

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

**ОТЧЁТ О  
НАУЧНО-ИССЛЕДОВАТЕЛЬСКОЙ РАБОТЕ  
ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ  
ДЛЯ ЗАДАЧИ КЛАССИФИКАЦИИ ЧАСТИЦ В  
СЦИНТИЛЛЯЦИОННЫХ ДЕТЕКТОРАХ**

Студент

\_\_\_\_\_ А. А. Козлов

Научный руководитель,  
ассистент кафедры 40

\_\_\_\_\_ Д. В. Попов

Москва 2025

# СОДЕРЖАНИЕ

<b>Введение</b>	<b>2</b>
<b>1 Литературный обзор актуальных задач машинного обучения в физике частиц</b>	<b>4</b>
1.1 ML в задачах ускорительной физики . . . . .	4
1.2 ML в задачах нейтринной физики . . . . .	5
1.3 Сравнение эффективности методов ML и PSD . . . . .	7
<b>2 Реализация методов машинного обучения для классификации частиц</b>	<b>9</b>
2.1 Описание модели эксперимента и формата экспериментальных данных . . . . .	9
2.2 Метод PSD . . . . .	10
2.3 Работа с экспериментальными данными и конструирование признаков . . . . .	12
2.3.1 Конструирование признаков . . . . .	12
2.3.2 Методика обучения моделей на экспериментальных данных . . . . .	13
2.4 Применение классических ML-алгоритмов для классификации частиц . . . . .	14
2.4.1 Модель логистической регрессии . . . . .	14
2.4.2 Модель Boosted Decision Tree (BDT) . . . . .	16
2.5 Обсуждение результатов . . . . .	18
<b>Заключение</b>	<b>20</b>
<b>Список использованных источников</b>	<b>21</b>

# ВВЕДЕНИЕ

В последние годы методы машинного обучения стали неотъемлемой частью анализа данных в физике элементарных частиц. Существенный рост интенсивности экспериментальных установок, увеличение числа каналов регистрации и переход к детекторам с высокой временной и пространственной разрешающей способностью приводят к формированию больших объёмов многомерных данных, ручная обработка которых становится практически невозможной. В таких условиях классические методы анализа, основанные на одном или нескольких заранее выбранных параметрах, часто оказываются недостаточно гибкими и не позволяют в полной мере использовать всю информацию, содержащуюся в экспериментальных сигналах.

Одним из широко применяемых подходов в экспериментах со сцинтилляционными детекторами является метод дискриминации по форме импульса (Pulse Shape Discrimination, PSD), позволяющий различать частицы на основе различий во временной структуре сигнала. Несмотря на свою простоту и физическую наглядность, метод PSD обладает рядом существенных ограничений. Это делает актуальным поиск альтернативных методов анализа, способных учитывать корреляции между различными характеристиками формы импульса и обеспечивать более устойчивую и универсальную классификацию событий.

Методы машинного обучения, и в частности классические алгоритмы supervised learning, предоставляют эффективный инструментарий для решения подобных задач. Использование моделей машинного обучения позволяет работать с многомерными пространствами признаков, автоматически выявлять значимые зависимости в данных и формировать оптимальные разделяющие поверхности между классами событий. При этом такие методы, как логистическая регрессия и ансамбли решающих деревьев, сохраняют интерпретируемость и вычислительную эффективность, что особенно важно для применения в физическом анализе и при работе с экспе-

риментальными данными.

Целью данной работы является исследование возможности применения классических методов машинного обучения для задачи классификации частиц в сцинтилляционном детекторе типа Phoswich. В рамках работы проводится построение набора физически осмысленных признаков, извлечённых из временной формы сигнала, обучение и тестирование моделей логистической регрессии и Boosted Decision Trees (AdaBoost), а также сравнение их эффективности с традиционным методом PSD. Уделяется внимание анализу сильных и слабых сторон рассматриваемых моделей, их устойчивости к коррелированным признакам и способности обобщать результаты на независимых экспериментальных данных.

# 1 ЛИТЕРАТУРНЫЙ ОБЗОР АКТУАЛЬНЫХ ЗАДАЧ МАШИННОГО ОБУЧЕНИЯ В ФИЗИКЕ ЧАСТИЦ

## 1.1 ML В ЗАДАЧАХ УСКОРИТЕЛЬНОЙ ФИЗИКИ

Одними из первых в физике частиц машинное обучение успешно применили в ускорительной физике высоких энергий (HEP). Необходимость этого была продиктована спецификой ускорительных экспериментов: во-первых, необходимо было фильтровать приходящие события с многочисленных каналов электроники, чтобы избежать перегрузки хранилищ ненужными данными. Во-вторых, эффективная ручная обработка собранных экспериментальных данных представлялась фактически невозможной в силу их объёма и масштабов. Лидером в вопросах внедрения методов машинного обучения стала коллаборация LHC. Рассмотрим на примере основных экспериментов LHC использованные подходы в работе с ИИ.

В экспериментах ATLAS и CMS применялись системы отбора событий в режиме реального времени ("Real-time analysis"), проводившие отбор событий до записи их данных в базу данных. Это позволило существенно уменьшить объём данных для анализа: в среднем сохранялось лишь 1 событие из 100000, однако даже такой жёсткий отбор давал порядка 20 петабайт данных в год [1].

Вместе с тем CMS использует машинное обучение в аппаратном обеспечении триггера для более точной оценки импульса мюонов [2]. При этом входные данные алгоритма дискретизируются, чтобы ответ машинного обучения можно было закодировать в большой справочной таблице, которую

легко запрограммировать на ПЛИС.

В случае эксперимента LHCb многие из событий, представляющих наибольший интерес, не оставляют заметных следов в детекторе, что делает необходимым тщательный анализ многомерных пространств признаков в режиме реального времени для эффективной классификации событий<sup>29</sup>. С первого года сбора данных LHCb основным алгоритмом, используемым для такой классификации, было машинное обучение; в частности, в течение первых двух лет использовался алгоритм Boost Decision Tree [3], который с тех пор был заменен алгоритмом matrixnet. В настоящее время 70% всех сохраняемых данных классифицируются с помощью алгоритмов машинного обучения, а все треки заряженных частиц проверяются нейронными сетями [4].

Помимо прочих для обработки экспериментальных данных активно применяются рекуррентные нейронные сети (RNN) и сверточные нейронные сети (CNN). RNN используются в задаче классификации струй, например, в экспериментах с b-кварком [5]. CNN применяются для анализа изображений с нейтринных экспериментов NOvA [6] и MicroBooNE [7]. В эксперименте NoVA применение CNN позволило увеличить эффективность отбора электронных нейтрино на 40%. В эксперименте MicroBooNE CNN используется для отбора полезных событий в реальном времени.

## 1.2 ML В ЗАДАЧАХ НЕЙТРИННОЙ ФИЗИКИ

В последние годы методы машинного обучения (ML) стали важным инструментом в физике нейтрино, прежде всего в задачах реконструкции параметров событий и подавления фона. Особый интерес представляют некоторые классические методы машинного обучения, такие как, например, популярный в анализе данных метод Boosted Decision Trees (BDT), поскольку такие методы сочетают высокое качество предсказаний с интерпретируемостью и вычислительной эффективностью.

Одним из наиболее актуальных нейтринных экспериментов является

эксперимент JUNO (Jiangmen Underground Neutrino Observatory), физический запуск которого произошёл в 2025 году. Командой JUNO был разработан собственный набор данных для моделирования эксперимента в среде GEANT4, что позволило начать обучение ML-моделей на результатах моделирования. Характерным примером успешного применения классического ML является работа [8], в которой BDT используются для реконструкции энергии нейтринных событий в JUNO. Авторы формулируют задачу как supervised-регрессию и используют агрегированные признаки, построенные на основе суммарного числа фотоэлектронов и временных характеристик сигналов фотомножителей. Ключевым результатом работы является демонстрация того, что BDT-модель с небольшим числом тщательно отобранных признаков достигает энергетического разрешения, сопоставимого с результатами более сложных глубоких нейросетевых архитектур (CNN, GNN), при существенно меньших вычислительных затратах. Это подчёркивает, что в задачах нейтринной физики качество реконструкции определяется не только сложностью модели, но и физически осмысленным выбором входных признаков. Таким образом, классические методы машинного обучения остаются конкурентоспособным и практически значимым инструментом для анализа данных современных и будущих нейтринных экспериментов.

Методы машинного обучения применяются и в других крупных нейтринных экспериментах. В частности, в статье [9], посвящённой эксперименту PROSPECT (The Precision Reactor Oscillation and Spectrum Experiment) задача реконструкции параметров нейтринных событий также формулируется в терминах supervised learning, однако основной акцент делается на сравнении нескольких ML-подходов. В работе исследуются методы, использующие CNN и графовые нейронные сети (GNN). CNN и GNN обучались на данных, отражающих энергетическую и временную структуру события. Результатом работы стало увеличение полезной статистики эксперимента на 3.3%.

## 1.3 СРАВНЕНИЕ ЭФФЕКТИВНОСТИ МЕТОДОВ ML И PSD

Одним из классических методов классификации событий в экспериментах с сцинтилляционными детекторами является метод PSD (Pulse Shape Discrimination). В рамках этого метода изучается аппаратная форма сигнала, возникающего в детекторе при прохождении той или иной частицы, например, гамма-кванта или нейтрона. В силу различного характера взаимодействия с веществом сцинтиллятора возникают различия в форме сигнала, наблюдаемого на выходе детектора.

Однако такой подход имеет ряд недостатков: во-первых, ручной выбор окна интегрирования для получения заряда провоцирует неизбежные расхождения в экспериментальных данных; во-вторых, в рамках данного подхода теряется информация о характеристиках сигнала, заменяемых единственной величиной зарядового интеграла, тогда как данные о форме импульса также являются мощным фактором отбора и классификации событий; в-третьих, метод PSD очень зависим от выбора конкретной электроники и её шумовых характеристик, а также выборе рабочего напряжения.

Все обозначенные недостатки классического метода PSD могут быть исправлены при внедрении даже классических методов ML, т.е. без использования нейросетевых технологий: грамотный feature-engineering и использование пайплайнов позволяют нивелировать недостатки метода PSD для классификации частиц.

В эксперименте, описываемом в данной статье [10], был создан компактный phoswich-детектор. Из временных форм импульсов извлекался набор PSD-признаков. Эти признаки использовались для обучения алгоритма Boosted Decision Tree, который научился учитывать корреляции между характеристиками формы импульса, недоступные классическим одномерным методам. Применение ML позволило компенсировать искажения сигнала, возникающие при прохождении света от внутреннего сцинтиллятора через



жидкий слой, и обеспечить надёжную классификацию событий по месту их возникновения.

В другой статье [11] был выполнен эксперимент с использованием двух детекторов, объединённых в time-of-flight конфигурацию, что позволило надёжно различать нейтроны и гамма-кванты и формировать качественную обучающую выборку для supervised ML. После предварительной обработки полных форм импульсов эти данные использовались для обучения моделей Decision Tree (DT), Random Forest (RF) и Back-Propagation Neural Network (BPNN). Наилучшие результаты показала BPNN, которая смогла эффективно уменьшить ошибки классификации.

## 2 РЕАЛИЗАЦИЯ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ КЛАССИФИКАЦИИ ЧАСТИЦ

### 2.1 ОПИСАНИЕ МОДЕЛИ ЭКСПЕРИМЕНТА И ФОРМАТА ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ

Экспериментальная установка представлена детектором типа "Phoswich" (phoswich sandwich), включающим в себя быстрый пластиковый сцинтиллятор, тонкий сцинтиллятор типа LCS (литий-кальций-силикат), а также классический сцинтиллятор NaI(Tl), предназначенный для реализации схемы задержанных совпадений.




Рисунок 2.1 — Схема эксперимента Phoswich

Источником излучения выступил калифорний-252, излучающий гамма-кванты, а также быстрые нейтроны, замедляемые окружающим источником парафином. Регистрация событий происходит по двум каналам: с пластикового сцинтиллятора и с NaI(Tl), что позволяет отслеживать связанные между собой события.

Сигналы с ФЭУ, присоединённых к сцинтилляторам, собирались и записывались при помощи DAQ. Это позволило сохранить максимально большое количество информации о событии в виде его осциллограммы, которая после будет использована для обучения модели ML. Пример характерной записи одного события представлен на рисунке 2.2. Далее из записанного сигнала извлекалась дополнительная информация при помощи ROOT-скрипта.




Рисунок 2.2 — Типичная форма записи сигнала с детектора Phoswich

## 2.2 МЕТОД PSD

PSD (Pulse Shape Discrimination) - классический метод анализа экспериментальных данных и классификации частиц в ядерной физике и в экспериментах с событиями типа "нейтрон-гамма" в частности. В рамках этого метода исследуется форма и длительность сигнала, приходящего с детектора, чтобы по различию в зарядовом интеграле классифицировать событие и отделить его от остальных. Классический график распределения PSD value в зависимости от полного заряда представлен на рисунке 2.3




Рисунок 2.3 — Классический метод PSD для эксперимента Phoswich

На графике PSD отчётливо выделяются несколько характерных областей, отвечающих различным типам частиц: во-первых, область с большим PSD value (длинные сигналы) и средним суммарным зарядом отвечает нейтронным событиям, во-вторых, область с малым PSD value (короткие сигналы) и средним суммарным зарядом (до 30 тысяч) отвечает событиям, связанным с гамма-квантами, и в-третьих, длинный "хвост" с низким PSD value и большим зарядом соответствует событиям с жёсткими высокоэнергичными мюонами, создающими дополнительный фон.

Отсюда сразу же становится ясен первый недостаток метода PSD: он не уточняет, какие события лежат за оговорёнными ранее промежутками, так как их однозначная классификация по PSD value затруднена, что потенциально лишает экспериментальные данные полезных событий. Другими немаловажными минусами метода PSD являются произвол в выборе PSD-value-критерия, произвол в выборе ворот интегрирования сигнала, а также очевидная сильная зависимость результатов построения графика от характеристик электроники. Методы машинного обучения будут призваны устранить эти недостатки в задаче классификации частиц.

## 2.3 РАБОТА С ЭКСПЕРИМЕНТАЛЬНЫМИ ДАННЫМИ И КОНСТРУИРОВАНИЕ ПРИЗНАКОВ

Данные о событиях, зарегистрированных детектором, хранятся в формате ROOT-деревьев, откуда они могут быть извлечены ROOT-скриптами для дальнейшей работы и обучения модели.

### 2.3.1 КОНСТРУИРОВАНИЕ ПРИЗНАКОВ

В качестве основных признаков для модели было решено использовать следующие характеристики распределения:

- Front Time - время нарастания переднего фронта сигнала
- Tale Time - время спада заднего фронта сигнала
- FWHM - полная ширина на половине высоты
- skewness - коэффициент асимметрии формы сигнала
- curtosis - четвёртый момент распределения, эксцесс
- $Q_{total}/Q_{muon}$  - полный заряд, нормированный на заряд мюонов

Параметр PSD value также рассматривался в качестве потенциального признака для обучения модели, однако был отвергнут в силу своей нефизичности.

Обучающие данные для модели были отобраны и размечены при помощи использования классического метода PSD, который позволил точно отделить между собой события трёх классов: гамма, нейтрон и мюон. Соответственно, для всех трёх классов был составлен общий набор обучающих данных, включающий в себя каждый вышеупомянутый признак. Между некоторыми признаками при детальном изучении можно наблюдать высокий коэффициент корреляции, что следует учитывать при построении моделей, чувствительных к мультиколлинеарности.




Рисунок 2.4 — Матрица корреляций признаков

### 2.3.2 МЕТОДИКА ОБУЧЕНИЯ МОДЕЛЕЙ НА ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ

Алгоритм обучения модели на экспериментальных данных можно представить в следующем виде:

- 1) При помощи классического метода PSD получают размеченные обучающие данные трёх классов событий: нейтроны, гамма и мюоны
- 2) Размеченные данные разбиваются на train-test набор для тренировки модели и проверки её эффективности
- 3) При необходимости происходит масштабирование признаков, скейлер сохраняется для дальнейшего использования модели
- 4) Производится обучение модели и оценка её эффективности
- 5) Также проводится дополнительная валидация данными с гамма-источника, полученными на той же экспериментальной установке.

## 2.4 ПРИМЕНЕНИЕ КЛАССИЧЕСКИХ ML-АЛГОРИТМОВ ДЛЯ КЛАССИФИКАЦИИ ЧАСТИЦ

### 2.4.1 МОДЕЛЬ ЛОГИСТИЧЕСКОЙ РЕГРЕССИИ

Логистическая регрессия является линейным вероятностным классификатором, в котором для вектора признаков  $x \in \mathbb{R}^d$  вычисляется линейная комбинация  $z = w^\top x + b$ , после чего к ней применяется сигмоидная функция  $\sigma(z) = \frac{1}{1+e^{-z}}$ , интерпретируемая как условная вероятность принадлежности объекта положительному классу:  $P(y = 1 \mid x) = \sigma(w^\top x + b)$ . Обучение модели сводится к минимизации логистической функции потерь (кросс-энтропии)  $\mathcal{L} = -\frac{1}{n} \sum_{i=1}^n [y_i \log p_i + (1 - y_i) \log(1 - p_i)]$  с регуляризацией, а классификационное решение принимается по порогу вероятности, обычно  $p_i \geq 0.5$ .




Рисунок 2.5 — Пример сигмоиды, используемой в задаче классификации логистической регрессии

Модель логистической регрессии из библиотеки `scikit-learn` была обучена на размеченных данных по принципу "One-VS-Others" для реализации механизма мультиклассовой классификации. В качестве параметра "solver" был использован алгоритм "saga" включающий в себя использования L1-регуляризации - это позволило работать с набором признаков, которые имеют близкий по модулю к единице коэффициент корреляции.

Результаты обучения модели представлены в confusion-matrix и классификационном отчёте по результатам тестирования на тестовых данных, не участвующих в обучении.




Рисунок 2.6 — Confusion-Matrix для модели логистической регрессии (по вертикали истинные значения, по горизонтали – предсказания модели)

	precision	recall	f1-score	support
gamma	1.00	1.00	1.00	3830
muon	1.00	1.00	1.00	327
neutron	1.00	1.00	1.00	3439
accuracy			1.00	7596
macro avg	1.00	1.00	1.00	7596
weighted avg	1.00	1.00	1.00	7596

Рисунок 2.7 — Классификационный отчёт с метриками мо

Из предложенных к ознакомлению метрик видно, что даже простая логистическая регрессия идеально описала экспериментальные данные из известных областей PSD-графика. Однако не меньший интерес представляет собой работа модели на данных из валидационной выборки, где в эксперименте использовался источник цезий-137, излучающий лишь гамма-кванты. По результатам применения обученной ранее модели к таким данным и с использованием порога уверенности в классификации частицы в 80% метрика accuracy score составила для модели 0.93. Также для наглядности было проделано разбиение данных с графика PSD по типам частиц, где также фигурирует класс "N/C "Not Classified в рамках которого остаются частицы с вероятностью принадлежности к конкретному классу менее 80%.






Рисунок 2.8 — Разметка частиц классификатором линейной регрессии

## 2.4.2 МОДЕЛЬ BOOSTED DECISION TREE (BDT)

Бустинговый классификатор на решающих деревьях в постановке AdaBoost представляет собой ансамбль слабых классификаторов  $h_t(x)$  (как правило, неглубоких деревьев решений), которые последовательно обучаются на одной и той же выборке с адаптивным перераспределением весов объектов: на каждом шаге больший вес получают неправильно классифицированные примеры. Итоговая модель имеет вид взвешенной суммы  $F(x) = \sum_{t=1}^T \alpha_t h_t(x)$ , где коэффициенты  $\alpha_t = \frac{1}{2} \ln \frac{1-\varepsilon_t}{\varepsilon_t}$  зависят от ошибки  $\varepsilon_t$  очередного классификатора. Классификационное решение принимается по знаку функции  $F(x)$ , что эквивалентно минимизации экспоненциальной функции потерь  $\mathcal{L} = \sum_{i=1}^n \exp(-y_i F(x_i))$ . Другими словами, модель строит множество деревьев решений (Decision Tree), причём делает это последовательно, учитывая для каждого следующего дерева ошибку предшественника при помощи повышения весов неправильно классифицированных точек.

Модель была обучена при помощи метода AdaBoost из библиотеки

scikit-learn, в качестве классификатора использовался метод Decision Tree, оптимальное число слабых классификаторов составило 20. Результаты проверки модели на тестовом наборе данных приведены ниже.




Рисунок 2.9 — Confusion-Matrix для модели BDT (по вертикали истинные значения, по горизонтали – предсказания модели)

Также модель BDT проводит оценку важности каждого признака для принятия решения о классификации частицы. Результаты весов для каждого признака приведены ниже:

Front Time	0.0
Tale Time	0.172
FWHM	0.036
Skewness	0.151
Kurtosis	0.157
Q_total / Q_muon	0.483

Для модели BDT также была выполнена валидация данных при помощи источника гамма-квантов и разметка частиц на графике PSD. Метрика ассигасу score для валидации составила 0.956.




Рисунок 2.10 — Рис. 11 Разметка данных моделью BDT на графике PSD

## 2.5 ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Результаты, полученные в ходе работы, демонстрируют, что даже относительно простые модели машинного обучения способны эффективно решать задачу классификации частиц на основе набора физически осмысленных признаков, извлечённых из формы сигнала. Модель логистической регрессии показала высокое качество классификации для событий, лежащих в хорошо разделимых областях PSD-пространства, что подтверждает адекватность линейного разделения в пространстве выбранных признаков. Использование L1-регуляризации позволило частично нивелировать влияние сильной корреляции между признаками и повысить устойчивость модели. В то же время линейная природа логистической регрессии ограничивает её способность к описанию более сложных нелинейных границ между классами, что проявляется в наличии неклассифицированных событий при повышении порога уверенности.

Модель Boosted Decision Tree (AdaBoost) продемонстрировала более высокое качество классификации как на тестовой, так и на валидационной выборке, что связано с её способностью учитывать нелинейные зависимости и взаимодействия между признаками. Дополнительным преимуществом BDT является возможность оценки важности признаков, что поз-

воляет интерпретировать вклад физических характеристик сигнала в процесс классификации. Вместе с тем бустинговые модели обладают большей сложностью и потенциальной чувствительностью к переобучению, что требует аккуратного подбора гиперпараметров и контроля обобщающей способности модели. В целом результаты показывают, что методы машинного обучения позволяют существенно расширить возможности анализа по сравнению с классическим PSD, сохраняя при этом физическую интерпретируемость.

## ЗАКЛЮЧЕНИЕ

В данной работе были исследованы возможности применения классических методов машинного обучения для задачи классификации частиц в сцинтилляционном детекторе типа Phoswich. Было показано, что модели логистической регрессии и Boosted Decision Trees успешно обучаются на экспериментальных данных и превосходят традиционный метод PSD по качеству классификации и гибкости анализа. Логистическая регрессия обеспечивает простую и интерпретируемую модель с высокой точностью в линейно разделимых областях пространства признаков, тогда как BDT демонстрирует наилучшие результаты за счёт учёта нелинейных эффектов и корреляций между характеристиками формы сигнала. Полученные результаты подтверждают, что применение методов машинного обучения, даже без использования глубоких нейросетевых архитектур, является эффективным и перспективным инструментом для анализа данных в задачах ядерной и нейтринной физики. В дальнейшем развитие подхода может быть связано с расширением набора признаков, применением более сложных ансамблевых методов и использованием полностью необработанных форм импульсов в качестве входных данных, а также внедрения более сложных методов классификации на основе нейронных сетей.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Machine learning at the energy and intensity frontiers of particle physics / A. Radovic [и др.] // Nature. — 2018. — Т. 560, № 7716. — С. 41–48.
2. Boosted decision trees in the Level-1 muon endcap trigger at CMS / D. Acosta [и др.] // Journal of Physics: Conference Series. Т. 1085. — IOP Publishing. 2018. — С. 042042.
3. *Gligorov V. V., Williams M.* Efficient, reliable and fast high-level triggering using a bonsai boosted decision tree // Journal of Instrumentation. — 2013. — Т. 8, № 02. — P02013.
4. *Collaboration L.* LHCb detector performance // International Journal of Modern Physics A. — 2015. — Т. 30, № 07. — С. 1530022.
5. Identification of jets containing b-hadrons with recurrent neural networks at the ATLAS experiment : тех. отч. / A. collaboration [и др.] ; ATL-PHYS-PUB-2017-003. — 2017.
6. Constraints on Oscillation Parameters from  $\nu_e$  Appearance and  $\nu_\mu$  Disappearance in NOvA / P. Adamson [и др.] // Physical review letters. — 2017. — Т. 118, № 23. — С. 231801.
7. Convolutional neural networks applied to neutrino events in a liquid argon time projection chamber / R. Acciarri [и др.] // Journal of instrumentation. — 2017. — Т. 12, № 03. — P03011.
8. *Gavrikov A., Ratnikov F.* The use of boosted decision trees for energy reconstruction in JUNO experiment // EPJ Web of Conferences. Т. 251. — EDP Sciences. 2021. — С. 03014.

9. Machine Learning for Single-Ended Event Reconstruction in PROSPECT Experiment / M. Andriamirado [и др.] // arXiv preprint arXiv:2503.06727. — 2025.
10. Pulse shape discrimination in an organic scintillation phoswich detector using machine learning techniques / Y. Lee [и др.] // Frontiers in Physics. — 2024. — Т. 12. — С. 1361608.
11. Neutron-gamma pulse shape discrimination for EJ301 liquid scintillator based on machine learning / J. Xu [и др.] // Journal of Radioanalytical and Nuclear Chemistry. — 2024. — Т. 333, № 2. — С. 905—916.