



МОДЕЛИРОВАНИЕ И РЕКОНСТРУКЦИЯ СОБЫТИЙ В МЮОННОЙ СИСТЕМЕ УСТАНОВКИ SPD

Студент магистратуры: Осетров Александр Олегович

Научный руководитель: Солдатов Евгений Юрьевич

Научный консультант: Верхеев Александр Юрьевич

Национальный исследовательский ядерный
университет «МИФИ», г. Москва 2025



О работе

- Для проектирования установки и изучения возможности решения поставленных физических задач в эксперименте необходимо моделирование различных детекторных систем.
- Необходимо построение алгоритмов и методик обработки и анализа экспериментальных данных.
- Цель работы: моделирование прототипа мюонной системы SPD и разработка программного обеспечения для обработки и анализа данных эксперимента.

Задачи

- Моделирование прототипа системы
- Кластеризация хитов
- Тестирование алгоритмов машинного обучения
- Сравнительный анализ алгоритмов идентификации мюонов

Эксперимент SPD

Цель эксперимента - изучение спиновой структуры протона и дейтрона и других спиновых явлений в столкновениях поляризованных p-p, d-d и p-d пучков с $\sqrt{s} = 27$ ГэВ и светимостью порядка $10^{32} \text{ см}^{-2} \text{ с}^{-1}$.





Рис. 1 Общая схема установки SPD

Мюонная система



- Идентификации мюонов в присутствии значительного адронного фона и оценки энергии адронов (грубая адронная калориметрия).
- Состоит из восьмимодульного барреля и двух торцевых дисков.
- В межслоевые зазоры помещаются Mini Drift Tubes (MDT) детекторы и считывающая электроника.

Рис. 2 Схематичный вид мюонной системы

MDT детектор




Рис. 3 Поперечное сечение детектора MDT

- Состоит из металлического катода (алюминиевый гребенчатый профиль из 8 ячеек), анодных проволочек и пластиковой оболочки (норил) для газонепроницаемости.
- Перпендикулярная стриповая плоскость вместе с системой анодных проволочек дают две координаты прохождения частицы.

Геометрическая модель прототипа




Рис. 4 Геометрическая модель прототипа мюонной системы SPD

- MDT детектор из восьми ячеек, заполненных газовой смесью $\text{Ar} + \text{CO}_2$.
- 6 MDT объединены в одну детекторную плоскость
- В железном корпусе размещено 16 детекторных плоскостей с железными поглотителями с шагом в 35 мм для размещения считывающей электроники.
- Bilayer, состоящий из двух детекторных плоскостей, по 4 MDT детектора. За ними расположен железный лист толщиной 60 мм.
- Модель создана при помощи геометрического пакета ROOT и интегрирована в SpdRoot




Рис. 5 Моделирование прохождения протона (слева) и мюона (справа)
с энергиями 5 и 10 ГэВ

Верхние рисунки – 5 ГэВ, нижние – 10 ГэВ

Алгоритм кластеризации DBSCAN

DBSCAN – это метод кластеризации, который идентифицирует кластеры на основе плотности точек в пространстве данных. Он особенно хорошо работает с кластерами произвольной формы и справляется с шумами в данных.

Ключевые понятия:

- ϵ -окрестность точки p , обозначаемая как $N_\epsilon(p)$
- MinPts (Минимальное количество точек в ϵ -окрестности точки p)
- Основная точка (Core Point)
- Пограничная точка (Border Point)
- Шумовая точка (Noise Point)




Рис. 6 Иллюстрация работы DBSCAN.
Сверху изображен оригинальный набор точек, снизу –
результат работы алгоритма DBSCAN

Алгоритм кластеризации DBSCAN

Поскольку стандартные библиотеки C++ не включают готовую реализацию DBSCAN, была выполнена адаптация этого алгоритма из других библиотек с последующей интеграцией в SpdRoot.

На рис. 7 представлен пример сравнения результата работы алгоритма DBSCAN, реализованного на C++, с результатом стандартной версии из библиотеки scikit-learn языка Python для смоделированного события J/ψ.




Рис. 7 Пример визуального сравнения работы двух реализаций алгоритма DBSCAN

Алгоритм кластеризации DBSCAN

Проведен сравнительный анализ работы адаптированного под SpdRoot алгоритма DBSCAN с существующей реализацией, опирающейся на данные моделирования Монте-Карло. Построены распределения количества кластеров в событии для мюонов и протонов с характерными энергиями 2 и 9 ГэВ, представленные на рис. 8.




Рис. 8 Распределение по количеству сформированных кластеров
Слева дано распределение для мюонов, справа – для протонов

Нейронные сети

Искусственные нейронные сети представляют собой модели машинного обучения, основанные на принципах функционирования биологических нейронных сетей мозга. Они состоят из множества взаимосвязанных узлов — искусственных нейронов, организованных в слои




Рис. 9 Схема работы искусственного нейрона в нейронных сетях




Рис. 10 Схема искусственной нейронной сети

Свёрточные нейронные сети

Свёрточные нейронные сети (CNN) представляют собой специализированную архитектуру искусственных нейронных сетей, разработанную для эффективного распознавания и обработки данных с сеточной структурой, таких как изображения.




Рис. 11 Применение свертки в свёрточном слое




Рис. 12 Структура свёрточной нейронной сети

Дерево решений

На каждом узле дерева происходит бинарное разбиение входного множества примеров: одно подмножество содержит объекты, удовлетворяющие условию узла, другое – не удовлетворяющие. Данная процедура рекурсивно применяется к полученным подмножествам до выполнения критериев остановки алгоритма




Рис. 13 Пример схемы работы дерева решений

Алгоритм классификации: CNN

Структура свёрточной нейронной сети:

Вход: $128 \times 128 \times 1$ (H×W×C)

Conv2D (16, 3×3 , ReLU) → MaxPool (2×2) → $64 \times 64 \times 16$

Conv2D (32, 3×3 , ReLU) → MaxPool (2×2) → $32 \times 32 \times 32$

Conv2D (64, 3×3 , ReLU) → MaxPool (2×2) → $16 \times 16 \times 64$

Flatten → 16384

Dense (128, ReLU) → 128

Dense (2, linear) → 2

Softmax → $[p_1, p_2]$

Алгоритм классификации: CNN




Рис. 14 Примеры входных изображений для CNN
Слева – мюон, справа – протон.

Алгоритм классификации: CNN






Рис. 15 Пример событий для CNN: проекции треков в детекторе

Алгоритм классификации: CNN




Рис. 16 Матрица ошибок для CNN




Рис. 17 ROC-кривые для CNN

Алгоритм классификации: XGBoost

Основные параметры модели:

- Количество деревьев в ансамбле: 100
- Максимальная глубина каждого дерева: 3 уровня
- Функция потерь: бинарная логистическая (binary:logistic)

Переменные для классификации:

- Среднее количество хитов на детекторную плоскость
- Максимальное количество хитов в одной плоскости
- Стандартное отклонение углового распределения




Рис. 18 Диаграмма важности признаков для модели бустинга

Алгоритм классификации: XGBoost




Рис. 19 Матрица ошибок для XGBoost




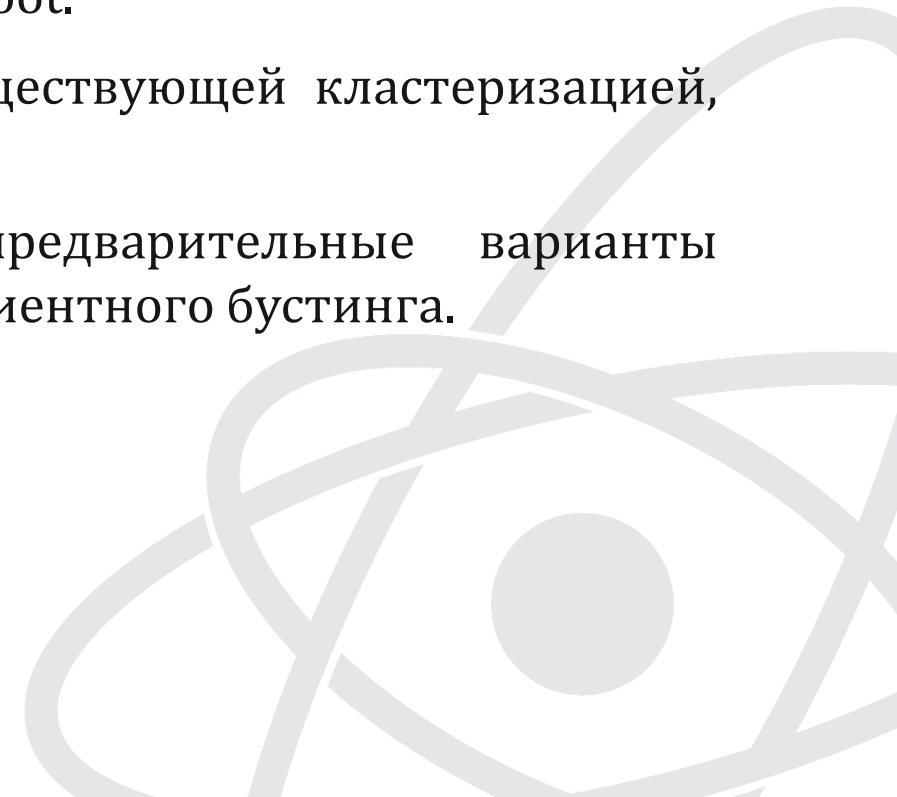
Рис. 20 ROC-кривая для XGBoost

Сравнительный анализ моделей


Метрика	CNN	XGBoost
Accuracy	0.92	0.93
Precision	0.91	0.91
Recall	0.92	0.96
F1-score	0.92	0.93

Заключение



- Смоделирован и интегрирован в SpdRoot прототип мюонной системы эксперимента SPD.
- В среде SpdRoot выполнено моделирование и визуализация событий, получен набор хитов частиц.
- Реализована версия алгоритма кластеризации DBSCAN на C++ для формирования кластеров частиц. Разработка интегрирована в среду SpdRoot.
- C++ реализация алгоритма DBSCAN сопоставлена с существующей кластеризацией, основанной на данных Монте-Карло.
- Разработаны и сравнительно проанализированы предварительные варианты алгоритмов идентификации мюонов на основе CNN и градиентного бустинга.




Дополнительные слайды



Дополнительные слайды



Дополнительные слайды



Дополнительные слайды

Частица	Энергия, ГэВ	$\bar{n}_{\text{DBSCAN}}$	$\bar{n}_{\text{MC}}$	$\bar{n}_{\text{DBSCAN}} - \bar{n}_{\text{MC}}$
μ	2	1.05	1.00	0.05
μ	3	1.04	1.00	0.04
μ	4	1.05	1.00	0.05
μ	5	1.04	1.00	0.04
μ	6	1.03	1.00	0.03
μ	7	1.04	1.00	0.04
μ	8	1.04	1.01	0.03
μ	9	1.03	1.01	0.02
μ	10	1.04	1.01	0.03
p	2	1.03	1.06	-0.03
p	3	1.13	1.21	-0.08
p	4	1.29	1.44	-0.15
p	5	1.36	1.62	-0.26
p	6	1.46	1.96	-0.50
p	7	1.60	2.05	-0.45
p	8	1.68	2.34	-0.66
p	9	1.69	2.48	-0.79
p	10	1.78	2.83	-1.05