

ПРИМЕНЕНИЕ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ  
ДЛЯ РЕКОНСТРУКЦИИ МНОГОЧАСТИЧНЫХ СОБЫТИЙ  
ПО ДАННЫМ ДРЕЙФОВЫХ КАМЕР

© 2021 г. В. С. Воробьев<sup>а</sup>, \*, Е. А. Задеба<sup>а</sup>, Р. В. Николаенко<sup>а</sup>, А. А. Петрухин<sup>а</sup>, И. Ю. Трошин<sup>а</sup>

<sup>а</sup>Национальный исследовательский ядерный университет “МИФИ”, Москва, 115409 Россия

\*E-mail: VSVorobev@mephi.ru

Поступила в редакцию 04.03.2021 г.

После доработки 11.05.2021 г.

Принята к публикации 05.12.2021 г.

В НИЯУ МИФИ для исследования наклонных широких атмосферных ливней создается координатно-трековый детектор ТРЕК на основе многопроволочных дрейфовых камер. Для реконструкции событий с высокой множественностью по данным дрейфовых камер в настоящее время используется метод гистограммирования, который разработан для поиска параллельных треков. Однако в экспериментальных данных, полученных с помощью координатно-трековой установки на дрейфовых камерах (КТУДК), среди полезных сигналов наблюдаются послеимпульсы, которые приводят к ложным реконструкциям. Для решения этой проблемы разрабатывается новый метод с использованием глубокого обучения. В работе представлены результаты разработки этого метода и его применения к моделированным данным.

*Ключевые слова:* космические лучи, дрейфовая камера, мюоны, машинное обучение, глубокое обучение

DOI: 10.56304/S2079562920060603

## 1. ВВЕДЕНИЕ

В НИЯУ МИФИ разрабатывается новый крупномасштабный координатно-трековый детектор ТРЕК [1] на основе многопроволочных дрейфовых камер. Совместная работа черенковского водного калориметра НЕВОД [2] и ТРЕК позволит исследовать наблюдаемый в экспериментах избыток числа мюонов в широких атмосферных ливнях [3], генерируемых первичными космическими лучами сверхвысоких энергий.

Используемые дрейфовые камеры разработаны в ИФВЭ и применялись для нейтринных экспериментов на ускорителе У-70 [4]. В этих экспериментах плотность регистрируемых частиц была относительно низкой, и реконструкция событий не вызывала больших сложностей. Однако в космических лучах сверхвысоких энергий могут регистрироваться и исследоваться события со значительно большей плотностью заряженных частиц.

Ранее на координатно-трековой установке на дрейфовых камерах (КТУДК) [5] были применены такие методы реконструкции, как метод перебора, поиска прямолинейного участка и гистограммирования [6]. Последний был разработан с целью поиска и реконструкции параллельных треков. Так как задача установки ТРЕК — исследование ква-

зипараллельных групп мюонов, то этому методу было отдано предпочтение. Тем не менее, из-за наличия в экспериментальных данных послеимпульсов и вторичных треков метод гистограммирования приводит к ложным реконструкциям. В силу сложности реконструкции многочастичных событий по данным отдельной дрейфовой камеры разрабатывается новый подход для обработки данных на основе машинного обучения.

## 2. ФИЛЬТРАЦИЯ СИГНАЛОВ С ПОМОЩЬЮ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

Главная сложность обработки данных с дрейфовых камер — это то, что одному сигналу соответствуют две точки в пространстве (рис. 1). Так как сигнальные проволоки расположены в центре дрейфовой камеры, а время дрейфа не может быть отрицательным, то во время реконструкции возникает задача определения стороны камеры, через которую прошла частица. Сигнальные проволоки попарно смещены относительно центра, поэтому на той стороне, где прошла частица, точки будут лучше лежать на прямой, чем с противоположной.

Для одночастичных событий определение нужных точек не вызывает проблем, в то время как с ро-

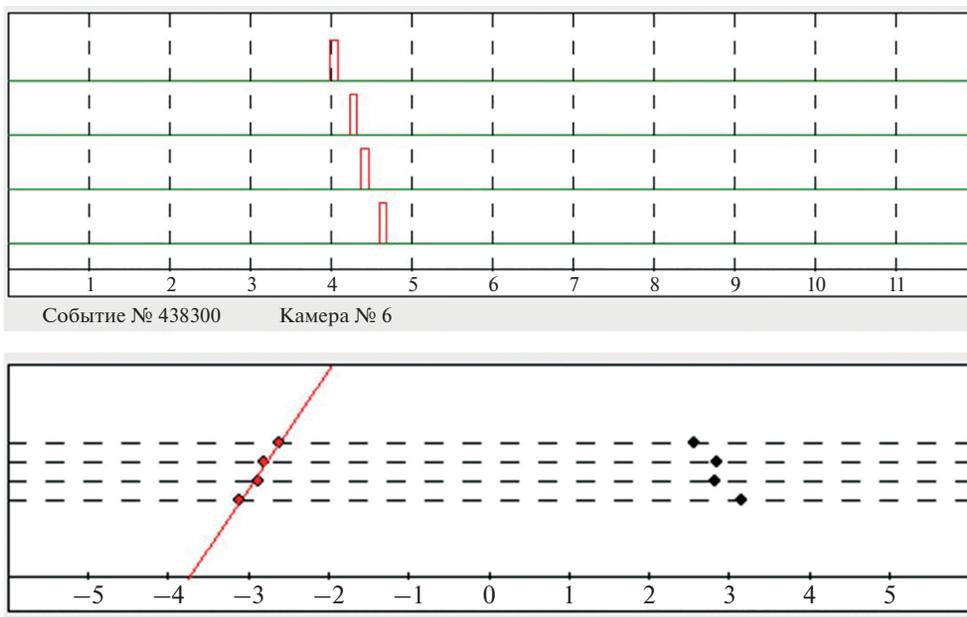


Рис. 1. Сигналы от одиночного трека (сверху) и точки на плоскости дрейфовой камеры (снизу).

0	0	0	1	1	1	0	0	0	0	0	0
0	0	0	0	1	1	1	0	0	0	0	0
0	0	0	0	0	1	1	1	0	0	0	0
0	0	0	0	0	0	1	1	1	0	0	0

Рис. 2. Часть изображения с представлением данных с дрейфовой камеры в виде бинарной матрицы.

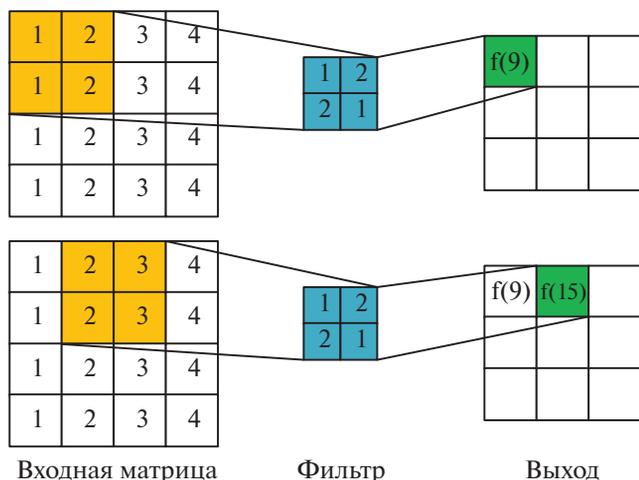
стом числа прошедших через камеру частиц задача усложняется тем, что необходимо понять к какому треку принадлежит та или иная точка. В такой ситуации рассматривать именно точки становится неудобно, и более целесообразно анализировать сигналы на временной развертке, которые более удобно использовать для распределения по трекам. Поэтому для реконструкции событий с помощью искусственных нейронных сетей будут рассматриваться не точки, как это обычно делается, а времена дрейфа.

Временную развертку можно представить в виде матрицы  $4 \times 600$  (рис. 2), где 4 – количество сигнальных каналов, 600 – число столбцов, каждый из которых представляет собой 10-наносекунд-

ный интервал (максимальное время дрейфа электронов в камере 6 мкс). Нули в такой матрице означают отсутствие сигнала, единицы – его наличие.

Для работы с матрицами (изображениями) себя отлично зарекомендовали сверточные нейронные сети [7]. В основе сверточных нейронных сетей лежат 2 слоя: сверточный и субдискретизации.

В первом слое происходит свертка входных тензоров с применением фильтров (ядер). Пусть имеется фильтр в виде матрицы с размерами  $n \times m$ . Проводится свертка каждого участка изображения тех же размеров с фильтром (рис. 3). Каждый результат свертки (число) подается на функцию активации  $f(x)$ . В данном случае элементы фильтра играют роль весовых коэффициентов. Результат



**Рис. 3.** Процесс свертки с использованием фильтра размера  $2 \times 2$ .

свертки всего изображения носит название карты признаков.

Слой субдискретизации (англ. pooling) позволяет еще больше уменьшить размеры полученных данных (карты признаков). Карта признаков делится на одинаковые участки определенного размера. Среди элементов этих участков выделяется один с определенными признаками. Чаще всего выбирается элемент с наибольшим значением.

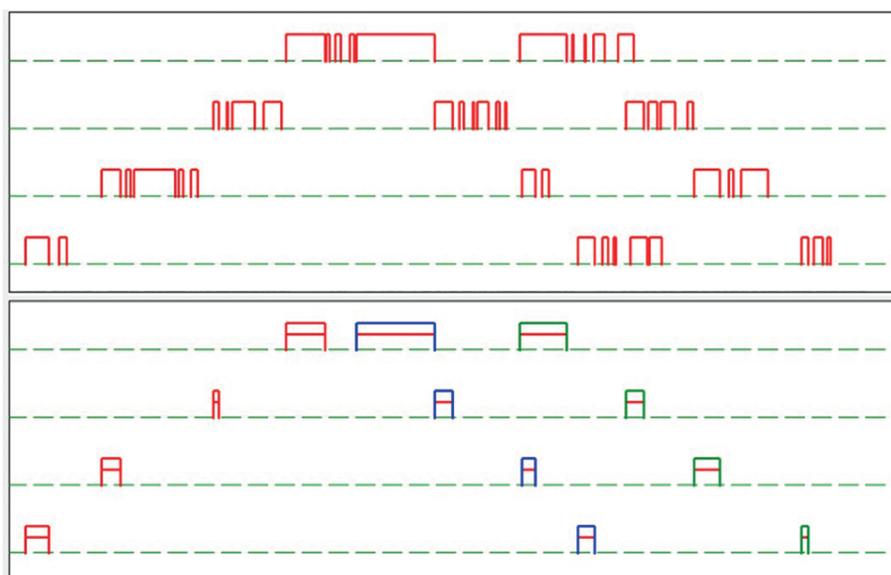
Совокупность слоев свертки и субдискретизации, а также слоев, выполняющих обратную операцию, была применена для фильтрации сигналов во временных развертках. На вход такого фильтра по-

дается изображение с послеимпульсами, а на выходе ожидается изображение без послеимпульсов.

Для обучения и тестирования такой нейронной сети было проведено моделирование в среде Garfield++ [8] – программного обеспечения, позволяющего детально моделировать работу газовых детекторов. Для дрейфовых камер установки ТРЕК важно, что данная среда позволяет разыгрывать ионизацию при прохождении заряженных частиц, дрейф высвобождающихся электронов и токовый сигнал при достижении электронами сигнальных проволок. В процессе моделирования для каждого события определяются первые сигналы от каждого отдельного трека, по которым его надо реконструировать, и послеимпульсы.

Результат работы фильтра представлен на рис. 4. Сверху показана временная развертка с сигналами от трех прошедших треков через камеру. Снизу изображена временная развертка на выходе нейронной сети.

На выходе нейронной сети отдельный элемент матрицы может принимать значения от 0 до 1. Поэтому необходимо определить порог, ниже которого сигнал считается исключенным. При испытании на тестовой выборке значение порога было выбрано таким, что сеть исключает в этой выборке 85% послеимпульсов, сохраняя 94% полезных сигналов. И, как видно из рис. 4, это приводит к существенному упрощению реконструкции событий.



**Рис. 4.** Применение фильтра на основе машинного обучения.

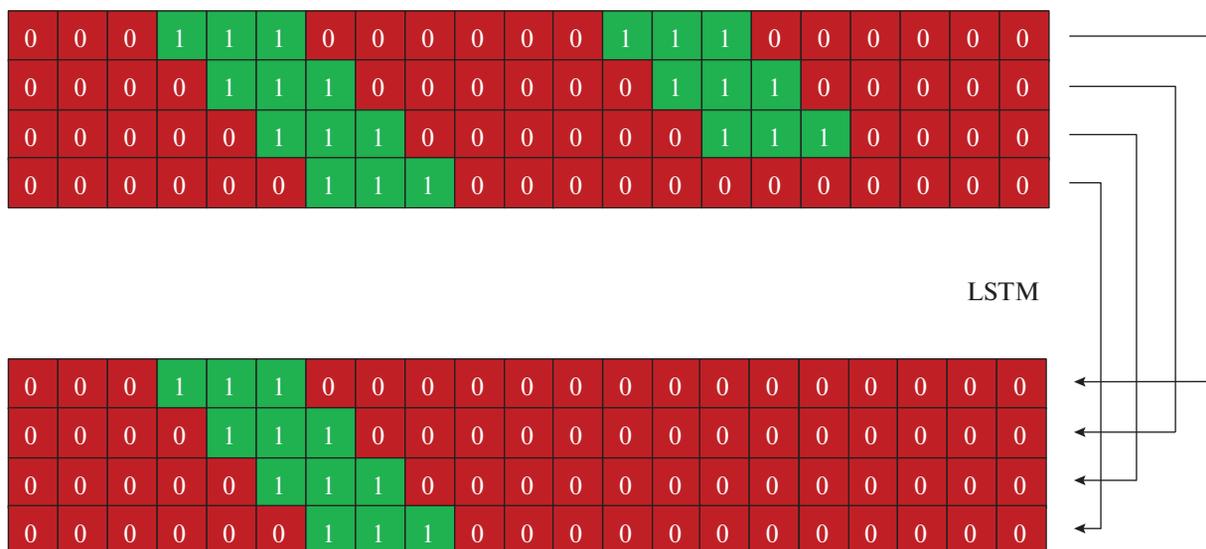


Рис. 5. Сравнение работы метода гистограммирования с фильтром и без.

### 3. РЕКОНСТРУКЦИЯ ТРЕКОВ С ПОМОЩЬЮ РЕКУРРЕНТНОЙ НЕЙРОННОЙ СЕТИ

Применение фильтра исключает большую долю всех послеимпульсов в тестовых событиях. Однако такой фильтр решает лишь одну проблему реконструкции. Вторичные треки даже в отфильтрованных событиях остаются проблемой, так как фильтр не позволяет качественно от них избавиться. Поэтому необходимо разработать новый метод реконструкции, способный их учитывать.

За основу нового метода взяты рекуррентные нейронные сети – разновидность нейронных сетей, в которых выход на предыдущем этапе работы поступает на вход на следующем этапе. Таким образом, сеть может запоминать информацию с предыдущих итераций. Такая сеть отлично зарекомендовала себя для работы с временными рядами. Существуют разные сети, реализованные на таком принципе. Однако самыми популярными являются long short-term memory (LSTM) [9], которые способны выделять нужную информацию для краткосрочного или долгосрочного хранения во времени.

Новый метод основан на работе коллаборации Нер.TrkX [10]. На первом сигнальном канале фиксируется только один сигнал, а остальные исключаются из входной матрицы (рис. 5). После чего такое изображение послойно поступает на LSTM модуль. Задача сети – оставить только те сигналы, которые принадлежат треку с фиксированным в начале сигналом.

Такая сеть обучалась на моделированных с помощью Garfield++ многочастичных событиях. Пример работы такого метода продемонстрирован на рис. 6. По своей сути такой метод сводит реконструкцию всего события к отдельным реконструк-

циям одночастичных событий, к которым уже можно применить метод перебора.

Проведено сравнение реконструкций с помощью метода гистограммирования с применением фильтра и без, а также метода на основе рекуррентных сетей. Для это с помощью Garfield++ моделировались события с множественностью от 2 до 5 параллельных мюонов под проекционными углами от 0° до 45°. Вдобавок моделировались вторичные треки частиц, проекционный угол которых отличался от угла группы минимум на 10°. Число вторичных треков в отдельном событии разыгрывалось равномерно в интервале от 0 до 2. Для каждой комбинации угла и множественности проведено моделирование 100 событий.

Для каждого набора построены распределения по величине разницы между числом запущенных и реконструированных параллельных треков, рассчитано стандартное отклонение. На рис. 7 приведена зависимость стандартного отклонения от проекционного угла для двух треков на дрейфовую камеру (слева) и пяти треков (справа). Как видно из рисунка, метод на основе рекуррентных нейронных сетей показал лучший результат.

Анализ показывает, что при малых значениях проекционного угла высокая точность определения множественности параллельных треков с помощью метода на основе рекуррентных сетей сохраняется и для большего числа треков на дрейфовую камеру. Основной причиной увеличения числа ошибок в определении множественности при больших углах является слияние сигналов от отдельных треков. На данный момент плотность мюонов, при которой число частиц с использованием нового подхода определяется с точностью до единицы, составляет приблизительно 5 частиц

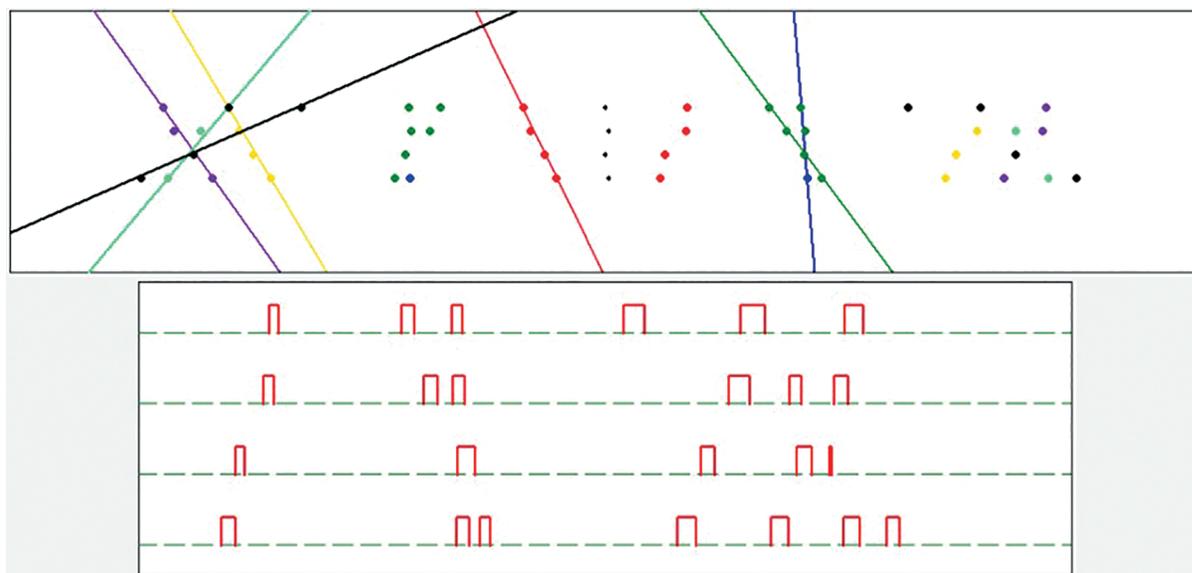


Рис. 6. Реконструкция события с помощью нейронной сети.

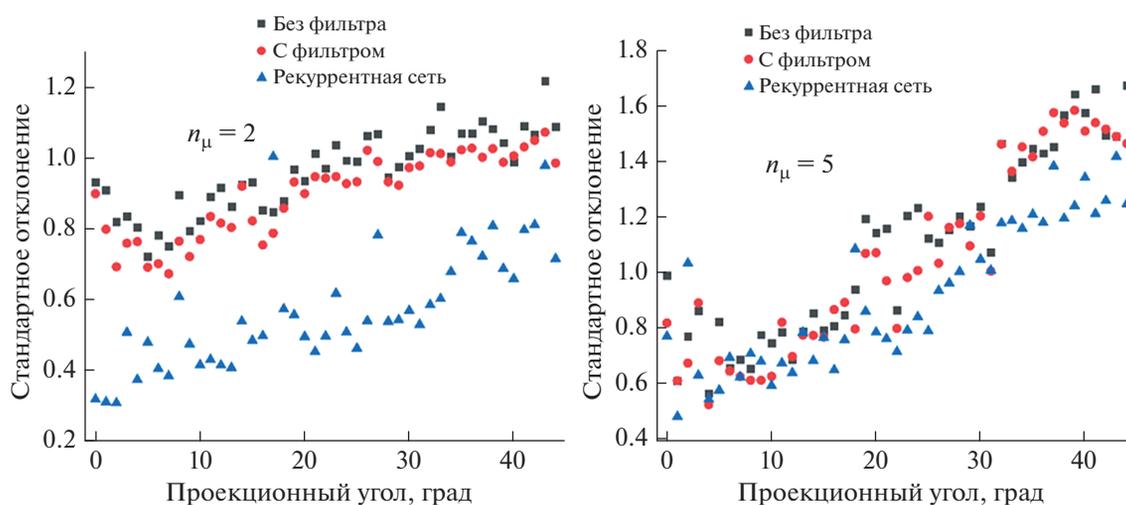


Рис. 7. Стандартные отклонения разниц между числом смоделированных и числом реконструированных параллельных треков в зависимости от проекционного угла при множественности мюонов 2 (слева) и 5 (справа).

на кв. м. Тем не менее, планируется достичь лучшей точности реконструкции с новым подходом до плотностей около 10 частиц на кв. м.

### ЗАКЛЮЧЕНИЕ

С ростом мощностей вычислительных технологий в физике высоких энергий все чаще и чаще начинают применять методы машинного обучения для обработки огромных и сложных массивов данных. Методы нейронных сетей отлично себя проявляют в различных задачах по качеству и скорости обработки.

Для дрейфовых камер установки ТРЕК разработан новый подход к обработке данных с помощью сверточных и рекуррентных нейронных сетей. Такой подход позволяет исключать из данных 85% послеимпульсов и реконструировать с высокой точностью события с плотностью заряженных частиц до 5 на кв. м. Подход демонстрирует преимущества перед уже существующими методами реконструкции.

В дальнейшем новый подход будет применен к экспериментальным данным, полученным на установках КТУДК и прототипе ТРЕК.

БЛАГОДАРНОСТИ

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 20-32-90155.

СПИСОК ЛИТЕРАТУРЫ/REFERENCES

1. Zadeba E.A. et al. // J. Instrum. 2014. V. 9. P. C08018.
2. Petrukhin A.A. // Phys. Usp. 2015. V. 58. P. 486–494.
3. Petrukhin A.A. // Nucl. Instrum. Methods Phys. Res., Sect. A. 2012. V. 692. P. 228–232.
4. Barabash L.S. et al. // Proc. Int. Conf. Neutrino-82. 1982. V. 2. P. 249
5. Vorobyev V.S. et al. // J. Phys.: Conf. Ser. 2018. V. 945. P. 012027.
6. Воробьев В.С., Борисов А.А., Волков Н.С., Задеба Е.А., Кожин А.С., Петрухин А.А., Фахрутдинов Р.М., Яшин И.И. // Ядерная физика и инжиниринг. 2017. Т. 8. № 4. С. 344–352 [Vorobyev V.S., Borisov A.A., Volkov N.S., Zadeba E.A., Kozhin A.S., Petrukhin A.A., Fakhrutdinov R.M., Yashin I.I. // Phys. At. Nucl. 2018. V. 81. P. 1325].
7. Nebauer C. // IEEE Trans. Neural Networks. 1998. V. 9. P. 685–696. <https://doi.org/10.1109/72.701181>
8. Garfield++. <https://garfieldpp.web.cern.ch/>.
9. Hochreiter S. et al. // Neural Comput. 1997. V. 9. P. 1735–1780.
10. Farrell S. et al. // EPJ Web Conf. 2017. V. 150. P. 00003.

## Applying Deep Learning Techniques for Multiparticle Track Reconstruction of Drift Chamber Data

V. S. Vorob'ev<sup>1</sup>, \*, E. A. Zadeba<sup>1</sup>, R. V. Nikolaenko<sup>1</sup>, A. A. Petrukhin<sup>1</sup>, and I. Yu. Troshin<sup>1</sup>

<sup>1</sup>National Research Nuclear University MPhI (Moscow Engineering Physics Institute), Moscow, 115409 Russia

\*e-mail: VSVorobev@mephi.ru

Received March 4, 2021; revised May 11, 2021; accepted May 12, 2021

**Abstract**—The new coordinate-tracking detector TREK, based of drift chambers, is being developed at NR-NU MPhI for studies of ultrahigh energy cosmic rays. To reconstruct events with a high multiplicity from the data of drift chambers, the histogram method is currently used, which is designed to search for parallel tracks. However, we observe afterpulses in the experimental data obtained using a coordinate-tracking unit based on drift chambers (CTUDC). The afterpulses lead to fake track reconstructions. To solve this problem, a new method is being developed using deep learning. The paper presents the results of the development of this method and its application to simulated data.

*Keywords:* cosmic rays, drift chamber, muons, machine learning, deep learning