

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

ИНСТИТУТ ЯДЕРНОЙ ФИЗИКИ И ТЕХНОЛОГИЙ
КАФЕДРА №40 «ФИЗИКА ЭЛЕМЕНТАРНЫХ ЧАСТИЦ»

УДК 531.3, 539.1.05

На правах рукописи

МАССАЛОВ КИРИЛЛ ЮРЬЕВИЧ

РЕКОНСТРУКЦИЯ СИГНАЛОВ В ДЕТЕКТОРЕ FARICH УСТАНОВКИ SPD НА КОЛЛАЙДЕРЕ NICA

Направления подготовки:

09.04.04 «Программная инженерия»,

14.04.02 «Ядерная физика и технологии»

Диссертация на соискание степени магистра

Научный руководитель,

к.ф.-м.н.

_____ Е. Ю. Солдатов

Научный консультант,

к.ф.-м.н.

_____ А. С. Жемчугов

Москва 2025

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА МАГИСТРА

**РЕКОНСТРУКЦИЯ СИГНАЛОВ В ДЕТЕКТОРЕ FARICH
УСТАНОВКИ SPD НА КОЛЛАЙДЕРЕ NICA**

Студент _____ К. Ю. Массалов

Научный руководитель,
к.ф.-м.н. _____ Е. Ю. Солдатов

Научный консультант,
к.ф.-м.н. _____ А. С. Жемчугов

Рецензент,
к.ф.-м.н. _____ И. И. Денисенко

Рецензент,
к.т.н. _____ Д. А. Олейник

Секретарь ГЭК,
к.ф.-м.н. _____ Е. Ю. Солдатов

Зав. каф. №40,
д.ф.-м.н., проф. _____ М. Д. Скорохватов

Рук. учеб. прог.,
к.ф.-м.н. _____ Е. Ю. Солдатов

ОГЛАВЛЕНИЕ

Введение	5
1 Экспериментальная установка Spin Physics Detector на строящемся в ОИЯИ коллайдере NICA	7
1.1 Конструкция детектора	7
1.2 FARICH	8
2 Алгоритмы распознавания колец	10
2.1 Разделение частиц по вторым моментам	10
2.2 Итерационный метод	10
2.3 Отношение функций максимального правдоподобия	12
2.4 Метод масок	12
2.5 Нечеткая кластеризация	13
2.6 Преобразование Хафа	13
2.7 COP	14
2.8 Фитирование эллипса	15
2.9 Реконструкция на основе зависимости азимутального угла черенковского конуса от полярного	15
3 Моделирование детектора	17
3.1 GEANT4	17
3.2 Моделирование детектора и событий	17
3.3 Вид обучающей выборки	18
4 Применение классических методов	20
4.1 Метод вторых моментов	20
4.2 Фитирование эллипсом	21
4.3 Реконструкция на основе зависимости азимутального угла черенковского конуса от полярного	21

5	Применение нейросетевых методов	23
5.1	Варианты обработки сигналов детектора с использованием информации о треках частиц	23
5.1.1	Варианты архитектур	23
5.1.2	Подходы к обработке множества треков	24
5.2	Позиционное кодирование	25
5.2.1	Архитектура	25
5.2.2	Результаты	26
5.3	Устойчивость к шуму	26
5.3.1	Без дополнительной очистки	27
5.3.2	С дополнительным этапом очистки	28
5.3.3	Оптимизированная архитектура с этапом очистки	29
5.3.4	Сравнение получившихся нейросетевых моделей	30
5.3.5	Сравнение нейросетевых и классических моделей	31
5.4	Сегментация исходного изображения	32
5.5	Исследование масштабируемости моделей	34
5.6	Исследование интерпретируемости моделей	35
5.7	Варианты обработки сигналов детектора без использования информации о треках частиц	36
	Заключение	39
	Список использованных источников	40

ВВЕДЕНИЕ

Относительный вклад видимой барионной материи во Вселенную составляет около 5% от общей массы [1]. 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.

За последние 25 лет эксперименты по глубоко неупругому рассеянию (проводимые в CERN, DESY, JLab, SLAC) и высокоэнергетические столкновения протонов (RHIC в BNL) 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 [2] — 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 неполяризованной и поляризованной глюонной составляющей нуклона. Изучение спиновых явлений в SPD на коллайдере NICA откроет новые возможности для понимания спиновой структуры нуклона.

На установке планируется частота соударений до 4 МГц, число выходных каналов с детекторов ~ 600000 . 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 online-фильтр, представляющий собой высокопроизводительную систему, которая будет включать в себя гетерогенные вычислительные платформы, аналогичные многим высокопроизводительным вычислительным кластерам. Задача online-фильтра — быстрая частичная реконструкция событий и отбор данных. Для реконструкции и отбрасывания неинтересных со-

бытий можно использовать методы машинного обучения, поскольку проблема классических алгоритмов в том, что они имеют невысокую скорость и плохо поддаются распараллеливанию, в отличие от нейронных сетей. Проблема же нейронных сетей в сложности интерпретации их решений и необходимости валидации каждого результата.

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

Одним из детекторов установки SPD является детектор FARICH — Focusing Aerogel Ring-Imaging CHerenkov. Этот детектор играет ключевую роль в разделении пионов и каонов в широком диапазоне импульсов. Идентификация каона из распадов D-мезонов, одного из ключевых процессов изучения глюонной структуры в эксперименте SPD, должна позволить значительно снизить поток данных после online-фильтра.

Таким образом, целью данной работы является разработка и исследование нейросетевых методов реконструкции сигналов с детектора FARICH, а также изучение их характеристик и сравнение с классическими подходами. Предлагаемые алгоритмы должны обеспечивать высокую скорость работы и точность идентификации частиц, а также быть устойчивыми к различным видам шумов.

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

Детектор SPD будет установлен 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 на ускорительном комплексе NICA позволит заполнить кинематический пробел между измерениями при низких энергиях (эксперименты ANKE-COSY [3] и SATURNE [4]) и измерениями на ускорительном комплексе RHIC, а также предложенными для детекторов БАК проектов LHCspin [5] и AFTER [6]. Уникальность NICA заключается в возможности работы с пучками поляризованных дейтронов при этих энергиях.

1.1 КОНСТРУКЦИЯ ДЕТЕКТОРА

Экспериментальная установка SPD — универсальный 4π -детектор, создаваемый на основе современных технологий. Схема детектора и его основные части приведены на рис. 1.1. Вершинный детектор (vertex detector) на основе кремния обеспечит разрешение по позиции вершин на уровне менее 100 микрон, что необходимо для восстановления вторичных вершин от распадов D-мезонов. Трековая система на основе дрейфовых трубок находится в магнитном поле с напряженностью до 1 Тесла на оси детектора и вместе с вершинным детектором обеспечивает импульсное разрешение $\sigma_{p_T}/p_T \approx 2\%$ 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 соответ-

ственно. Использование черенковского детектора на базе аэрогеля — FARICH — поможет расширить этот диапазон вплоть до 6 ГэВ. Реконструкция 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 нулевого угла (zero-degree calorimeter).




Рисунок 1.1 — Конструкция детектора.

1.2 FARICH

FARICH — черенковский детектор с аэрогелем, используемым в качестве рабочего тела. Основной задачей FARICH является идентификация в широком диапазоне импульсов каонов из распадов D-мезонов для снижения вклада фоновых процессов. Ожидаемые диапазоны импульсов идентификации каонов с уверенностью в три сигма — до 5.5 ГэВ при разделении каонов и пионов, до 8 ГэВ при разделении протонов и каонов.

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: $\beta > \frac{c}{n}$. Черенковское излучение испускается под определенным углом относительно направления движения частицы и формирует конус. Угол излучения связан со

скоростью частицы (β) и показателем преломления среды (n) по формуле:

$$\cos \theta_c = \frac{1}{\beta n} \quad (1.1)$$

Излучение регистрируется массивом пиксельных фотодетекторов, в результате чего на выходе получается срез конуса плоскостью. В пренебрежении преломления света на выходе из детектора срез имеет форму эллипса. На этапе реконструкции эллипсоподобная форма анализируется для нахождения черенковского угла. Тип заряженной частицы определяется путем сопоставления полученного угла с ее импульсом.

В качестве радиатора планируется использовать четыре слоя аэрогеля с разными показателями преломления – от 1.037 до 1.047, что позволит улучшить фокусировку и, как следствие, разрешающую способность детектора.




Рисунок 1.2 — Принципиальная схема детектора FARICH.

2 АЛГОРИТМЫ РАСПОЗНАВАНИЯ КОЛЕЦ

В данной главе представлен обзор существующих алгоритмов, предназначенных для распознавания и реконструкции эллипсов в черенковских детекторах, что является ключевым этапом в задаче идентификации частиц в экспериментах физики высоких энергий. Некоторые из рассмотренных ниже методов были реализованы программно с целью сравнения эффективности их работы.

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 ожидаемых центрах колец, которую можно получить независимо, например, в результате экстраполяции трека из трекового детектора.

Принцип работы итерационного метода [7] заключается в следующем:

- Инициализация. На первом этапе для каждого сработавшего пикселя, называемого хитом, рассчитывается расстояние до каждого ожидаемого центра кольца. Полученные значения расстояний используются для заполнения гистограмм. Количество гистограмм соответствует количеству треков заряженных частиц в трековой системе. Изначально, все хиты имеют одинаковый вес – значение 1. Таким образом, каждая гистограмма представляет собой распределение расстояний от хитов до предполагаемого

го центра кольца, соответствующего данному треку, с одинаковым весом для каждого хита.

- Итеративное обновление весов. После инициализации начинается итеративный процесс обновления весов хитов. На каждой итерации веса хитов пересчитываются на основе содержимого гистограмм, в которые эти хиты попали. Формула для обновления веса хита выглядит следующим образом:

$$w_k = \frac{y_k}{\sum_i y_i},$$

где:

- w_k – вес хита в k -той гистограмме (то есть, вес хита, относящегося к k -тому треку);
- y_k – содержание ячейки гистограммы, в которую попал данный хит. Это значение отражает частоту появления хитов на данном расстоянии от предполагаемого центра кольца;
- $\sum_i y_i$ – сумма содержаний всех ячеек в k -той гистограмме. Это значение представляет собой полное количество хитов, связанных с k -тым треком.

Таким образом, вес каждого хита обновляется в соответствии с относительной частотой его появления на определенном расстоянии от предполагаемого центра кольца. Хиты, которые находятся на расстояниях, где хиты встречаются часто (то есть, вблизи “пиков” гистограммы), получают более высокий вес, а хиты, которые находятся на расстояниях, где хиты встречаются редко, получают более низкий вес.

- Повторение итераций. Шаг обновления весов повторяется несколько раз. С каждой итерацией веса хитов, находящихся вблизи истинных центров колец, увеличиваются, а веса остальных хитов уменьшаются.

В результате итерационного процесса в гистограммах формируются четкие пики. Положение этих пиков соответствует наиболее вероятным центрам колец Черенковского излучения.

2.3 ОТНОШЕНИЕ ФУНКЦИЙ МАКСИМАЛЬНОГО ПРАВДОПОДОБИЯ

В эксперименте LHCb для идентификации частиц использовались два подхода, основанных на методе правдоподобия: локальный [8] и глобальный [9]. В обоих подходах для каждой гипотезы о типе частицы (пион, каон, электрон и т.д.) предсказывается положение черенковского фотона на основе параметров трека и особенностей конструкции RICH-детектора. Это предсказание сравнивается с наблюдаемым распределением фотонов, и строится логарифмическая функция правдоподобия. Выбирается гипотеза с максимальным правдоподобием.

Локальный подход для каждого трека и каждого пикселя фотодетектора вычисляет угол, под которым испускается фотон по отношению к треку. Предполагается, что эти углы распределены по нормальному закону вокруг ожидаемого угла черенковского излучения для данной гипотезы. Вычисляется логарифмическая функция правдоподобия, суммирующая вклады от всех хитов в некотором “коридоре” вокруг ожидаемого угла. Эта функция используется для оценки количества фотонов, которое следовало бы ожидать для данной гипотезы. Тип частицы определяется с использованием информации о количестве реконструированных хитов.

Глобальный подход вычисляет правдоподобие для всего события, а не для каждого трека в отдельности. При этом учитывается шум от других треков в событии. Правдоподобие вычисляется путем сравнения количества фотоэлектронов, зарегистрированных в каждом пикселе фотодетектора, с ожидаемым количеством фотоэлектронов.

Оба подхода показали хорошую эффективность в эксперименте LHCb. Основные трудности связаны с плохой оценкой параметров треков, а также с кольцами, для которых не удалось найти соответствующий трек.

2.4 МЕТОД МАСОК

Метод масок [10] представляет собой подход к идентификации кольца Черенковского излучения, основанный на сравнении наблюдаемого изображения

с эталонными шаблонами (масками).

Основная идея заключается в следующем:

- Изображение предварительно центрируется.
- На центрированное изображение накладывается бинарная маска с известными параметрами, после чего выполняется сложение по модулю 2. Маски генерируются для каждого типа частиц.
- Подсчитывается количество нулей в результате. Чем больше нулей, тем лучше соответствие.
- Выбирается маска, дающая максимальное количество нулей. На её основе делается вывод о типе частицы.

2.5 НЕЧЕТКАЯ КЛАСТЕРИЗАЦИЯ

Метод [11] заключается в минимизации следующего функционала:

$$J = \sum_{i=1}^C \sum_{j=1}^N u_{ij} d_{ij}^2, \quad (2.1)$$

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.

2.6 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 [12].

2.7 COP

Алгоритм COP (Chernov-Ososkov-Pratt) позволяет по точкам оценить параметры окружности [13].

Для подгонки окружности методом наименьших квадратов необходимо минимизировать функционал:

$$L(a, b, R) = \sum_{i=1}^N (\sqrt{(x_i - a)^2 + (y_i - b)^2} - R)^2, \quad (2.2)$$

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:

$$M(a, b, c) = \sum_{i=1}^N ((x_i - a)^2 + (y_i - b)^2 - R^2)^2 \quad (2.3)$$

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

В алгоритме COP предлагается использовать функционал:

$$M(a, b, c) = \sum_{i=1}^N [((x_i - a)^2 + (y_i - b)^2 - R^2)^2 / R^2] \quad (2.4)$$

Нахождение минимума такого функционала эквивалентно минимизации (2.2), однако вычислительно менее затратно.

2.8 ФИТИРОВАНИЕ ЭЛЛИПСА

Для фитирования эллипса предлагается использовать функционал вида [14]:

$$L(x_{F_1}, y_{F_1}, x_{F_2}, y_{F_2}, a) = \sum_{i=1}^N \left(\sqrt{(x_i - x_{F_1})^2 + (y_i - y_{F_1})^2} + \sqrt{(x_i - x_{F_2})^2 + (y_i - y_{F_2})^2} - 2a \right)^2, \quad (2.5)$$

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.

2.9 РЕКОНСТРУКЦИЯ НА ОСНОВЕ ЗАВИСИМОСТИ АЗИМУТАЛЬНОГО УГЛА ЧЕРЕНКОВСКОГО КОНУСА ОТ ПОЛЯРНОГО

В данном подходе [15] для реконструкции используется зависимость полярного угла черенковских фотонов (θ_c) от азимутального угла (ϕ_c). Поскольку значения θ_c и ϕ_c определены в системе координат первичной частицы, необходимо перевести их в лабораторную систему координат, в которой движется первичная частица. Положение первичной частицы в лабораторной системе координат определяется её начальным положением и углами θ_t и ϕ_t . Зависимость θ_c от ϕ_c выражается формулой, в которой учитываются коэффициент преломления излучателя (n), скорость частицы (β) и угол θ_t :

$$\theta_c(\phi_c|\beta, n, \theta_t) = \arccos\left(\frac{1}{n\beta}\right) + \arccos\left(n\sqrt{1 - (n_0 n_\gamma)^2} + (n_0 n_\gamma)\sqrt{1 - n^2(1 - (n_0 n_\gamma)^2)}\right) \quad (2.6)$$

- n - средний индекс преломления радиатора;
- n_0 - вектор нормали к излучателю;
- n_γ - вектором образующей конуса;

- $n_0 n_\gamma = \frac{\cos \theta_t}{n\beta} + \cos \phi_c \sin \theta_t \sqrt{1 - \frac{1}{(n\beta)^2}}.$

Это единственный подход, который учитывает преломление света на выходе из аэрогеля.

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) [16—18].

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 компонентов экспериментальной установки, оценки эффективности их работы и интерпретации результатов.

В данной работе пакет GEANT4 использовался для моделирования детектора FARICH.

3.2 МОДЕЛИРОВАНИЕ ДЕТЕКТОРА И СОБЫТИЙ




Рисунок 3.1 — Моделирование детектора FARICH.

Модель детектора (Рис. 3.1)— два диска радиусом 847 мм. Первый диск состоит из четырех слоев аэрогеля на основе диоксида кремния с изменяющим-




Рисунок 3.2 — График зависимости квантовой эффективности от длины волны.

ся показателем преломления: 1.037, 1.041, 1.043, 1.047. Толщины слоев 7 мм, 10 мм, 9 мм, 10 мм соответственно. Второй — чувствительный детектор, который регистрирует черенковские фотоны. Квантовая эффективность фоточувствительных элементов взята для фотоумножителя MCP-PMT N0621. График зависимости эффективности от длины волны представлен на рис. 3.2. Расстояние между аэрогелем и фотоприемником — 164 мм. Размер пикселя фотодетектора — $5.8 \cdot 5.8 \text{ мм}^2$.

При моделировании детектора использовалась физика из стандартного модуля «QGSP_FTFP_BERT» с дополнительно подключенным модулем «G4Optical».

Для обучения и проверки моделей было смоделировано 210000 одночастичных событий — по 70000 событий с пионом, 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 одночастичных событий.

3.3 ВИД ОБУЧАЮЩЕЙ ВЫБОРКИ

Детектор будет регистрировать события в режиме так называемых временных срезов (timeslice). За один временной срез он будет регистрировать порядка 100 частиц, поэтому одно событие с детектора создается путем сэмплирования из набора одночастичных событий. Кроме того, моделируется шум для каждого пикселя из распределения Бернулли.

Также, кроме сигналов непосредственно с FARICH детектора, использо-




Рисунок 3.3 — Вид одного события из 100 частиц с детектора. Дополнительно каждый пиксель с вероятностью 0.025 – шумовой.

вались экстраполированные треки частиц и их импульсы на входе в детектор. К экстраполированным трекам добавляется случайный сдвиг на один пиксель в разные стороны, имитирующий ошибку.

Пример одного временного среза представлен на рис. 3.3.

4 ПРИМЕНЕНИЕ КЛАССИЧЕСКИХ МЕТОДОВ

Данная глава посвящена исследованию классических методов обработки данных с целью установления базового уровня эффективности для задачи идентификации частиц в детекторе FARICH. Полученные результаты будут использованы в качестве эталона для оценки преимуществ более сложных алгоритмов, рассматриваемых в последующих главах.

Для оценки качества моделей использовалась величина под названием разделяющая способность (separation power) [19]:

$$n_\sigma = \frac{R_A - R_B}{< \sigma_{A,B} >}, \quad (4.1)$$

где R_A, R_B - среднее значение отклика детектора (в данном случае это значение предсказываемого моделью угла черенковского конуса), $< \sigma_{A,B} >$ - среднее стандартных отклонений.

Вычисления проводились на языке Python с использованием библиотеки SciPy [20].

4.1 МЕТОД ВТОРЫХ МОМЕНТОВ

На рисунках 4.1а и 4.1б представлены основные результаты работы данного метода. Рисунок 4.1а демонстрирует зависимость разделяющей способности между различными типами частиц от импульса. Видно, что для частиц с импульсом примерно до 3 ГэВ для π/K и до 6 ГэВ для K/p достигается разделяющая способность выше 3σ (отмечено серой линией), что позволяет эффективно разделять частицы в этом диапазоне. Однако при более высоких импульсах разделяющая способность снижается, что связано с уширением колец черенкова и увеличением влияния шума.

На рисунке 4.1б представлена двумерная гистограмма зависимости угла

излучения черенкова от импульса. Данная гистограмма позволяет визуально оценить качество реконструкции колец и разделение различных типов частиц. Видно, что области, соответствующие разным типам частиц, достаточно хорошо разделены, особенно в области низких импульсов.

Важным преимуществом метода вторых моментов является его высокая устойчивость к шуму. Как видно из рисунка 4.1а, добавление пяти случайных точек шума не приводит к существенному снижению разделяющей способности. Это связано с тем, что метод использует интегральные характеристики изображения (моменты), которые менее чувствительны к отдельным шумовым пикселям.

4.2 ФИТИРОВАНИЕ ЭЛЛИПСОМ

На рисунках 4.1в и 4.1г представлены основные результаты работы данного метода. Анализ рисунка 4.1г показывает, что разделяющая способность, достигаемая методом фитирования эллипсом, несколько выше, чем у метода вторых моментов, в области низких импульсов. Однако данный метод значительно более чувствителен к шуму. Добавление всего лишь пяти случайных точек приводит к существенному снижению разделяющей способности.

4.3 РЕКОНСТРУКЦИЯ НА ОСНОВЕ ЗАВИСИМОСТИ АЗИМУТАЛЬНОГО УГЛА ЧЕРЕНКОВСКОГО КОНУСА ОТ ПОЛЯРНОГО

На рисунках 4.1д и 4.1е представлены основные результаты работы данного метода. Анализ рисунка 4.1д показывает, что данный метод обеспечивает наилучшую разделяющую способность среди трех рассмотренных методов.




Рисунок 4.1 — Разделяющая способность (а,в,д) и двумерные гистограммы θ_c vs p (б,г,е) для метода вторых моментов, фитирования эллипсом и реконструкции на основе зависимости θ_c от ϕ_c сверху вниз соответственно; серой горизонтальной линией отмечен порог в 3σ ; при оценке разделяющей способности при наличии шума добавлялось пять случайных точек.

5 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.

Создание и обучение нейросетей проводилось на языке Python с использованием фреймворка Pytorch [21].

5.1 ВАРИАНТЫ ОБРАБОТКИ СИГНАЛОВ ДЕТЕКТОРА С ИСПОЛЬЗОВАНИЕМ ИНФОРМАЦИИ О ТРЕКАХ ЧАСТИЦ

5.1.1 ВАРИАНТЫ АРХИТЕКТУР

Предлагаются два варианта архитектуры нейронных сетей для решения поставленной задачи:

- 1) Обработка неупорядоченных наборов точек, представленных координатами x и y .

1.1 Для получения векторного представления набора точек можно усреднить или максимизировать значения вдоль каждого канала (координаты x и y), затем выполнить конкатенацию полученного вектора с каждым вектором из набора точек и применить два полносвязных слоя с нелинейностью. Последовательное применение нескольких таких блоков с операцией глобального пулинга позволит получить век-

торное описание события, пригодное для дальнейшего анализа. Этот подход основан на архитектуре PointNet [22].

1.2 Набор точек также можно рассматривать как неупорядоченную последовательность, что позволяет использовать трансформеры и одномерные свертки.

2) Использование сверточных нейронных сетей (CNN) [23].

Основное преимущество первого подхода — меньшая вычислительная сложность, поскольку обработке подвергаются только ненулевые пиксели, число которых значительно меньше общего количества (например, на рис. 3.3 из 264x264 пикселей ненулевыми являются всего 3717). Однако в экспериментах данный подход показал значительно худшие результаты по сравнению с использованием двумерных сверток, поэтому в дальнейшем будут рассматриваться только они.

5.1.2 ПОДХОДЫ К ОБРАБОТКЕ МНОЖЕСТВА ТРЕКОВ

Для обработки множества треков предлагаются следующие три подхода:

- 1) Создание сжатого векторного представления (эмбединга) исходного изображения с использованием сверток и последующая обработка этого эмбединга совместно с вектором, описывающим трек каждой частицы (координаты и импульс). Этот подход может быть вычислительно эффективным при большом количестве частиц на событие (>100).
- 2) Обработка каждого трека независимо путем выделения интересующей области вокруг точки, обозначающей пересечение экстраполированного трека с плоскостью детектора.
- 3) Сегментация изображения: для каждого пикселя предсказание набора интересующих значений, а затем выделение только тех значений, которые лежат на точке пересечения экстраполированного трека с плоскостью детектора.

На практике эффективное сжатие пространственной информации в один вектор оказалось невозможным. В результате, при использовании первого подхода нейронная сеть предсказывала только константное значение, минимизирующее соответствующую функцию потерь.

В следующих секциях будут подробнее рассмотрены варианты два и три.




Рисунок 5.1 — Схема модели (вариант 1).

5.2 ПОЗИЦИОННОЕ КОДИРОВАНИЕ




Рисунок 5.2 — Пример входа модели с координатами.

Поскольку нейронная сеть обрабатывает область, вырезанную из полного изображения, она лишается информации об абсолютном положении трека. Для компенсации этой потери используется позиционное кодирование.

В данной секции будет рассмотрена важность позиционного кодирования. Для этого используется модель с независимой обработкой треков.

5.2.1 АРХИТЕКТУРА

Как показано на рис. 5.1, модель состоит из энкодера (последовательность сверточных и пулинговых слоев), который служит для извлечения признаков из входного изображения, и набора полносвязных слоев. Входной тензор имеет размерность $1 \times 25 \times 25$ без позиционного кодирования и $3 \times 25 \times 25$ с позиционным кодированием. Выходные значения соответствуют уверенности модели в идентификации зарегистрированной частицы. Для повышения интерпретируемости

и обобщающей способности модели, за несколько слоев до классификационного выхода добавлены дополнительные выходы регрессии, предсказывающие скорость и угол черенковского конуса.

Размер входного тензора выбран, исходя из следующих соображений: размер пикселя составляет $5.8 \times 5.8 \text{ мм}^2$, а максимальный радиус окружности, образуемой сечением черенковского конуса плоскостью детектора, составляет приблизительно 6 см. Следовательно, размер области 25×25 пикселей обеспечивает достаточное покрытие для обработки данных без потери информации.

При использовании позиционного кодирования в два дополнительных канала записываются номера бинов вдоль осей x и y (см. рис. 5.2). Эти значения затем нормируются на интервал $(-1, 1)$ для улучшения сходимости модели. Это позволяет модели: 1) получить информацию о масштабе колец, важную для определения скорости и угла, и 2) понимать положение точки входа частицы, что, в свою очередь, позволяет оценить угол ее вылета и угол наклона оси эллипса относительно плоскости детектора.

5.2.2 РЕЗУЛЬТАТЫ

На рисунке 5.3 показаны двумерные гистограммы, отображающие распределение угла черенковского конуса в зависимости от импульса, а также ROC-кривые. Микроусредненное значение ROC AUC составляет 0.987 ± 0.002 .

На рисунке 5.4 представлены аналогичные результаты: двумерные гистограммы для распределения угла черенковского конуса в зависимости от импульса и ROC-кривые. Микроусредненное значение ROC AUC в этом случае достигает 0.9994 ± 0.0001 , что свидетельствует о значительно более высокой точности модели. В дальнейшем эта модель будет использоваться в качестве основы для будущих исследований.

5.3 УСТОЙЧИВОСТЬ К ШУМУ

Следующим важным шагом является исследование устойчивости модели к шуму. Детектор в процессе работы будет генерировать ложные сигналы, поэтому важно обучить модель игнорировать их.

Для этого к входному изображению добавлялся шум, моделируемый рас-




Рисунок 5.3 — 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 и при микроусреднении.

пределением Бернулли: каждый пиксель с вероятностью $\mathbf{p}$ инвертировался. Было исследовано влияние различных уровней шума ($\mathbf{p}$ принимало разные значения) на качество работы модели.

5.3.1 БЕЗ ДОПОЛНИТЕЛЬНОЙ ОЧИСТКИ

В этой секции представлены результаты, полученные для базовой модели, описанной в секции 5.2.1. Дополнительная очистка не применялась: зашумленное изображение подавалось непосредственно на вход модели, а на выходе оценивались скорость, угол и тип частицы.

В таблице 5.1 представлены значения ROC AUC и MAE для угла черенковского конуса при различных уровнях шума. Как и ожидалось, качество предсказания ухудшается с увеличением уровня шума.




Рисунок 5.4 — 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 и при микроусреднении.




Рисунок 5.5 — Модель с дополнительным этапом очистки от шума.

5.3.2 С ДОПОЛНИТЕЛЬНЫМ ЭТАПОМ ОЧИСТКИ

Для повышения устойчивости к шуму был применен подход, включающий предварительную очистку изображения. Для этого к базовой модели (рис. 5.1) перед энкодером была добавлена небольшая UNet-подобная [24] сеть, состоящая из пары энкодер-декодер (рис. 5.5). Пример результата очистки зашумленного изображения представлен на рисунке 5.6.

В таблице 5.2 представлены значения ROC AUC и MAE для угла черенковского конуса при различных уровнях шума после применения этапа очистки. Качество предсказания по-прежнему ухудшается с увеличением уровня шума,

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 5.1 — Качество модели без дополнительной очистки при разных уровнях шума.




Рисунок 5.6 — Результат очистки от шума. Слева исходное изображение, по центру — результат работы нейросети, справа — искомое изображение.

хотя и в меньшей степени. Как видно из таблицы, применение этапа очистки позволяет несколько улучшить метрики качества по сравнению с моделью без очистки.

5.3.3 ОПТИМИЗИРОВАННАЯ АРХИТЕКТУРА С ЭТАПОМ ОЧИСТКИ

Предыдущая архитектура является вычислительно затратной из-за наличия дополнительного энкодера и декодера. Для снижения вычислительной нагрузки в новой архитектуре (рис. 5.7) второй энкодер был удален, а блок декодера вынесен за пределы основной вычислительной линии, что позволяет

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 5.2 — Качество модели с дополнительной очисткой при разных уровнях шума.




Рисунок 5.7 — Модель с вынесенным в сторону декодером.

отключать его, когда очистка изображения не требуется.

В процессе обучения в функцию потерь добавляется слагаемое, представляющее собой косинусное расстояние между выходами энкодера для зашумленного и очищенного изображений. Целью является максимизация этого расстояния, что способствует сохранению полезной информации при очистке.

Результаты, полученные для данной архитектуры, представлены в таблице 5.3.

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 5.3 — Качество модели с дополнительной очисткой при разных уровнях шума.

5.3.4 СРАВНЕНИЕ ПОЛУЧИВШИХСЯ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

В таблице 5.4 представлены итоговые значения метрик и время работы для трех рассмотренных моделей. Модель с отдельным этапом очистки (вторая модель) демонстрирует наивысшую точность, но и наибольшее время выполнения. Базовая модель (первая модель) и оптимизированная модель с очисткой (третья модель) показывают сравнимые результаты, однако первая не позволяет оценивать качество очистки изображения.

	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 5.4 — Финальное сравнение устойчивости к шуму для разных моделей.

В дальнейших главах шум создается с вероятностью, равномерно распределенной в интервале от 0 до 0.025.

5.3.5 СРАВНЕНИЕ НЕЙРОСЕТЕВЫХ И КЛАССИЧЕСКИХ МОДЕЛЕЙ




Рисунок 5.8 — Разделяющая способность (а) и двумерная гистограмма θ_c vs p (б) для нейросети; серой горизонтальной линией отмечен порог в 3σ ; при оценке разделяющей способности при наличии шума 1% случайных пустых пикселей обращались из 0 в 1.

Для сравнения с классическими моделями была выбрана самая первая модель, описанная в секции 5.2.1. На рис. 5.8а представлен график зависимости разделяющей мощности модели от импульса частицы. На рис. 5.8б представлена гистограмма θ_c vs p .

Из рис. 5.8а видно, что нейросеть превосходит по качеству метод вторых моментов и метод фитирования эллипсом и не уступает методу реконструкции на основе зависимости θ_c от ϕ_c , а при наличии шума – превосходит все три классических подхода.

5.4 СЕГМЕНТАЦИЯ ИСХОДНОГО ИЗОБРАЖЕНИЯ

Сегментация решает задачу классификации пикселей, присваивая каждому пикселю изображения метку, соответствующую определенному классу или области. В дополнение к этому, для распознавания сигналов с детектора FARICH необходимо для каждого пикселя решать задачу регрессии: предсказывать значение скорости (или угла черенковского конуса) частицы, проходящей через данный пиксель, основываясь на форме эллипса, создаваемого этой частицей (если таковой эллипс присутствует). В процессе работы (инференса) нейросети для повышения вычислительной эффективности достаточно рассматривать только те пиксели, через которые проходит реконструированный трек частицы.

Для решения этой задачи была реализована Unet-подобная [24] архитектура, адаптированная для задачи регрессии. Unet, известная своей эффективностью в задачах сегментации, обеспечивает сохранение пространственной информации, что критически важно для точного предсказания скорости.

На вход модели подается 4 канала: сигнал с детектора, два канала для позиционного кодирования, а также канал, в котором в соответствующих пикселях находятся значения импульсов, взятых из трекового детектора.

Результаты работы представлены на рис. 5.9. Видно, что такая модель по качеству на уровне модели с независимой обработкой треков.

Помимо задачи классификации частиц для оценки работы модели или для дополнительного анализа может потребоваться определение принадлежности хитов соответствующим трекам. Для этого для каждого пикселя решается задача бинарной классификации по числу частиц. Бинарная классификация была выбрана по той причине, что фотоны от нескольких частиц могут попасть в один хит. Пример работы нейросети показан на рис. 5.10.




Рисунок 5.9 — ROC AUC для классификации частиц при модели сегментации.




Рисунок 5.10 — Работа нейросети для определения, какому треку принадлежит каждый хит. Черным выделены шумовые хиты, соответствие обозначено одинаковыми цветами у хитов и центров треков. Крестиками обозначены хиты, для которых модель неверно определила частицу, квадратами — хиты, для которых модель верно определила частицу.

5.5 ИССЛЕДОВАНИЕ МАСШТАБИРУЕМОСТИ МОДЕЛЕЙ




Рисунок 5.11 — Влияние масштабируемости на качество моделей: (а) независимая обработка треков; (б) сегментация.

В этой секции исследуется влияние вычислительной сложности модели на ее эффективность. Для этого варьируются такие параметры, как глубина и ширина модели, а также функция активации.

Варьируемые параметры следующие:

- 1) Глубина: увеличение глубины на единицу соответствует добавлению 10 сверточных слоев.
- 2) Ширина: показывает количество каналов в скрытых слоях.
- 3) Функция активации: функция, обеспечивающая нелинейность в нейронной сети. Оценка вычислительной сложности (от наименьшей к наибольшей): ReLU, Tanh, Sigmoid.

Во время обучения к входным данным добавлялся шум, моделируемый распределением Бернулли, с вероятностью $\mathbf{p}$ в диапазоне от 0 до 0.025.

На рисунке 5.11 представлены графики, показывающие зависимость качества модели от количества параметров. Для модели с независимой обработкой треков наблюдается рост качества с увеличением числа параметров, однако темп роста постепенно снижается. В большинстве случаев наилучшие результаты достигаются при использовании гиперболического тангенса (Tanh) в качестве функции активации.




Рисунок 5.12 — Представление распределения по предсказанным углам черенковского конуса и скоростям в виде суммы распределений для верно классифицированных частиц и неверно классифицированных частиц.

Качество модели с сегментацией также демонстрирует тенденцию к росту с увеличением числа параметров, особенно в группах моделей с фиксированной шириной. Для этой архитектуры наилучшей функцией активации в большинстве случаев оказалась SiLU.

5.6 ИССЛЕДОВАНИЕ ИНТЕРПРЕТИРУЕМОСТИ МОДЕЛЕЙ

В данной секции исследуется, насколько связаны ее предсказания между собой и насколько им можно доверять. Рассматриваться будут две модели (с независимой обработкой треков и с сегментацией) со следующими параметрами: глубина «m» (в терминах из прошлой главы), ширина 64, функция активации - гиперболический тангенс.

Так как модели (рис. 5.1, рис. 5.7) на последнем слое выдают класс, а из слоев, находящихся ранее, выдают физические параметры, можно посмотреть, насколько эти предсказания связаны. На рис. 5.12 показано, как распределение по предсказанным углам черенковского конуса и скоростям раскладывается на сумму распределений для верно классифицированных частиц и неверно классифицированных частиц. Видна корреляция между неверной классификацией




Рисунок 5.13 — Калибровочные кривые для моделей с: (а) независимой обработкой треков; (б) сегментацией.

и неверной регрессией – если модель сильно ошиблась в предсказании скорости и угла черенковского конуса, то, скорее всего, она ошибется и в классификации.

Также, для классификации можно построить калибровочную кривую. Калибровочные кривые, также называемые диаграммами надежности ([25]), сравнивают, насколько хорошо откалиброваны вероятностные предсказания бинарного классификатора. Чем ближе кривая к прямой $y = x$, тем лучше откалиброван классификатор и тем больше вероятности, которые он выдает, соответствуют действительности. На рис. 5.13 представлены калибровочные кривые для модели с независимой обработкой треков (5.13а) и с сегментацией (5.13б).

5.7 ВАРИАНТЫ ОБРАБОТКИ СИГНАЛОВ ДЕТЕКТОРА БЕЗ ИСПОЛЬЗОВАНИЯ ИНФОРМАЦИИ О ТРЕКАХ ЧАСТИЦ

В условиях необходимости быстрой обработки сигналов может быть гораздо эффективнее не ждать информации о треках из другого детектора, а начинать обработку сразу, как только данные пришли из установки. Для этого есть два возможных подхода: сегментация и детекция. Сегментация рассматривалась выше. Отличие будет в том, что на входе не будет канала с импульсами, а на выходе не будет классификации.

Детекция отличается тем, что модель не предсказывает классы для каж-

дого пикселя, а предсказывает ограничивающие рамки, в которых лежит объект, уверенность в том, что в этих рамках объект действительно есть, а также непосредственно класс объекта в рамке. Из-за того, что размер выхода модели фиксированный, некоторая часть рамок будет пустыми. Для того, чтобы их отсеять, и используется уверенность.

В случае детектора FARICH нет необходимости предсказывать рамку – гораздо важнее предсказать точку предполагаемого пересечения трека с детектором. Таким образом, модель предсказывает для каждого объекта четыре числа: координаты x и y , вероятность, что через точку с такими координатами проходит трек, а также интересующую нас скорость (или угол черенковского конуса).

В процессе обучения для каждого целевого значения берется ближайшее предсказание и для него считается функция ошибки для регрессии. На предсказание уверенности обучаются все предсказания. Для этого введена эмпирическая формула:

$$conf = \begin{cases} \frac{0.6}{(r-0.75)^2+0.6} & \text{if } r > 0.75 \\ 1 & \text{else} \end{cases} \quad (5.1)$$

Здесь r – расстояние от предсказанной точки до ближайшего трека.

На стадии работы модели точки с низким значением уверенности удаляются, а для близко лежащих точек применяется алгоритм «подавление не максимумов» (non maximum suppression – nms): из всех точек, лежащих внутри некоторого радиуса, выбирается точка с наибольшей уверенностью, а остальные удаляются.

Результат работы модели, а затем алгоритма nms представлены на рис. 5.14

Качество детекции и качество детекции при условии, что по найденному углу можно предсказать тип частицы, показано на рис. 5.15. Видно, что модель достаточно хорошо находит треки, однако сильно уступает всем предыдущим моделям по качеству определения параметров частицы.




Рисунок 5.14 — Результат работы модели детекции (а) и алгоритма non maximum supression (б); красные точки – центры, предсказанные моделью, зеленые точки – истинные центры.




Рисунок 5.15 — Результат работы модели детекции (а) и алгоритма non maximum supression (б).

ЗАКЛЮЧЕНИЕ

В ходе исследования разработана сверточная нейросеть для предсказания скорости и типа регистрируемых частиц. Предложен и экспериментально подтвержден метод улучшения характеристик модели, основанный на позиционном кодировании, что позволило увеличить значение ROC AUC с 0.987 до 0.9994 на чистых данных.

Проведено сравнение модели с такими классическими подходами, как разделение методом вторых моментов, фитирование эллипсом, реконструкция по зависимости θ_c от ϕ_c . Модель способна разделять с уверенностью в 3σ пионы и каоны в диапазоне импульсов до 5 ГэВ, протоны и каоны в диапазоне импульсов до 8 ГэВ. Полученная модель сравнима с классическими подходами, а уже при уровне шума 1% превосходит их.

Исследована устойчивость разработанных моделей к шумовым искажениям, имитирующим реальные условия работы детектора. Для повышения устойчивости к шуму предложена и протестирована архитектура, включающая этап предварительной очистки изображений от шума, которая позволила увеличить ROC AUC с 0.9966 до 0.9978.

Исследована масштабируемость моделей, а также их интерпретируемость. Подтверждена взаимосвязь регрессионных выходов с классификационными. Построены калибровочные кривые для классификации.

Также предложена архитектура для сегментации и детекции треков для обработки сигналов из детектора FARICH параллельно с обработкой сигналов из трекового детектора. Модель для сегментации дополнительно обучена определять принадлежность хитов к родительским трекам.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Conceptual design of the Spin Physics Detector / V. M. Abazov [и др.]. — 2022. — arXiv: 2102.00442 [hep-ex].
2. Technical Design Report of the Spin Physics Detector at NICA / T. S. Collaboration [и др.]. — 2024. — arXiv: 2404.08317 [hep-ex].
3. *Kacharava A., Wilkin C.* Results from the spin programme at COSY-ANKE. — 2012. — arXiv: 1212.2771 [nucl-ex].
4. *Bruck H., Laclare J. L., Leleux G.* SATURNE-II: Proposal of a Renovated Proton Facility at Saclay. // 9th International Conference on High-Energy Accelerators. — 1974. — С. 615—617.
5. The LHCspin project / M. Santimaria [и др.] // SciPost Physics Proceedings. — 2022. — № 8. — ISSN 2666-4003.
6. Physics perspectives with AFTER@LHC (A Fixed Target Experiment at LHC) / L. Massacrier [и др.] // EPJ Web of Conferences / под ред. A. Mischke, P. Kuijer. — 2018. — Т. 171. — С. 10001. — ISSN 2100-014X.
7. *Staric M., Krizan P.* An iterative method for the analysis of Cherenkov rings in the HERA-B RICH // Nucl. Instrum. Meth. A / под ред. A. Breskin, R. Chechik, T. Ypsilantis. — 1999. — Т. 433. — С. 279—285.
8. *Schöning A.* Particle identification in the RICH detectors and study of impact parameters. — 1997.
9. *Forty R. W., Schneider O.* RICH pattern recognition. — 1998.
10. *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.

11. *Gath I., Hoory D.* Fuzzy clustering of elliptic ring-shaped clusters // Pattern Recognition Letters. — 1995. — Т. 16, № 7. — С. 727–741. — ISSN 0167-8655.
12. *Hough V P. C.* Method and means for recognizing complex patterns. — 1962.
13. *Chernov N. I., Ososkov G. A.* Effective Algorithms of Circle Fitting // Comput. Phys. Commun. — 1984. — Т. 33. — С. 329–333.
14. *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.
15. *Bobrovnikov V. S.* FARICH simulation. — 2020. — *2nd CREMLINplus WP5 General Meeting, Novosibirsk, 28-29 September, 2020.*
16. Recent developments in Geant4 / J. Allison [и др.] // Nucl. Instrum. Meth. A. — 2016. — Т. 835. — С. 186–225.
17. Geant4 developments and applications / J. Allison [и др.] // IEEE Transactions on Nuclear Science. — 2006. — Т. 53, № 1. — С. 270–278.
18. GEANT4—a simulation toolkit / S. Agostinelli [и др.] // Nucl. Instrum. Meth. A. — 2003. — Т. 506. — С. 250–303.
19. *Lippmann C.* Particle identification // Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment. — 2012. — Т. 666. — С. 148–172. — ISSN 0168-9002.
20. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python / P. Virtanen [и др.] // Nature Methods. — 2020. — Т. 17. — С. 261–272.
21. Automatic differentiation in PyTorch / A. Paszke [и др.]. — 2017.
22. PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation / C. R. Qi [и др.]. — 2017. — arXiv: 1612.00593 [cs.CV].
23. *LeCun Y., Bengio Y.* Convolutional networks for images, speech, and time series // The Handbook of Brain Theory and Neural Networks. — Cambridge, MA, USA : MIT Press, 1998. — С. 255–258. — ISBN 0262511029.
24. *Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation. — 2015. — arXiv: 1505.04597 [cs.CV].

25. *Wilks D., Wolfe D.* Optimal use and economic value of weather forecasts for lettuce irrigation in a humid climate // *Agricultural and Forest Meteorology*. — 1998. — T. 89, № 2. — C. 115—129. — ISSN 0168-1923.