

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»

УДК 531.3, 539.1.05

ОТЧЕТ
О НАУЧНО-ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЕ
**РЕКОНСТРУКЦИЯ СИГНАЛОВ В ДЕТЕКТОРЕ FARICH
УСТАНОВКИ SPD НА КОЛЛАЙДЕРЕ NICA**

Научный руководитель

к. ф-м. н.

Студент

_____ А. С. Жемчугов

_____ К. Ю. Массалов

Москва 2024

СОДЕРЖАНИЕ

Введение	3
1 Экспериментальная установка Spin Physics Detector на строящемся в ОИЯИ коллайдере NICA	4
1.1 Конструкция детектора	4
1.2 FARICH	5
2 Алгоритмы распознавания колец	6
2.1 Разделение частиц по вторым моментам	6
2.2 Итерационный метод	6
2.3 Отношение функций максимального правдоподобия	6
2.4 Метод масок	6
2.5 Нечеткая кластеризация	6
2.6 Преобразование Хафа	7
2.7 COP	7
2.8 Фитирование эллипса	7
3 Моделирование детектора	8
3.1 GEANT4	8
3.2 Моделирование детектора и событий	8
4 Применение нейросетевых методов	9
4.1 Сверточные нейронные сети	9
4.2 Постановка задачи	10
4.3 Вариант 1	10
4.3.1 Архитектура	10
4.3.2 Результаты	11
4.4 Вариант 2	12
4.4.1 Архитектура	12
4.4.2 Результаты	12
5 Устойчивость к шуму	12
5.1 Без дополнительной очистки	13
5.2 С дополнительным этапом очистки	13
5.3 Объединение предыдущих двух подходов	13
5.4 Финальное сравнение	14
Заключение	15
Список использованных источников	16

ВВЕДЕНИЕ

Относительный вклад видимой барионной материи во Вселенную составляет около 5% от общей массы. Хотя барионная материя представляется достаточно изученной, вопрос о том, почему нуклоны имеют именно такую структуру и свойства, остается открытым. Одним из главных нерешенных вопросов в квантовой хромодинамике (КХД) остается понимание структуры и основных свойств нуклонов исходя из динамики кварков и глюонов внутри них.

Нуклон обладает спином, который отвечает за его магнитный момент и другие свойства. Изучение спиновой структуры нуклонов является важной задачей. Центральной задачей является понимание того, как спин нуклона формируется из спинов и орбитальных моментов кварков и глюонов.

За последние 25 лет эксперименты по глубоко неупругому рассеянию (CERN, DESY, JLab, SLAC) и высокоэнергетические столкновения протонов (RHIC) были основными источниками информации о спиновых структурных функциях нуклонов. Наши знания о внутренней структуре нуклонов все еще ограничены, особенно в отношении глюонного вклада.

Spin Physics Detector — универсальная установка для исследования спиновой структуры нуклонов и других спиновых явлений. Установка будет использовать поляризованные пучки протонов и дейтронов. Проект основан на большом опыте работы с поляризованными пучками в ОИЯИ. Основная цель эксперимента - комплексное исследование неполяризованного и поляризованного глюонной составляющей нуклона. Измерения спина в SPD на коллайдере NICA откроют новые возможности для понимания спиновой структуры нуклона.

На установке планируется частота соударений до 4 МГц и число выходных каналов с детекторов ~ 700000 . Таким образом, ожидается поток данных примерно 20 Гбайт/с или 200 Пбайт/год. Такой объем информации необходимо уменьшать, избавляясь от неинформативных событий и шумов. Для этого планируется использовать онлайн-фильтр, представляющий собой высокопроизводительную систему, которая будет включать в себя гетерогенные вычислительные платформы, аналогичные многим высокопроизводительным вычислительным кластерам. Для реконструкции и отбрасывания неинтересных событий можно использовать методы машинного обучения, поскольку проблема классических алгоритмов в том, что они имеют невысокую скорость и плохо параллелятся, в отличие от нейронных сетей. Проблема же нейронных сетей в сложности интерпретации их решений: никогда нельзя знать наверняка, почему сеть выдала именно такой результат, и насколько она права.

Таким образом, планируется использовать нейронные сети и классические алгоритмы одновременно: первые обеспечат скорость работы, вторые позволят проверять правильность результатов нейросетей.

Цель работы состоит в создании нейросетевых методов реконструкции сигналов с детектора FARICH, изучении их характеристик и сравнении их с классическими подходами.

1 ЭКСПЕРИМЕНТАЛЬНАЯ УСТАНОВКА SPIN PHYSICS ДЕТЕКТОР НА СТРОЯЩЕМСЯ В ОИЯИ КОЛЛАЙДЕРЕ NICA

Коллаборация Spin Physics Detector предлагает установить универсальный детектор во второй точке взаимодействия строящегося ускорителя NICA в Дубне. Этот детектор будет использоваться для изучения спиновой структуры протона и дейтрона и других спиновых эффектов с помощью поляризованных пучков протонов и дейтронов с энергией столкновения до 27 ГэВ и светимостью до 10^{32} $\text{см}^{-2} \text{с}^{-1}$. Эксперимент SPD в NICA позволит заполнить кинематический пробел между измерениями при низких энергиях на установках ANKE-COSY и SATURNE, измерениями при высоких энергиях на ускорителе тяжелых ионов и будущими экспериментами на Большом адронном коллайдере (БАК). Уникальность NICA заключается в возможности работы с пучками поляризованных дейтронов при этих энергиях.

1.1 КОНСТРУКЦИЯ ДЕТЕКТОРА

Экспериментальная установка SPD (Рис. 1) проектируется как универсальный детектор 4 π с расширенными возможностями для отслеживания и идентификации частиц на основе современных технологий. Вершинный детектор (vertex detector) на основе кремния обеспечит разрешение по позиции вершин на уровне менее 100 микрон, необходимое для восстановления вторичных вершин от распадов D- мезонов. Система трекинга (straw tracker), помещенных в соленоидное магнитное поле с напряженностью до 1 Тесла на оси детектора, обеспечивает разрешение по поперечной импульсу $\sigma_{p_T}/p_T \approx 2\%$ для частиц с импульсом 1 ГэВ/с. Время-пролетная система (time-of-flight system) с временным разрешением около 60 пикосекунд обеспечивает разделение 3σ для пионов/каонов и для каонов/протонов до энергий 1.2 и 2.2 ГэВ соответственно. Использование черенковского детектора на базе аэрогеля — FARICH — поможет расширить этот диапазон вплоть до 6 ГэВ. Обнаружение фотонов обеспечивается электромагнитным калориметром (electromagnetic calorimeter) с энергетическим разрешением $5\%/\sqrt{E}$. Для идентификации мюонов планируется использовать мюонную систему (range system). Она также может использоваться как грубый адронный калориметр. За локальную поляриметрию и контроль светимости будет отвечать пара счетчиков пучков (beam-beam counter) и калориметров малого угла, или малоапертурных калориметров (zero-degree calorimeter).




Рисунок 1 — Конструкция детектора

1.2 FARICH

FARICH (Focusing Aerogel Ring-Imaging CHerenkov detector) — черенковский детектор с аэрогелем, используемым в качестве рабочего тела. Черенковский детектор работает на основе эффекта Черенкова, который заключается в излучении света заряженными частицами, движущимися в среде со скоростью, превышающей фазовую скорость света в этой среде: $\beta n > c$. Это излучение имеет вид конуса, ось которого совпадает с направлением движения частицы, а угол раствора зависит от скорости частицы и показателя преломления среды. Излучение регистрируется массивом фотодетекторов, в результате чего на выходе получается срез конуса плоскостью. Если частица летела перпендикулярно детектору, получается набор точек, формирующих окружность, которую в дальнейшем на онлайн-фильтре надо будет реконструировать при помощи методов машинного обучения.

В качестве среды планируется использовать четыре слоя аэрогеля каждый со своим показателем преломления, что позволит улучшить разрешающую способность детектора [1].




Рисунок 2 — Принципиальная схема детектора FARICH

2 АЛГОРИТМЫ РАСПОЗНАВАНИЯ КОЛЕЦ

2.1 РАЗДЕЛЕНИЕ ЧАСТИЦ ПО ВТОРЫМ МОМЕНТАМ

Простейшим методом идентификации является разделение по вторым моментам. Для каждого значения импульса второй центральный момент для кольца будет меняться в зависимости от типа частицы. Зная зависимость вторых моментов от импульса для разных частиц, можно определить их тип.

2.2 ИТЕРАЦИОННЫЙ МЕТОД

Для данного метода необходима дополнительная информация о предположительных центрах колец, которую можно получить независимо, например, в результате экстраполяции трека из трекового детектора.

Принцип работы следующий: при инициализации рассчитывается расстояние от каждого хита до каждого трека. Полученными значениями с весом 1 заполняют гистограммы (по числу треков). Затем, на каждой итерации обновляют веса хитов по формуле:

$$w_k = \frac{y_k}{\sum_i y_i}, \quad (1)$$

где w_k — вес хита в k -той гистограмме, y_k — содержание ячейки гистограммы, в которую попал данный хит. В результате получаются пики, которые соответствуют центрам колец [2].

2.3 ОТНОШЕНИЕ ФУНКЦИЙ МАКСИМАЛЬНОГО ПРАВДОПОДОБИЯ

Данный метод также требует дополнительной информации о центрах колец. На основании информации о конструкции детектора и параметрах трека делается предсказание положения черенковского фотона при гипотезе о типе частицы. На основе предсказания и наблюдения строится функция правдоподобия, а затем выбирается функция с максимальным правдоподобием [2].

2.4 МЕТОД МАСОК

На предварительно центрированное изображение накладывается трафарет с известными параметрами. Наложение заключается в сложении пикселей маски и изображения по модулю два. Чем больше нулей в результате, тем больше данная маска соответствует изображению [2].

2.5 НЕЧЕТКАЯ КЛАСТЕРИЗАЦИЯ

Метод заключается в минимизации следующего функционала:

$$J = \sum_{i=1}^C \sum_{j=1}^N u_{ij} d_{ij}^2, \quad (2)$$

где u_{ij} — весовой коэффициент, показывающий вероятность принадлежности хита i к кластеру j ($\sum_j u_{ij} = 1$), d_{ij} — расстояние между i хитом и j кластером, C — количество колец, N — количество хитов.

В данном методе необходимо также знать центры колец и их количество [2].

2.6 ПРЕОБРАЗОВАНИЕ ХАФА

Изначально преобразование Хафа предназначено для распознавания прямых и заключается в идее перейти из пространства координат в пространство параметров и нахождения там точки с наибольшей «интенсивностью», т.е. точки с наибольшим числом пересечений прямых. Полученная точка в пространстве параметров и есть параметры, описывающие прямую, проходящую через исходные точки.

Затем данное преобразование можно обобщить и на случай окружностей, перейдя в трехмерное пространство параметров [3].

2.7 СОР

Алгоритм СОР (Chernov-Ososkov-Pratt) позволяет по точкам оценить параметры окружности [4].

Для подгонки окружности методом наименьших квадратов необходимо минимизировать функционал:

$$L(a, b, R) = \sum_{i=1}^N (\sqrt{(x_i - a)^2 + (y_i - b)^2} - R)^2, \quad (3)$$

где a, b — x и y координаты центра окружности, R — ее радиус, x_i и y_i — координаты i -й точки, N — число точек.

Однако, такой метод требует достаточно много времени для вычисления. Для ускорения работы алгоритма можно использовать следующий функционал:

$$M(a, b, c) = \sum_{i=1}^N ((x_i - a)^2 + (y_i - b)^2 - R^2)^2 \quad (4)$$

Минус такого подхода в том, что при измерениях, не покрывающих всю окружность, результат может оказаться довольно далеко от истины.

В алгоритме СОР предлагается использовать функционал:

$$M(a, b, c) = \sum_{i=1}^N [((x_i - a)^2 + (y_i - b)^2 - R^2)^2 / R^2] \quad (5)$$

Нахождение минимума такого функционала эквивалентно минимизации (3), однако вычислительно менее затратно.

2.8 ФИТИРОВАНИЕ ЭЛЛИПСА

Для фитирования эллипса предлагается использовать функционал вида [5]:

$$L(x_{F_1}, y_{F_1}, x_{F_2}, y_{F_2}, a) = \sum_{i=1}^N (\sqrt{(x_i - x_{F_1})^2 + (y_i - y_{F_1})^2} + \sqrt{(x_i - x_{F_2})^2 + (y_i - y_{F_2})^2} - 2a)^2, \quad (6)$$

где $x_{F_1}, y_{F_1}, x_{F_2}, y_{F_2}$ — координаты x и y первого и второго фокуса эллипса соответственно, a — длина большой полуоси.

Минимизация осуществляется при помощи градиентного спуска.

3 МОДЕЛИРОВАНИЕ ДЕТЕКТОРА

3.1 GEANT4

GEANT4 — это программный инструмент на C++ для моделирования экспериментов в области физики элементарных частиц. Он разрабатывается и поддерживается Европейской организацией по ядерным исследованиям (CERN) [6–8].

GEANT4 используется для моделирования прохождения частиц через материю, включая взаимодействия, которые происходят при столкновении частиц с атомами в материале. Эта информация может быть использована для проектирования экспериментов, понимания результатов этих экспериментов и создания симуляций будущих экспериментов.

В данной работе пакет GEANT4 использовался для моделирования детектора FARICH.

3.2 МОДЕЛИРОВАНИЕ ДЕТЕКТОРА И СОБЫТИЙ

Модель детектора (Рис. 3) — два диска радиусом 847 мм. Первый диск состоит из четырех слоев аэрогеля на основе диоксида кремния с изменяющимся показателем преломления: 1.037, 1.041, 1.043, 1.047. Толщины слоев 7 мм, 10, 9 мм, 10 мм соответственно. Второй — чувствительный детектор, который регистрирует черенковские фотоны в диапазоне примерно от 400 нм до 450 нм — в области чувствительности кремниевых фотодетекторов. Расстояние между аэрогелем и фотоприемником — 164 мм.




Рисунок 3 — Моделирование детектора FARICH

Для обучения и проверки моделей было смоделировано 75000 событий — по 25000 событий с протоном, каоном и протоном. Затем отобраны события, в которых число хитов больше 5, а также χ^2 которых при фитировании эллипсом меньше 3. В результате получилось 70000 событий.

4 ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ

В связи с быстрым развитием методов машинного обучения и в частности нейросетевых подходов, возникает возможность применения этих методов для анализа данных, полученных с FARICH детектора. Нейросетевые методы обладают уникальной способностью выявлять сложные зависимости в данных, что делает их идеальным инструментом для распознавания колец и анализа параметров частиц, регистрируемых в эксперименте. Такой подход не только повышает точность распознавания, но и позволяет создавать более эффективные модели, способствуя глубокому пониманию физических процессов.

В рамках поставленной задачи было решено использовать сверточные нейронные сети.

4.1 СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ

Сверточные нейронные сети (Convolutional Neural Networks, CNN) - это класс нейронных сетей, специально разработанный для обработки структурированных данных, таких как изображения. Они состоят из нескольких слоев, включая сверточные слои, слои пулинга и полносвязные слои.

Сверточные слои (Рис. 4): основной компонент CNN. Они используют фильтры для извлечения различных признаков из входных данных. Например, первый сверточный слой может выявлять базовые черты, такие как грани или углы, тогда как последующие слои могут выявлять более сложные особенности.

Input		Kernel		Output																	
<table border="1" style="border-collapse: collapse;"><tr><td style="padding: 2px 10px;">0</td><td style="padding: 2px 10px;">1</td><td style="padding: 2px 10px;">2</td></tr><tr><td style="padding: 2px 10px;">3</td><td style="padding: 2px 10px;">4</td><td style="padding: 2px 10px;">5</td></tr><tr><td style="padding: 2px 10px;">6</td><td style="padding: 2px 10px;">7</td><td style="padding: 2px 10px;">8</td></tr></table>	0	1	2	3	4	5	6	7	8	*	<table border="1" style="border-collapse: collapse;"><tr><td style="padding: 2px 10px;">0</td><td style="padding: 2px 10px;">1</td></tr><tr><td style="padding: 2px 10px;">2</td><td style="padding: 2px 10px;">3</td></tr></table>	0	1	2	3	=	<table border="1" style="border-collapse: collapse;"><tr><td style="padding: 2px 10px;">19</td><td style="padding: 2px 10px;">25</td></tr><tr><td style="padding: 2px 10px;">37</td><td style="padding: 2px 10px;">43</td></tr></table>	19	25	37	43
0	1	2																			
3	4	5																			
6	7	8																			
0	1																				
2	3																				
19	25																				
37	43																				

Рисунок 4 — Пример свертки с ядром 2×2

Слои пулинга (Рис. 5): эти слои снижают размерность и объем данных путем объединения информации с определенных областей. Это помогает уменьшить количество параметров и вычислений в сети, а также делает признаки инвариантными к небольшим изменениям в данных.

3	3	2	1	0
0	0	1	3	1
3	1	2	2	3
2	0	0	2	2
2	0	0	0	1

3.0	3.0	3.0
3.0	3.0	3.0
3.0	2.0	3.0

Рисунок 5 — Пример пулинга с ядром 3×3

Также распространен глобальный пулинг (Рис. 6): он позволяет обрабатывать изображения произвольных размеров путем агрегации данных вдоль каналов.

Полносвязные слои: последние слои в сети, которые объединяют признаки, выученные предыдущими слоями сверточной нейросети, для принятия решений.

CNN применяются в широком диапазоне задач компьютерного зрения, включая распознавание объектов, классификацию изображений, детекцию объектов и семантическую сегментацию. Их эффек-




Рисунок 6 — Пример глобального пулинга

тивность объясняется способностью изучать иерархии признаков изображений на различных уровнях абстракции.

В случае необходимости предобработки данных, аугментации и выбора функций потерь, CNN требуют настройки определенных параметров для достижения оптимальных результатов в конкретных задачах.

4.2 ПОСТАНОВКА ЗАДАЧИ

На вход подается матрица сигналов с детектора $M \in R^{N \times N}$, а также координаты центров $C \in R^{2 \times c}$ из трекового детектора вместе с импульсами частиц. На выходе надо получить значение скорости $v \in R^c$ для всех частиц, вызвавших срабатывание детектора.

Однако, как было показано ранее, в таком виде задача плохо решается, поэтому постановку можно немного дополнить: из исходной матрицы вырезаются матрицы размера 25×25 так, чтобы через центральный пиксель проходил экстраполированный трек искомой частицы. Таким образом при небольшой загрузке детектора уменьшаются вычислительные затраты, так как пустые области игнорируются, а также упрощается задача модели, что позволяет достичь большей точности.

Для оценки качества моделей далее будет использоваться 5-фолд кросс-валидация.

4.3 ВАРИАНТ 1

4.3.1 Архитектура

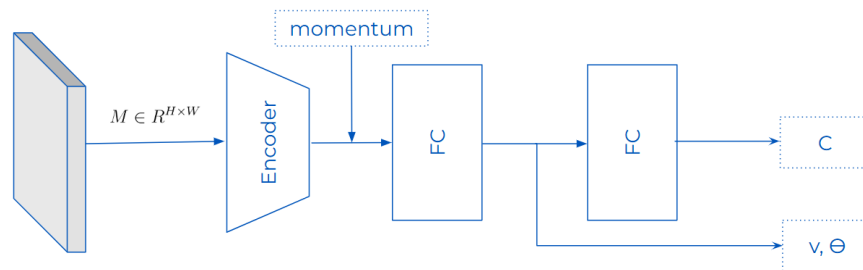


Рисунок 7 — Схема модели (вариант 1)

Модель (рис. 7) состоит из энкодера, представленного последовательностью сверток и пулингов, а также набора полносвязных слоев. На вход подается тензор размерности $1 \times 25 \times 25$. На выходе - числа, характеризующие уверенность модели в том, какая частица зарегистрирована. Кроме того, за несколько слоев до классификационного выхода сделаны дополнительные выходы на регрессию для скорости и угла черенковского конуса. Это сделано, чтобы, во-первых, повысить интерпретируемость

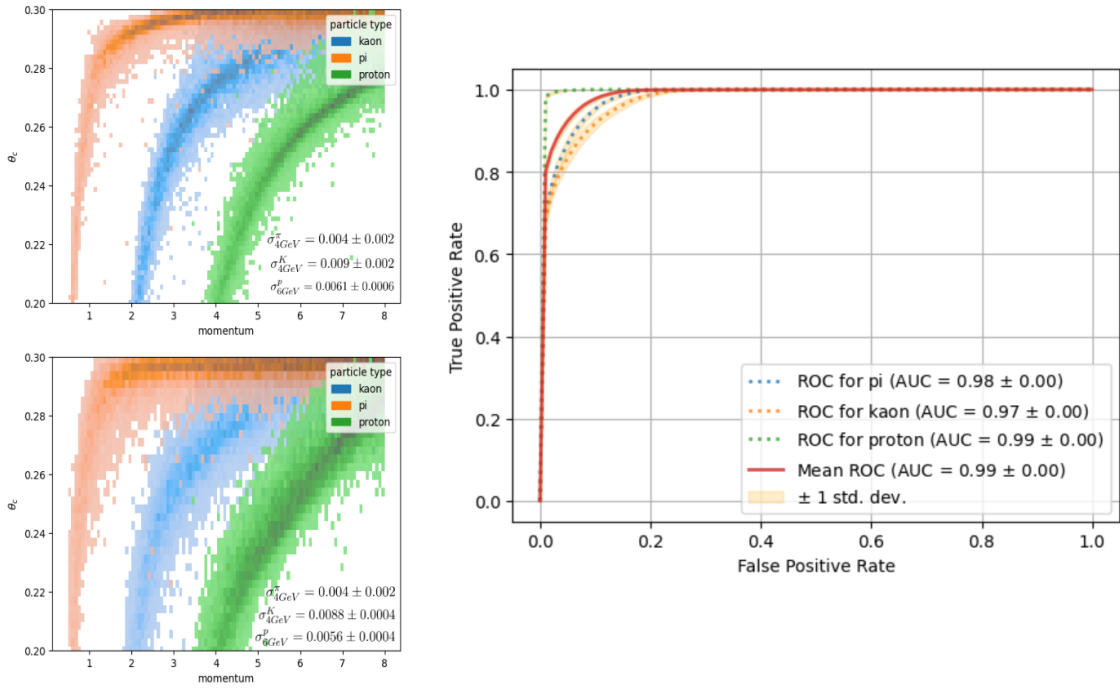


Рисунок 8 — Слева – двумерные гистограммы в координатах импульс-угол черенковского конуса; сверху угол восстановлен из предсказанной скорости, снизу – угол берется напрямую из выхода нейросети. Справа – ROC для классификации частицы на каждый из трех классов по отдельности, а также в общем

модели, а во-вторых, чтобы повысить обобщающую способность.

Здесь и далее для обучения использовался оптимизатор NAdam со значением learning rate $2 \cdot 10^{-3}$, Weight decay $1 \cdot 10^{-4}$, а также StepLR с шагом 3 и дисконтирующим параметром $25 \cdot 10^{-3}$. Размер батча брался 128.

4.3.2 Результаты

На рис 8 представлены двумерные гистограммы для распределения угла черенковского конуса в зависимости от импульса, а также гис кривые. Микроусредненный ROC AUC достигает значения $0,987 \pm 0,002$. Точность такой модели выше, чем точность при реконструкции эллипсом, но все же недостаточно.

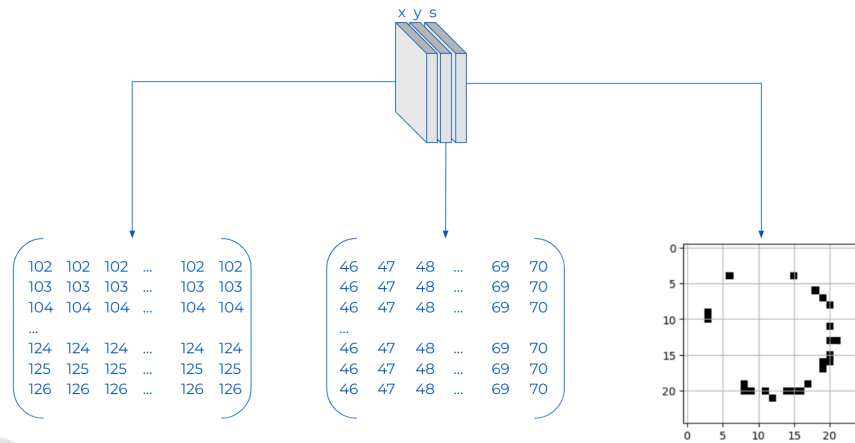


Рисунок 9 — Пример входа модели с координатами

4.4 ВАРИАНТ 2

4.4.1 Архитектура

Второй вариант имеет почти такую же архитектуру, как и первый. Единственное отличие – во входных данных (рис. 9): на вход принимается тензор размерности $3 \times 25 \times 25$. В два новых канала записываются номера бинов вдоль осей x и y соответственно, которые затем нормируются на интервал $(-1; 1)$ для улучшения сходимости. Таким образом, модель, во-первых, имеет представление о масштабе колец, что может быть важным для определения скорости и угла, а во-вторых таким образом модель понимает точку входа частицы, а следовательно угол ее вылета и угол наклона оси эллипса к плоскости детектора.

4.4.2 Результаты

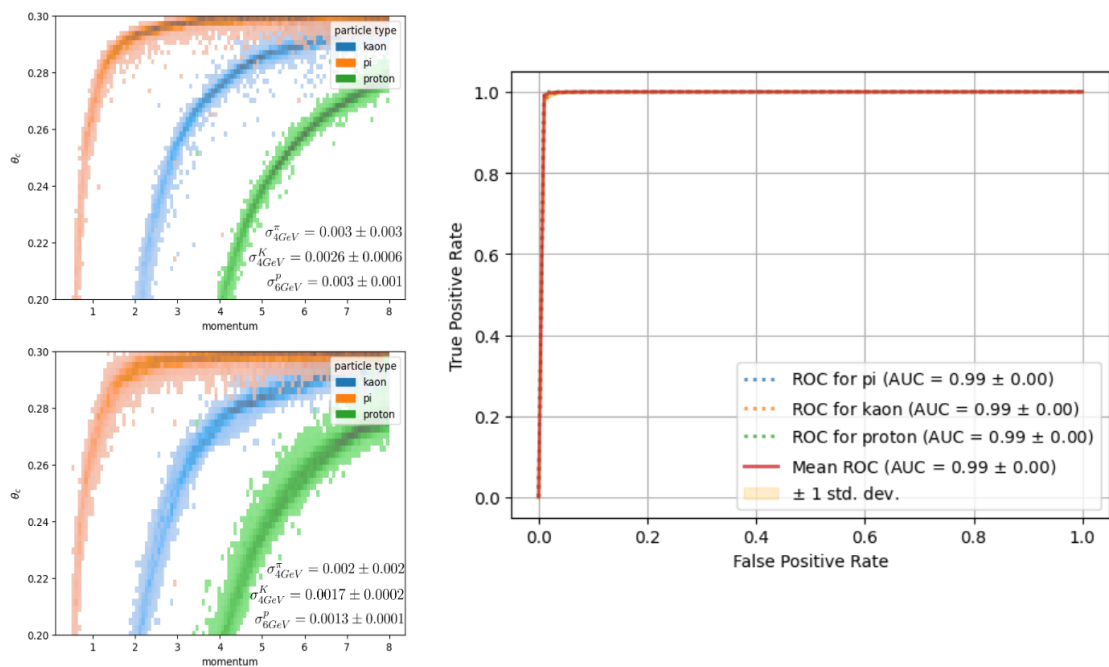


Рисунок 10 — Слева – двумерные гистограммы в координатах импульс-угол черенковского конуса; сверху угол восстановлен из предсказанной скорости, снизу – угол берется напрямую из выхода нейросети. Справа – ROC для классификации частицы на каждый из трех классов по отдельности, а также в общем

На рис 10 представлены двумерные гистограммы для распределения угла черенковского конуса в зависимости от импульса, а также гис кривые. Микроусредненный ROC AUC достигает значения $0,9994 \pm 0,0001$. Видно, что такая модель существенно точнее. Далее эта модель будет использоваться как основа для дальнейших исследований.

5 УСТОЙЧИВОСТЬ К ШУМУ

Следующий важный шаг - исследовать модель на устойчивость к шуму. Детектор в ходе работы будет генерировать ложные сигналы, и важно научить модель игнорировать их.

Для этого к изображению применялся шум с распределением Бернулли - каждый пиксель с вероятностью p переключался со значения 0 на 1. Было исследовано влияние разного уровня шума на качество модели.

5.1 БЕЗ ДОПОЛНИТЕЛЬНОЙ ОЧИСТКИ

В данной секции представлены результаты для модели из секции 4.4.1. Никакой дополнительной очистки не проводилось, зашумленное изображение подавалось на вход, на выходе ожидалась скорость, угол и тип частицы.

Noise Level	ROC AUC	MAE
0.01-0.02	0.9972 ± 0.0005	0.0026 ± 0.0003
0.03-0.04	0.995 ± 0.001	0.0029 ± 0.0002
0.05-0.06	0.991 ± 0.002	0.0034 ± 0.0003
0.07-0.08	0.989 ± 0.002	0.0038 ± 0.0004
0.09-0.10	0.985 ± 0.003	0.0041 ± 0.0004

Таблица 1 — Качество модели без дополнительной очистки при разных уровнях шума

В таблице 1 представлены ROC AUC и MAE для угла для пяти разных диапазонов шумов. Качество ожидаемо падает с ростом зашумленности.

5.2 С ДОПОЛНИТЕЛЬНЫМ ЭТАПОМ ОЧИСТКИ




Рисунок 11 — Модель с дополнительным этапом очистки от шума




Рисунок 12 — Результат очистки от шума. Слева исходное изображение, по центру – результат работы нейросети, справа – искомое изображение

Для улучшения качества можно использовать отдельную модель для очистки изображения, которое затем используется для предсказания целевых переменных. Для этого в исходную модель (рис. 7) перед энкодером была добавлена небольшая UNet-подобная сеть, состоящая из пары энкодер-декодер (рис. 11). Результат очистки зашумленного изображения представлен на рис. 12.

В таблице 2 представлены ROC AUC и MAE для угла для пяти разных диапазонов шумов. Качество ожидаемо падает с ростом зашумленности. Видно, что такой подход несколько повышает качество модели.

5.3 ОБЪЕДИНЕНИЕ ПРЕДЫДУЩИХ ДВУХ ПОДХОДОВ

Предыдущая модель получается весьма тяжелой и, как следствие, медленной из-за наличия дополнительного блока энкодера, а также блока декодера. Следующая архитектура (рис. ??) избавляется от второго энкодера и выносит блок декодера вне основной линии, так что его можно отключить,

Noise level	ROC AUC	MAE
0.01-0.02	0.9988 ± 0.0002	0.0021 ± 0.0004
0.03-0.04	0.9979 ± 0.0004	0.0022 ± 0.0003
0.05-0.06	0.9967 ± 0.0007	0.0025 ± 0.0001
0.07-0.08	0.994 ± 0.001	0.0027 ± 0.0002
0.09-0.10	0.986 ± 0.002	0.0039 ± 0.0002

Таблица 2 — Качество модели с дополнительной очисткой при разных уровнях шума




Рисунок 13 — Модель с вынесенным в сторону декодером

если чистое изображение не требуется.

В процессе обучения в лосс вводится дополнительное слагаемое – косинусное расстояние между выходами энкодера для шумного и для чистого изображений, которое необходимо максимизировать.

Результаты вынесены в таблицу 3.

Noise level	ROC AUC	MAE
0.01-0.02	0.997 ± 0.001	0.0025 ± 0.0004
0.03-0.04	0.995 ± 0.001	0.0027 ± 0.0003
0.05-0.06	0.992 ± 0.001	0.0032 ± 0.0005
0.07-0.08	0.989 ± 0.002	0.0034 ± 0.0004
0.09-0.10	0.985 ± 0.004	0.0039 ± 0.0005

Таблица 3 — Качество модели с дополнительной очисткой при разных уровнях шума

5.4 ФИНАЛЬНОЕ СРАВНЕНИЕ

В таблице 4 приведены метрики и время работы для трех рассмотренных моделей. Видно, что вторая самая точная, но при этом самая медленная. Первая по качеству сравнима с третьей, но она не дает возможности оценить работу сети по очищенному изображению.

	AUC	MAE(v)	MAE(θ)	Inference time (batch, 1000 samples)
v1	0.9966 ± 0.0009	0.0010 ± 0.0001	0.0029 ± 0.0003	(12.50 ± 0.02) ms
v2	0.9978 ± 0.0004	0.00087 ± 0.00006	0.0021 ± 0.0002	(73.80 ± 0.02) ms
v3	0.996 ± 0.001	0.009 ± 0.0001	0.0026 ± 0.0003	(53.50 ± 0.08) ms

Таблица 4 — Финальное сравнение моделей

ЗАКЛЮЧЕНИЕ

В ходе работы разработана модель, предсказывающая скорость и тип частицы. Предложен способ существенно улучшить ее работу. Также исследована устойчивость модели к шуму и разработана другая модель, позволяющая убрать шум с изображения.

В дальнейшем планируется учесть возможные погрешности при экстраполяции трека, а также проверить модель на устойчивость предсказания при пересечении двух и более колец.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. RICH with multiple aerogel layers of different refractive index / S. Korpar [и др.] // Nucl. Instrum. Meth. A / под ред. J. Engelfried, G. Paic. — 2005. — Т. 553.
2. *Лебедев С. А.* Математическое обеспечение для реконструкции колец черенковского излучения и идентификации электронов в RICH детекторе эксперимента CBM : дис. . . . канд. / Лебедев С. А. — Объединённый институт ядерных исследований, 2011.
3. *Hough V P. C.* Method and means for recognizing complex patterns. — 1962.
4. *Chernov N. I., Ososkov G. A.* Effective Algorithms of Circle Fitting // Comput. Phys. Commun. — 1984. — Т. 33. — С. 329—333.
5. *Lebedev S. A., Ososkov G. A.* Fast algorithms for ring recognition and electron identification in the CBM RICH detector // Phys. Part. Nucl. Lett. — 2009. — Т. 6. — С. 161—176.
6. Recent developments in Geant4 / J. Allison [и др.] // Nucl. Instrum. Meth. A. — 2016. — Т. 835. — С. 186—225.
7. Geant4 developments and applications / J. Allison [и др.] // IEEE Transactions on Nuclear Science. — 2006. — Т. 53, № 1. — С. 270—278.
8. GEANT4—a simulation toolkit / S. Agostinelli [и др.] // Nucl. Instrum. Meth. A. — 2003. — Т. 506. — С. 250—303.