

РАЗРАБОТКА И ИССЛЕДОВАНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ БЫСТРОЙ РЕКОНСТРУКЦИИ ТРЕКОВ ЧАСТИЦ

Чернов Андрей Максимович¹, Ершов Николай Михайлович²

¹Студент;

Московский государственный университет им. М. В. Ломоносова;
Россия, 119991, г. Москва, ул. Ленинские горы, 1;
e-mail: dnscookie@gmail.com.

²Кандидат физико-математических наук, доцент;

Московский государственный университет им. М. В. Ломоносова;
Россия, 119991, г. Москва, ул. Ленинские горы, 1;
e-mail: ershov@cs.msu.ru.

Работа посвящена разработке эффективных методов решения задачи восстановления треков (траекторий движения) частиц, порождаемых столкновением ускоренных заряженных частиц или атомных ядер с неподвижной мишенью. Важными свойствами данной задачи являются: необходимость её решения в режиме реального времени; большие объёмы обрабатываемых данных; значительный уровень зашумлённости этих данных, обусловленный особенностями устройства трековых детекторов. Для решения поставленной задачи предлагается три метода: на основе преобразования Хафа, с использованием технологии самоорганизующихся карт Кохонена и графовых нейронных сетей. Приводятся результаты численного исследования предложенных методов при решении модельной задачи трекинга частиц.

Ключевые слова: трекинг частиц, преобразование Хафа, самоорганизующиеся карты Кохонена, графовые нейронные сети.

Для цитирования:

Чернов А. М., Ершов Н. М. Разработка и исследование нейросетевых алгоритмов быстрой реконструкции треков частиц // Системный анализ в науке и образовании: сетевое научное издание. 2025. № 2. С. 66-72. EDN: LXYCCE. URL: <https://sanse.ru/index.php/sanse/article/view/666>.

DEVELOPMENT AND RESEARCH OF NEURAL NETWORK ALGORITHMS FOR FAST RECONSTRUCTION OF PARTICLE TRACKS

Chernov Andrey M.¹, Ershov Nikolay M.²

¹Student;

Lomonosov Moscow State University;
1 Leninskiye Gory, Moscow, 119991, Russia;
e-mail: dnscookie@gmail.com.

²PhD in Physical and Mathematical Sciences, associate professor;

Lomonosov Moscow State University;
1 Leninskiye Gory, Moscow, 119991, Russia;
e-mail: ershov@cs.msu.ru.

The paper is devoted to the development of effective methods for solving the problem of reconstruction particles tracks (trajectories of motion), generated by the collision of accelerated charged particles or atomic nuclei with a stationary target. Important properties of this problem are: the need to solve it in real time; large volumes of processed data; a significant level of noise in this data due to the features of the design of track detectors. To solve this problem, three methods are proposed: based on the Hough transform, using the



Статья находится в открытом доступе и распространяется в соответствии с лицензией Creative Commons «Attribution» («Атрибуция») 4.0 Всемирная (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0/deed.ru>

technology of self-organizing Kohonen maps and graph neural networks. The results of a numerical study of the proposed methods in solving a model problem of particle tracking are presented.

Keywords: particle tracking, Hough transform, self-organizing Kohonen maps, graph neural networks.

For citation:

Chernov A. M., Ershov N. M. Development and research of neural network algorithms for fast reconstruction of particle tracks. *System analysis in science and education*, 2025; (2): 66-72 (in Russ). EDN: LXYCCE. Available from: <https://sanse.ru/index.php/sanse/article/view/666>.

Введение

Физика элементарных частиц (ФЭЧ), иначе называемая физикой высоких энергий (ФВЭ), изучает фундаментальные свойства материи, стремясь объяснить структуру и свойства элементарных частиц, их рождение и уничтожение, а также ответить на вопросы о происхождении Вселенной [1]. Для этого проводятся эксперименты по изучению известных частиц и поиску новых [2]. Эти эксперименты включают использование ускорителей частиц, где заряженные частицы и атомные ядра разгоняются до энергий порядка 10 ТэВ. Столкновения пучков ускоренных частиц с мишенью или друг с другом приводят к взаимодействиям, создающим новые элементарные частицы. Такие исследования могут привести к открытию новых частиц или выявлению необычных свойств известных частиц [3]. На ускорителях частиц для проведения исследований создают экспериментальные установки, предназначенные для экспериментов определённого рода. Важнейшей частью таких установок являются трековые детекторы, позволяющие определять координаты прохождения через них заряженных частиц, порождаемых экспериментом. Имея данные о магнитном поле, влиявшем на частицы, по кривизне траекторий их движения можно сделать вывод об их заряде, импульсе и так далее [4].




Рис. 1. Схематический вид установки BM@N

В современных экспериментах ФВЭ количество порождаемых частиц таково, что объёмы данных, генерируемых детекторами, невозможно быстро обрабатывать классическими методами, а с течением времени эти объёмы будут только расти [5]. Исследование современных методов решения задачи реконструкции треков частиц позволит разработать методы, которые лучше масштабируются и позволяют быстро обрабатывать необходимый объём данных. Примером такого эксперимента является эксперимент BM@N проекта NICA на базе Объединённого института ядерных исследований (ОИЯИ) в Дубне, представляющий собой детекторную установку для экспериментов с неподвижной мишенью [6]. За полтора месяца первого запуска в эксперименте было зарегистрировано более 500 млн. событий, т. е. в среднем более 100 событий в секунду [7]. Целью настоящей работы является разработка и исследование алгоритмов, которые смогут обрабатывать данные экспериментов ФВЭ (в частности, эксперимента BM@N) с высокой скоростью и точностью.

В настоящей работе предлагается подход к решению задачи трекинга частиц с использованием нейросетевых моделей, известных высокой степенью параллелизма и хорошим масштабированием при обработке больших объёмов данных. Важной особенностью эксперимента BM@N, существенно

влияющей на выбор и настройку методов решения задачи трекинга, является то, большая часть треков частиц, возникающих в данном эксперименте, движутся по прямым линиям [8].

1. Модельная задача трекинга

В экспериментах ФВЭ факт столкновения двух пучков заряженных частиц или пучка заряженных частиц с неподвижной мишенью называется событием, а точка в пространстве, в которой произошло столкновение – вершиной события. В результате столкновения образуются новые частицы, которые фиксируются детекторными приборами, данные с которых обрабатываются, чтобы получить набор координат точек, через которые прошла каждая частица. Эти точки называют хитами (от англ. *hit* – удар, попадание), а набор хитов, принадлежащий одной частице, называют треком (от англ. *track* – путь, след). Не все хиты, получаемые с детектора, принадлежат трекам частиц, поэтому хиты делят на истинные и ложные, называемые фейками (от англ. *fake* – ложный). Рис. 2 показывает устройство стрипового детектора, который может выдавать $O(n^2)$ ложных хитов на n истинных.




Рис. 2. Иллюстрация обработки данных с детектора стрипового типа [9]

Задача трекинга заключается в том, чтобы из набора хитов, зафиксированных для данного события, выделить истинные и сгруппировать их по принадлежности тому или иному треку. Различают локальный и глобальный трекинг: в случае локального трекинга восстановление каждого трека происходит независимо хит за хитом, в то время как в случае глобального трекинга алгоритм пытается распознать треки, принимая в расчёт полную картину события.

Для проведения численных экспериментов по эффективности работы исследуемых методов трекинга была разработаны модельные двумерная и трёхмерная задачи (рис. 3), симулирующие прохождение заряженных частиц через систему линейных или плоских детекторов по траекториям, заданным прямыми линиями. Случайным способом создаются K треков, исходящих из одной общей точки события. Определяются точки прохождения треков через детекторы (истинные хиты), при этом небольшая доля $m \in [0, 1]$ этих хитов пропускается, симулируя несрабатывания детекторов. К истинным хитам добавляются шум в виде gK^2 ложных хитов, не принадлежащих ни одному из истинных треков. Итоговый набор хитов H в неупорядоченной форме подаётся на вход алгоритму трекинга.




Рис. 3. Примеры двумерной (слева) и трёхмерной (справа) модельных задач трекинга

Задача трекинга, таким образом, состоит в поиске исходных треков в наборе хитов H , т. е. в выделении в этом наборе кластеров, каждый из которых соответствует траектории движения одной из

частиц. Для количественного сравнения полученных кластеров (предсказанных треков) с эталонными (истинными треками) используется F_1 -мера – среднее гармоническое точности (*precision*) и полноты (*recall*). Такой подход одновременно штрафует за ложные треки (ложноположительные кластеры) и пропущенные треки (ложноотрицательные кластеры).

2. Метод Хафа

Преобразование Хафа (*Hough Transform*) – классический метод компьютерного зрения для обнаружения параметрических геометрических фигур. В основе метода лежит преобразование пространства изображения в параметрическое пространство, где поиск объектов сводится к анализу локальных максимумов в аккумуляторном массиве. Преобразование Хафа широко применяется для реконструкции треков заряженных частиц в экспериментах ФВЭ [10].

В ходе настоящей работы была разработана адаптация преобразования Хафа для модельной задачи для двумерного и трёхмерного случаев. Одной из ключевых особенностей адаптации по сравнению с классической версией алгоритма является то, что рассматриваются только прямые, проходящие через вершину события, что позволяет уменьшить размерность пространства Хафа для трёхмерного случая.

Пусть (x, y, z) – координаты некоторого хита, а (x_c, y_c, z_c) – координаты вершины события. Тогда прямая, проходящая через этот хит и вершину, может быть представлена вектором направления, который описывается двумя углами: $\theta \in [0, \pi]$ – угол между направлением прямой и осью OZ (аналог полярного угла в сферических координатах); $\varphi \in [0, 2\pi]$ – азимутальный угол между проекцией прямой на плоскость XY и осью OX . Таким образом, построение пространства Хафа в трёхмерном случае сводится к дискретизации единичной полусферы (или её части, если геометрия задачи позволяет сузить диапазоны углов). Для этого пространство (θ, φ) разбивается на прямоугольную сетку с заданными степенями квантования по соответствующим измерениям. Каждый хит вносит вклад в ячейку этой сетки, соответствующую направлению от центра события к данному хиту. Как и в двумерном случае, итогом является двумерный аккумуляторный массив, в котором накоплено количество хитов, попадающих в каждый из диапазонов направлений. После обработки всех хитов локальные максимумы в этом аккумуляторе соответствуют прямым, вдоль которых сконцентрировано наибольшее число хитов – с высокой вероятностью это и есть искомые треки.

Такой подход, ориентированный на фиксированную вершину события, позволяет избежать необходимости параметризовать смещение прямой в пространстве и тем самым существенно снизить размерность пространства поиска. Это приводит к значительному снижению вычислительной и пространственной сложности алгоритма по сравнению с классическим вариантом, в котором каждая прямая в трёхмерном пространстве требует более сложной параметризации, например через точку и направление или четыре угла и смещение.

3. Метод самоорганизующихся карт Кохонена

Метод самоорганизующихся карт Кохонена (*Self-Organizing Maps, SOM*) представляет собой один из классических алгоритмов обучения без учителя, предназначенный для проекции многомерных данных в упрощённое, чаще всего двумерное, отображение [11]. Модель была предложена Теуво Кохоненом и вдохновлена принципами организации нейронных систем головного мозга, где пространственная близость нейронов соответствует близости обрабатываемых стимулов и образов. Изначально *SOM* разрабатывались для задач кластеризации и визуализации данных большой размерности, однако со временем нашли применение и в более широком спектре задач: детекции аномалий, анализе медицинских изображений, управлении робототехническими системами и др.

Архитектурно *SOM* представляет собой сетку (обычно двумерную) нейронов, каждый из которых представляет собой вектор весов той же размерности, что и входные данные. Обучение начинается с инициализации весов нейронов: это могут быть случайные значения или небольшой набор точек из исходной выборки. Далее алгоритм итеративно проходит по всей обучающей выборке: для каждого входного вектора вычисляется «ближайший» к нему нейрон (*Best Matching Unit, BMU*), а затем веса *BMU* (и его соседей из некоторой окрестности) обновляются, «приближаясь» к данному входному вектору. В результате многократного обновления карта «растягивается» и «складывается» таким образом, чтобы смоделировать топологию исходного пространства данных. Выходом *SOM* служит

пространственное распределение нейронов с их весами, на основе которого строится тепловая карта расстояний от каждого входного вектора до нейронов, являющаяся наглядным инструментом для изучения кластерной структуры и выявления аномалий.

Алгоритм карт Кохонена для решения трёхмерной задачи трекинга включает следующие этапы:

1. Инициализация нейронов, при которой они равномерно распределяются по сферическим координатам (θ, φ) .
2. Предобработка хитов, состоящая из их центрирования относительно вершины событий и нормировке.
3. Обучение с учётом слоёв: хиты группируются по координате z , таким образом, алгоритм может одновременно обрабатывать все хиты с определённого детекторного слоя; слои детекторов обрабатываются последовательно (в прямом или обратном порядке); для каждого слоя определяются нейроны-победители для каждого хита; для каждого нейрона хиты, на которых он активировался, складываются, эта сумма нормируется, и нейрон обучается.
4. Формирование кластеров: каждому хиту назначается нейрон-победитель; для каждого нейрона составляется кластер хитов, на котором он активировался; возвращаются кластеры, в которых не менее T хитов.

4. Графовые нейронные сети

Графовая нейронная сеть (*GNN*) – это вид нейронной сети, предназначенный для работы с графовыми данными [12]. Метод трекинга, основанный на применении графовых нейронных сетей, состоит из четырёх этапов. На первом этапе выполняется построение графа эксперимента $G = (V, E)$: каждому хиту в соответствии ставится вершина графа, представляемая вектором координат этого хита. Рёбрами соединяются вершины на соседних детекторных слоях. На втором этапе представление каждой вершины уточняется с учётом представлений её соседей в графе, проходя через несколько слоёв графовой нейронной сети. На третьем шаге алгоритма для каждого ребра конкатенируются представления вершин, которые им соединены, формируя представление этого ребра, которое подаётся на многослойный перцептрон (*MLP*), выходом которого является вероятность того, что ребро соединяет хиты, принадлежащие одному треку. На последнем этапе производится формирование искоемых треков: выделяется множество рёбер, получивших достаточно высокую оценку на предыдущем шаге, все остальные ребра удаляются из графа, в полученном подграфе выделяются компоненты связности, каждая из которых соответствует некоторому треку.




Рис. 4. Архитектура графовой нейронной сети для решения задачи трекинга

Для решения трёхмерной задачи трекинга использовалась модель графовой нейронной сети со следующими значениями параметров (рис. 4): размерность скрытых слоёв *GNN* – 32, количество голов внимания слоёв *GNN* – 8, число слоёв *GNN* – 3, размерность выхода первого слоя *MLP* – 32, коэффициент *dropout* при обучении *MLP* – 0.05. Для начальной скорости обучения Adam было

установлено значение 0.005, вес положительного класса для взвешенного BCS был установлен равный 1. Параметры были подобраны эмпирически, при этом учитывались: сходимость, размер модели, итоговая F_1 -мера на тестовой выборке. Итоговый размер модели – 28961 параметр. Модель обучалась на 200 эпохах.

5. Численное исследование

Основные исследования проводились на модельных трёхмерных задачах с числом частиц $K = 7$, числом детекторов $N = 10$, уровнем шума $g = 0.4$, среднеквадратичным отклонением регистрации хитов $\sigma = 0.003$, вероятностью пропуска истинного хита $m = 0.05$. Оптимальные параметры методов Хафа и Кохонена подбирались с помощью метода дифференциальной эволюции из библиотеки *SciPy* путём минимизации F_1 -меры на отдельных выборках из 100 сгенерированных модельных задач. Оптимальные параметры для метода реконструкции вершины также подбирались с помощью того же метода дифференциальной эволюции путём минимизации суммарной ошибки предсказания положения этой вершины. Усреднённая ошибка при полученных оптимальных параметрах составила 0.023.

Табл. 1. Результаты сравнения методов трекинга по времени вычислений и точности

Метод	Время, с	Мера F_1
метод Хафа	0.00039	70.60 %
карты Кохонена	0.00452	85.66 %
графовые нейронные сети	0.00672	93.17 %

Все три метода были запущены на 10 000 модельных задачах с последующим усреднением полученных показателей времени работы и оценки качества. Вершины события были восстановлены на этапе предобработки данных, поэтому время работы соответствующей функции при вычислении времени работы самих методов не учитывалось. В таблице 1 приведены обобщённые результаты данного эксперимента.




Рис. 5. Зависимость времени (слева) и точности (справа) методов трекинга от уровня шума g

На рис. 5 приведены графики зависимости времени и метрики F_1 от уровня шума в модельных задачах g , усреднённые на 1000 модельных задачах.

Заключение

Проведённое сравнение предложенных методов восстановления треков по модельным данным позволило выявить их ключевые особенности: метод на основе классического преобразования Хафа отличается наименьшим временем работы, что делает его особенно привлекательным для задач с жёсткими ограничениями по вычислительным ресурсам. Однако, это достигается за счёт снижения качества реконструкции треков частиц; метод на основе самоорганизующихся карт Кохонена демонстрирует более высокое качество по сравнению с методом Хафа при умеренном увеличении времени работы. Он представляет собой сбалансированное решение, подходящее для случаев, когда требуется разумный компромисс между точностью и производительностью; метод на основе графовых нейронных сетей (*GNN*) показывает наилучшие результаты по метрикам качества, при этом показывая большую устойчивость к шуму, чем другие два метода. Однако при этом он требует наибольших вычислительных затрат.

Таким образом, выбор метода должен основываться на требованиях конкретной задачи: приоритет вычислительной эффективности оправдывает применение метода Хафа, стремление к максимальной точности – использование графовых нейронных сетей, тогда как метод Кохонена может быть использован в качестве универсального компромиссного варианта.

Список источников

1. Review of Particle Physics / S. Navas, C. Amsler, T. Gutsche [и др.] // *Physical Review D*. – 2024. – Т. 110, № 3. – С. 030001. – DOI: 10.1103/PhysRevD.110.030001.
2. Kobayashi T. Experimental verification of the standard model of particle physics // *Proceedings of the Japan Academy, Series B*. – 2021. – Т. 97, № 5. – С. 211–235. – DOI: 10.2183/pjab.97.013.
3. Shiltsev V., Zimmermann F. Accelerator Physics of Colliders // *Review of Particle Physics*. 2024. – Т. 110, № 3. – С. 030001. – DOI: 10.1103/PhysRevD.110.030001.
4. Tracking Detectors / R. Fruhwirth, M. Regler, R. K.Bock [и др.] // *Particle Physics Reference Library*. Springer, 2021. – С. 1–56. – DOI: 10.1007/978-3-030-65771-0_1.
5. Gligorov V. V., Rekovic V. Review of real-time data processing for collider experiments // *European Physical Journal Plus*. – 2023. – Т. 138. – С. 1005. – DOI: 10.1140/epjp/s13360-023-04599-6.
6. BM@N experiment – BM@N : [официальный сайт]. – BM@N, 2025. – URL: <https://bmj.jinr.int/bmn-experiment/> (дата обращения: 16.05.2025).
7. ИЯИ РАН - эксперимент на установке BM@N / Институт ядерных исследований РАН. – URL: <https://www.inr.ru/rus/2023/exp-bmn.html> (дата обращения: 16.05.2025).
8. Tracking system performance of the BM@N experiment / M. Kapishin, V. Lenivenko, V. Palichik [и др.] // *EPJ Web of Conferences*. – 2019. – Т. 214. – С. 02021. – DOI: 10.1051/epjconf/201921402021.
9. Landi G., Landi G.E. Silicon micro-strip detectors // *Encyclopedia*. – 2021. – Т. 1, №. 4. – С. 1076–1083. – DOI: 10.3390/encyclopedia1040082.
10. Gabrielli A., Alfonsi F., Del Corso F. Hough Transform Proposal and Simulations for Particle Track Recognition for LHC Phase-II Upgrade // *Sensors*. – 2022. – Т. 22, №. 5. – С. 1768. – DOI: 10.3390/s22051768.
11. Guerin A., Chauvet P., Saubion F. A Survey on Recent Advances in Self-Organizing Maps // *arXiv preprint arXiv:2501.08416 [cs.NE]*. – 2024. – DOI: 10.48550/arXiv.2501.08416.
12. Duarte J., Vlimant J.-R. Graph Neural Networks for Particle Tracking and Reconstruction // *Artificial Intelligence for High Energy Physics*. – World Scientific Publishing, 2022. – С. 387–436. – DOI: 10.1142/9789811234033_0012.