущественно использовалась метрика “площадь под кривой ошибок” (area under the curve, AUC). Напомним, что кривая ошибок (receiver operation curve, ROC), представляет собой зависимость доли истинно положительных элементов в наборе данных от доли ложноположительных. Площадь под кривой ошибок равняется 1 в идеальном случае, 0 – в наихудшем; значение 0.5 соответствует случайному равновероятному выбору. Величина этой площади не зависит от объема тестового набора и имеет простую интерпретацию: она дает

вероятность того, что нейронная сеть произведет верную классификацию, если ей будут предложены на выбор два события, извлеченные случайным образом из обоих классов<sup>2</sup>.

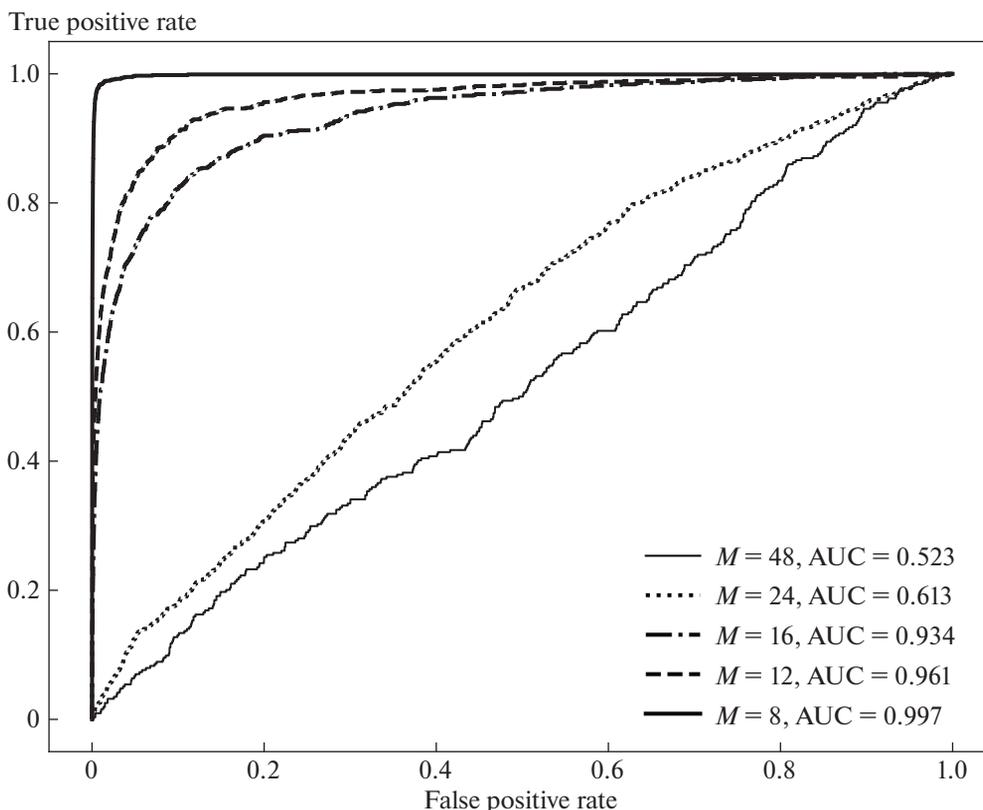
Обучение и тестирование НС осуществлялось следующим образом: из имеющегося набора данных исключалась одна из сессий, после чего обучение производилось на данных оставшихся сессий, а тестирование – на сессии, исключенной из обучения. Так перебирались все возможные комбинации из имевшихся 9 сессий.

Оказалось, что вне зависимости от архитектуры и гиперпараметров протестированных НС, результаты обучения на наборах, использовавших значения  $M = 24$  или 48, являются неудовлетворительными. В частности, при использовании данных размером  $48 \times 48 \times 48$  нам не удалось добиться площади под кривой ошибок, превышающей 0.75 даже при использовании сетей LSTM, требующих для обучения заметных вычислительных ресурсов. Однако величина AUC начинала быстро возрастать при уменьшении  $M$ . Этот эффект продемонстрирован на рис. 4, на котором показан результат тестирования простой СНС, состоящей из одного сверточного слоя с ядром размера 3, слоя объединения по максимуму и двух полносвязных слоев, состоящих из 256 и 64 нейронов, на сессии 14, проведенной 31.03–01.04.2020<sup>3</sup>. Хорошо видно, что при использовании данных сразу со всей ФП ( $M = 48$ ) результат классификации не сильно отличался от результата случайного выбора (AUC = 0.523), но достиг величины 0.997 при  $M = 8$ . Дальнейшего возрастания качества обучения при уменьшении  $M$  не наблюдалось. Аналогичные результаты были получены для всех остальных сессий, имевшихся в нашем распоряжении.

Подчеркнем, что в силу выбранной организации данных сигнал каждого метеора оказывается в той или иной степени представлен в двух и более элементах данных размером  $M \times M \times N$  (за исключением коротких сигналов, расположенных в углах ФП). При этом нас в конечном итоге интересует качество распознавания сигналов метеоров, а не этих перекрывающихся элементов, качество классификации которых характеризуют метрики типа AUC. Например, нас вполне устраивает ситуация, при которой некоторая доля элементов, содержащих сигнал метеора, будет утеряна (ложно отрицательные

<sup>2</sup> Мы использовали и другие метрики оценки качества обучения, встречающиеся в литературе, но их поведение в целом коррелировало с поведением данной метрики, поэтому мы на них в данной работе не останавливаемся.

<sup>3</sup> Для решения задачи оптимизации использовался алгоритм Adam, в качестве функции активации в выходном слое применялась функция сигмоид, в полносвязных слоях – ReLU.



**Рис. 4.** Кривые ошибок для тестовых наборов из 14-й сессии наблюдений, полученные при различных значениях размера окна  $M = 48, 24, 16, 12, 8$ . По оси абсцисс отложена доля ложноположительных событий, по оси ординат — доля истинно положительных событий. AUC обозначает площадь под соответствующими кривыми. Длина всех элементов выборок  $N = 48$ . AUC — площадь под кривой.

элементы), но все активные каналы данного сигнала будут представлены в элементах, классифицированных верно. Анализ этих двух групп данных показал, что доля потерянных метеоров в худшем случае составляет около 2% от числа метеоров в тестовой сессии.

Насколько мы можем судить, два фактора предопределили резко возросшую эффективность обучения НС при уменьшении размера окна  $M \times M^4$ . Во-первых, очевидно, что распознать короткий сигнал на маленьком сегменте изображения проще, чем на полном изображении, поскольку в первом случае сигнал метеора занимает более существенную часть подаваемого на вход нейронной сети изображения, что облегчает его идентификацию. Во-вторых, такой способ организации входных данных резко увеличил в обучающем наборе количество примеров, содержащих сигнал метеоров, поскольку благодаря маленькому размеру скользящего окна почти все сигналы метеоров оказывались сразу в нескольких элементах входного набора. Так, если число элемен-

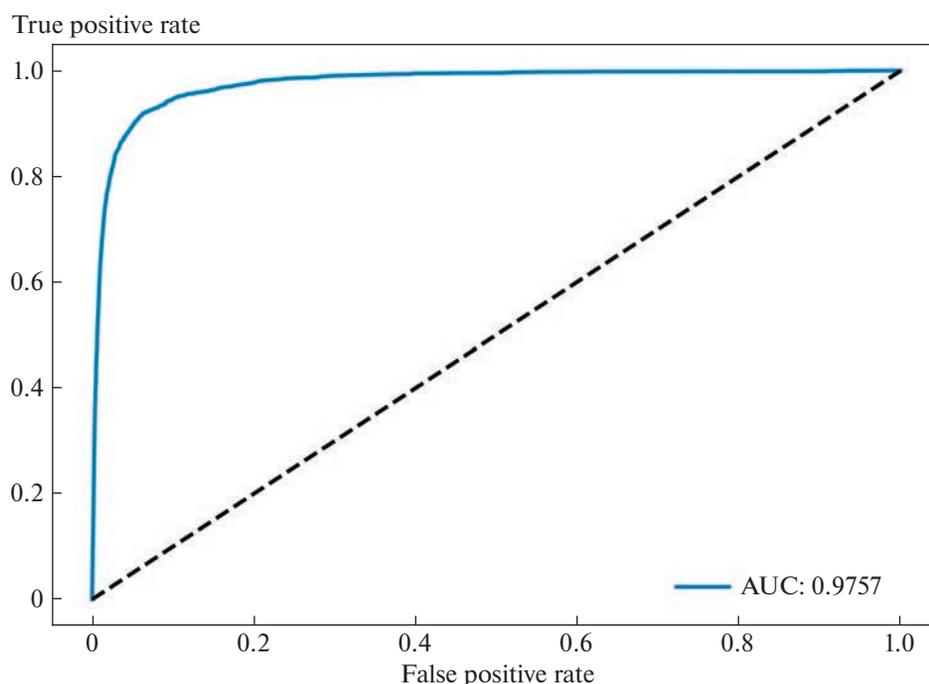
тов с сигналами метеоров в обучающей выборке с  $M = 48$  составляло 2385, то для  $M = 8$  оно равнялось 8066. После применения стандартной процедуры трехкратного поворота изображения на  $90^\circ$  с целью аугментации (“размножения”) данных это число превышало 32 тыс., что приближается к значениям, применяемым в других задачах классификации изображений.

#### 4. ВЫДЕЛЕНИЕ АКТИВНЫХ КАНАЛОВ

В результате классификации входных данных с помощью сверточной нейронной сети, описанной в предыдущем разделе, мы получаем список событий (набор данных), состоящий из тензоров размером  $8 \times 8 \times N$ , в которых сеть обнаружила сигнал метеора. Следующим шагом является указание, в каких именно пикселях каждого события локализован данный сигнал. В области обработки изображений такую операцию часто называют сегментацией.

Очевидно, что указанную задачу можно решить с помощью традиционного подхода, основная идея которого описана выше. Трудоемкость вычислений в данном случае будет существенно

<sup>4</sup> Отметим, что использование  $M = 8$  не эквивалентно применению ядра свертки размером 8 для  $M = 48$ .



**Рис. 5.** Кривая ошибок для тестовой выборки из 14-й сессии в задаче выделения каналов фокальной плоскости, содержащих сигнал метеора.

ниже, чем при анализе полного набора данных, так как события, содержащие сигналы метеоров, составляют его малую часть. Однако интересно попробовать решить ее с помощью нейронных сетей, поскольку эта задача хорошо изучена.

Одним из наиболее популярных методов сегментации изображений с помощью НС являются т.н. сети U-Net, первоначально предложенные для медицинских приложений [32]. Сети этой архитектуры продемонстрировали свою эффективность во многих областях, включая распознавание объектов определенных типов на спутниковых снимках (см., напр., [33]). К сожалению, попытка применить сеть U-Net к данным “УФ атмосфера” не дала хороших результатов. Поэтому мы воспользовались тем, что, как упоминалось выше, сигналы метеоров имеют характерную форму, а сама задача выделения каналов, в которых локализован сигнал, может быть решена как еще одна задача бинарной классификации. Поскольку в данном случае сигнал каждого канала представляет собой вектор фиксированной длины, эту задачу несложно решить, например, с помощью многослойного перцептрона.

Входные данные для МСП были организованы в виде размеченных наборов векторов длины  $N = 48$ , извлекаемых из элементов размером  $8 \times 8 \times 48$ , содержащих сигналы метеоров. Обучающие наборы содержали до 12 тыс. примеров, тестовые наборы – до 62 тыс. Были протестированы

перцептроны с одним, двумя и тремя скрытыми слоями, различным числом нейронов в слоях и разными функциями активации. Тесты не выявили существенных преимуществ какой-либо из опробованных конфигураций. В результате мы остановились на двухслойном перцептроне с 96 нейронами в первом скрытом слое и 64 нейронами во втором, в котором сочетались хорошая скорость и высокое качество обучения. Для оптимизации использовался алгоритм Adagrad. На рис. 5 показана кривая ошибок для тестового набора из 14-й сессии, состоящего из 54 тыс. элементов. Величина площади под кривой ошибок составляет 0.976, что можно считать хорошим результатом.

Типичная ошибка классификации, допускаемая этой нейронной сетью, связана с ситуацией, когда во входном векторе находится лишь самое начало либо конец сигнала, но не его максимум. Поскольку, как упоминалось выше, процедура построения входных наборов построена таким образом, что одни и те же сигналы дублируются со сдвигом по времени, всегда находится вектор данных, содержащий максимум соответствующего сигнала. Правильная классификация такого сигнала уже не представляет сложности для нейронной сети.

Может возникнуть вопрос, является ли первичная классификация данных на две группы – событий, содержащих сигналы метеоров, и событий, такие сигналы не содержащих, необходи-

мым элементом описанного подхода. Ответ утвердительный. Это связано с тем, что, как мы объясняли выше, для сигналов метеоров характерна не только специфическая форма сигнала, напоминающая нормальное распределение, но и взаимное расположение активных каналов на фокальной плоскости, а также перемещение сигнала по квазилинейному треку. Перцептрон, описанный выше, классифицирует сигналы исключительно по их форме, не принимая во внимание сигналы в смежных каналах. В результате этого попытка применить такой МСП сразу ко всем данным приводит к ошибочной классификации в качестве метеоров значительного количества сигналов, форма которых соответствует ожидаемой от метеора, но амплитуда изменяется синхронно в большом числе соседних каналов, так что они не образуют трека на ФП.

## 5. ОБСУЖДЕНИЕ И ВЫВОДЫ

Мы показали, каким образом можно решать задачу поиска сигналов метеоров в данных орбитального эксперимента “УФ атмосфера” с помощью простых нейронных сетей, обучение и применение которых возможно на типичном персональном компьютере. Важно подчеркнуть, что хотя эта задача надежно решается и с помощью традиционных методов анализа данных, представленный нейросетевой подход продемонстрировал ряд преимуществ: с одной стороны, он позволил в несколько раз уменьшить число событий, ошибочно отобранных в качестве содержащих сигнал метеора, и, следовательно, резко сократить время, необходимое для последующего “ручного” анализа данных, а с другой — выявить некоторое количество метеоров с низким соотношением сигнал/шум, которые не были найдены традиционным способом. Кроме этого, обученные нейронные сети показали существенно более высокую производительность: если в рамках классического подхода программе, написанной на Python, потребовалось несколько часов, чтобы проверить данные одной сессии наблюдений на наличие сигналов от метеоров, то НС справились с этой задачей за несколько минут.

Мы полагаем, что в силу простоты и общности примененных методов они могут быть использованы для распознавания сигналов других типов в данных различных флуоресцентных и черенковских телескопов. В частности, мы планируем применить этот подход для поиска ШАЛ-подобных событий в данных “УФ атмосфера” и стратосферного эксперимента EUSO-SPB2 [34], намеченного на 2023 г. Конкретные результаты поиска метеоров в данных “УФ атмосфера” с помощью описанных выше нейронных сетей будут представлены в отдельной публикации от лица коллаборации JEM-EUSO.

## ФИНАНСИРОВАНИЕ

Работа МЗ и ДС выполнена за счет гранта Российского научного фонда N22-22-00367, <https://rscf.ru/project/22-22-00367/>.

## БЛАГОДАРНОСТИ

МЗ благодарит Dario Barghini, Matteo Battisti, Александра Белова, Mario Bertaina, Marco Casolino, Павла Климова, Laura Marcelli, Hiroko Miyamoto, Lech Piotrowski, Zbigniew Plebaniak из коллаборации JEM-EUSO за неоценимую помощь с данными “УФ атмосфера”, а также Michal Vrábel за полезное обсуждение. Все нейронные сети были реализованы на языке Python с использованием пакетов TensorFlow [35] и Scikit-learn [36].

## СПИСОК ЛИТЕРАТУРЫ

1. *J. H. Adams, S. Ahmad, J.-N. Albert, D. Allard, et al.*, *Exp. Astron.* **40**(1), 3 (2015).
2. *M. E. Bertaina and JEM-EUSO Collaboration*, in *37th International Cosmic Ray Conference*, held 12–23 July 2021, Berlin, Germany, PoS(ICRC2021) **395**, id. 406 (2022).
3. *P. A. Klimov, M. I. Panasyuk, B. A. Khrenov, G. K. Garipov, et al.*, *Space Sci. Rev.* **212**, 1687 (2017).
4. *B. A. Khrenov, P. A. Klimov, M. I. Panasyuk, S. A. Sharakin, et al.*, *J. Cosmology and Astroparticle Phys.* **9**, id. 006 (2017).
5. *J. H. Adams, S. Ahmad, J.-N. Albert, D. Allard, et al.*, *Exp. Astron.* **40**, 253 (2015).
6. *G. Abdellaoui, S. Abe, A. Acheli, J. Adams, et al.*, *Planet. Space Sci.* **143**, 245 (2017).
7. *O. I. Ruiz-Hernandez, S. Sharakin, P. Klimov, O. M. Martínez-Bravo*, *Planet. Space Sci.* **218**, id. 105507 (2022).
8. *S. Bacholle, P. Barrillon, M. Battisti, A. Belov, et al.*, *Astrophys. J. Suppl.* **253**, id. 36 (2021).
9. *M. Casolino, J. Adams Jr., A. Anzalone, E. Arnone, et al.*, in *37th International Cosmic Ray Conference*, held 12–23 July 2021, Berlin, Germany, PoS(ICRC2021) **395**, id. 354 (2022).
10. *M. Casolino, D. Barghini, M. Battisti, C. Blaksley, et al.*, *Remote Sensing Environment* **284**, id. 113336 (2023).
11. *P. Klimov, M. Battisti, A. Belov, M. Bertaina, et al.*, *Universe* **8**, 88 (2022).
12. *A. V. Olinto, J. Krizmanic, J. H. Adams, R. Aloisio, et al.*, *J. Cosmology and Astroparticle Phys.* **2021**(06), id. 007 (2021), arXiv:2012.07945 [astro-ph.IM].
13. *D. Barghini, M. Battisti, A. Belov, M. E. Bertaina, et al.*, in: *14th Europlanet Science Congress 2020*, held virtually, 21 September 2020–9 October, 2020, online at <https://www.epsc2020.eu/>, id. EPSC2020-800 (2020).
14. *D. Barghini, M. Battisti, A. Belov, M. E. Bertaina, et al.*, in: *14th Europlanet Science Congress 2020*, held virtually, 21 September 2020–9 October, 2020, online at <https://www.epsc2020.eu/>, id. EPSC2021–243 (2020).
15. *Y. Le Cun, L. Bottou, Y. Bengio, and P. Haffner*, *Proc. of the IEEE* **86**, 2278 (1998).

16. *D. Cireşan, U. Meier, and J. Schmidhuber*, *Computer Vision and Pattern Recognition* **2012**, 3642 (2012), arXiv:1202.2745 [cs.CV].
17. *D. Baron*, arXiv:1904.07248 [astro-ph.IM] (2019).
18. *C. J. Fluke and C. Jacobs*, *WIREs Data Mining and Knowledge Discovery* **10**(2), id. e1349 (2019). <https://doi.org/10.1002/widm.1349>
19. *S. G. Djorgovski, A. A. Mahabal, M. J. Graham, K. Polsterer, and A. Krone-Martins*, arXiv:2212.01493 [astro-ph.IM] (2022).
20. *D. Fraser, Z. Khan, and D. Levy*, in: *Artificial Neural Networks*, edited by *I. Aleksander and J. Taylor* (North-Holland, Amsterdam, 1992), p. 1155.
21. *V. Ş. Roman and C. Buiu*, in: *Proc. of the International Meteor Conference*, held 18–21 September 2014, Giron, France, edited by *J. L. Rault and P. Roggemans*, Intern. Meteor Organization, p. 122 (2014).
22. *E. Silai, D. Vida, K. Nyarko*, in: *Proc. International Meteor Conference*, Mistelbach, held 27–30 August 2015, Mistelbach, Austria, edited by *J.-L. Rault and P. Roggemans*, Intern. Meteor Organization, p. 24 (2015).
23. *P. S. Gural*, *Monthly Not. Roy. Astron. Soc.* **489**, 5109 (2019).
24. *D. Cecil and M. Campbell-Brown*, *Planet. Space Sci.* **186** id. 104920 (2020).
25. *R. Sennlaub, M. Hofmann, M. Hankey, M. Ennes, T. Müller, P. Kroll, and P. Mäder*, *Monthly Notices of the Royal Astronomical Society* **516**, 811 (2022).
26. *M. Y. Zotov and D. B. Sokolinskiy*, *Moscow University Phys. Bull.* **75**, 657 (2020).
27. *M. Zotov*, *Universe* **7**, 1 (2021), <https://www.mdpi.com/2218-1997/7/7/221>.
28. *I. Goodfellow, Y. Bengio, and A. Courville*, *Deep Learning* (MIT Press, 2016).
29. *С. Рашка, В. Мурджалили, Python и машинное обучение* (Packt Publishing, Диалек-тика, 2019).
30. *D. E. Rumelhart, G. E. Hinton, and R. J. Williams*, *Nature* **323**, 533 (1986).
31. *G. V. Cybenko*, *Mathematics of Control, Signals and Systems* **2**, 303 (1989).
32. *O. Ronneberger, P. Fischer, and T. Brox*, arXiv:1505.04597 [cs.CV] (2015).
33. *G. Pasquali, G. C. Iannelli, and F. Dell'acqua*, *Remote Sensing* **11**, 2803 (2019).
34. *V. Scotti and G. Osteria*, *Nuclear Instruments and Methods in Physics Research A* **958**, id. 162164 (2020).
35. *M. Abadi, A. Agarwal, P. Barham, E. Brevdo, et al.*, *TensorFlow: Large-scale machine learning on heterogeneous systems* (2015), <https://www.tensorflow.org/>.
36. *F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, et al.*, *J. Machine Learn. Res.* **12**, 2825 (2011).