

Министерство науки и высшего образования Российской Федерации
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ЯДЕРНЫЙ УНИВЕРСИТЕТ «МИФИ»
ИНСТИТУТ ЯДЕРНОЙ ФИЗИКИ И ТЕХНОЛОГИЙ
КАФЕДРА ФИЗИКИ ЭЛЕМЕНТАРНЫХ ЧАСТИЦ

ИЛЬЯСОВ АЙДАР ИРШАТОВИЧ

МОНТЕ КАРЛО МОДЕЛИРОВАНИЕ И РАЗДЕЛЕНИЕ ПО
ФОРМЕ ИМПУЛЬСА НИЗКОЭНЕРГЕТИЧЕСКИХ СОБЫТИЙ
ЭКСПЕРИМЕНТА DARKSIDE-50

Отчет по НИР

Направление подготовки 14.04.02 Ядерная физика и технологии

Научный руководитель

А. В. Гробов _____

Оценка _____

Москва 2020

Оглавление

Введение	2
1 Эксперимент DarkSide-50	4
2 Монте Карло моделирование	7
3 Машинное обучение	15
4 Результаты	21
5 Заключение	25

Введение

Наблюдения за этапами развития Вселенной показали, что Вселенная состоит на $\Omega_\Lambda = 68,5\%$ из темной энергии и на $\Omega_\Lambda = 31,5\%$ из нерелятивистского вещества, из которых $\Omega_\Lambda = 26,5\%$ — темная материя и $\Omega_\Lambda = 5,0\%$ — барионное вещество [1]. Отметим, что темная материя, по всей видимости, состоит из массивных частиц, которые отсутствуют в Стандартной модели физики частиц. Эти частицы - нерелятивистские, почти не взаимодействуют между собой (иначе это привело бы к формированию в основном шарообразных гало, а это противоречит наблюдениям) и не взаимодействуют с фотонами [1].

Сделав предположение о том, что частицы темной материи X находились в термодинамическом равновесии с обычным веществом в ранней Вселенной, можно принять, что эти частицы вышли из равновесия в какой-то момент времени и с тех пор распространяются свободно. Сравнивая температуру заковки $T_{freeze-out}$ с массой темной материи, разделяют три модели [1]:

- Холодная темная материя: $T_f < M_X$, основной кандидат — слабовзаимодействующие массивные частицы - *WIMP*;
- Горячая темная материя: $T_f > M_X$, $M_X < 1$ эВ, основной кандидат — нейтрино;
- Теплая темная материя: $T_f > M_X$, $M_X > 1$ эВ, основной кандидат — стерильное нейтрино.

Наиболее приемлемым вариантом считается холодная темная материя (cold dark matter), а соответствующая ей пространственно-плоская модель Вселенной — Λ CDM модель [1].

За последние 20 лет создано большое число экспериментов по прямому и косвенному обнаружению темной материи. Косвенный метод основан на попытках измерить вторичные продукты взаимодействия темной материи. Метод прямого

обнаружения предполагает непосредственную регистрацию частиц темной материи в детекторе, обеспечивая низкоэнергетические (<100 кэВ) ядра отдачи. Прогнозируемые скорости столкновений крайне малы и требуют ультранизких фоновых детекторов с большими (1-100 т) мишенями, расположенными глубоко под землей, чтобы исключить нейтронный и мюонный фон.

С каждого детектора поступает большое число сигнальных, шумовых и фоновых событий. Понимание математической статистики и физики возникновения события помогает создавать отбор данных и с высокой частотой отбирать сигнальные события, но одновременно с этим ограничивает их параметры. Машинное обучение частично помогает решить эту проблему. Ее преимуществами являются высокая производительность, скорость работы и возможность находить скрытые зависимости в используемых данных. В данной работе будет описан метод классификации событий в области низких энергий в эксперименте DarkSide-50.

Глава 1

Эксперимент DarkSide-50

DarkSide-50 – это двухфазная время-проекционная камера (Time-Projection Chamber, TPC), представляющая собой стальной цилиндр с размерами 35,6 см в диаметре и 35,6 см в высоту. Активная масса жидкого аргона - $(46,4 \pm 0,7)$ кг, в верхней части камеры есть слой газообразного аргона. Несмотря на то, что аргон - хороший сцинтиллятор, он излучает в ультрафиолетовом спектре. По этой причине внутренняя стенка цилиндра покрыта тетрафенилбутадиеном, который сдвигает излучение в спектр видимого света. Этот объем просматривается через окна с плавленым кварцевым стеклом 38 фотоэлектронными умножителями (ФЭУ): по 19 сверху и снизу камеры. Окна покрыты с обеих сторон оксидом индия-олова (Indium Tin Oxide (ITO)). Это позволяет внутренним поверхностям окон служить анодом (вверху детектора) и катодом (внизу детектора) [2].




Рис. 1.1: Схема детектора DarkSide-50

Детектор DarkSide-50, состоит в целом из трех частей: жидкостной время-проекционной камеры (LAr TPC), которая является детектором темной материи, органического жидкого сцинтиллятора (Liquid Scintillator Veto (LSV)), который окружает TPC и служит для предотвращения регистрации радиогенных и космогенных нейтронов, γ - лучей и космических мюонов и водного черенковского детектора (Water Cherenkov Detector (WCD)), который предотвращает регистрацию детектором космических мюонов [3] [4].

Детектируемые события делятся на Nuclear Recoil (NR) (например, нейтроны) и Electron Recoil (ER) (например, β - или γ - частицы) [5]. В эксперименте предполагается обнаружение WIMP-частиц в области NR-частиц.

Детектирование происходит следующим образом. Частица (γ -квант, нейтрон, электрон) попадает в рабочий объем детектора и рассеивается на молекуле аргона, возбуждая ее. При возбуждении (поглощении кванта энергии) возникает либо возбужденное синглетное состояние молекулы (короткоживущее, $\tau \sim 6$ нс) либо триплетное состояние (долгоживущее, $\tau \sim 1,6$ мкс).

Обратный переход молекул в основное состояние сопровождается сцинтилляцией — сигнал S_1 . Обнаружено, что долгоживущее состояние без излучения соответствует трекам с высокой плотностью ионизации. Таким образом можно сделать вывод, что легкие частицы имеют более длительную продолжительность сцинтилляции по сравнению с тяжелыми. Это является рабочим принципом дискриминации по форме импульса (Pulse Shape Discrimination (PSD)) [5]. С помощью PSD можно определить, является ли детектируемая частица ER или NR с вероятностью ошибочной идентификации $\sim 10^{-8}$.

В то же время электроны ионизации дрейфуют в электрическом поле TPC вверх детектора и попадают в слой газообразного аргона между поверхностью LAr и TPC. Энергии электронов оказывается достаточно для возбуждения аргона и происходит вторая сцинтилляция — сигнал S_2 . Стоит отметить, что зачастую ФЭУ регистрируют и третью вспышку — сигнал S_3 . Она следует за S_2 с фиксированным временем задержки, равным максимальному времени дрейфа электрона

в жидком аргоне. Сигнал S_3 объясняется электронами, вылетевшими с катода ТРС вследствие яркого ультрафиолетового света сигнала S_2 [5].

Глава 2

Монте Карло моделирование

С помощью пакета Монте Карло моделирования *g4ds10* было создано ~ 320 тыс. событий с электронной отдачей (ER) и ~ 1.6 млн. событий с ядерной отдачей (NR). Nuclear recoil события создавались для четырех разных спектров масс WIMP частиц – 100, 200, 500 и 1000 ГэВ – в равных количествах. Отметим, что по причине отсутствия необходимых вычислительных мощностей события моделировались без сигнала S_2 .

С помощью моделирования были получены следующие параметры наших событий: импульс сцинтилляционного сигнала S_1 и параметры формы импульса f_{30} , f_{60} , f_{90} и f_{200} которые определяются следующим образом:

$$f_{30,60,90,200} = \frac{\int_0^{30,60,90,200ns} S_1 dt}{\int_0^{7\mu s} S_1 dt}$$

В интересующей нас области параметров (энергия сигнала $0 < S_1 < 500$ и $0.15 < f_{90} < 0.5$ для ER и $0.5 < f_{90} < 0.82$ для NR) осталось ~ 52 тыс. и 1.3 млн. событий соответственно. Прежде чем использовать эти данные для тренировки модели необходимо убедиться в соответствии их реальным данным и, в противном случае, привести их к похожему виду. Двусторонний критерий χ^2 (сравнение распределения параметров ER и NR событий Монте Карло моделирования с реальными предобработанными данными – использованием атмосферного аргона ААг в течение 50 дней и работой детектора с калибровочным источником ^{241}Am - ^9Be соответственно) показал результаты, представленные в Таблице 2.1.

Statistic/p-value	^{39}Ar	^{40}Ar
f_{90}	12.271/1.0	26.721/1.0
S_1	0.003/1.0	0.084/1.0
Кол-во событий	52 тыс.	1.3 млн.

Таблица 2.1: Результаты двустороннего критерия χ^2 для данных Монте Карло моделирования

Для улучшения соответствия Монте Карло моделирования реальным данным был применен метод обратного преобразования для четырех различных функций:

1. *foldnorm* – стандартная функция распределения, которая наилучшим образом фитировала распределение ^{40}Ar . Ее функция плотности вероятности следующая:

$$f(x, c) = \sqrt{2/\pi} \cosh(cx) \exp\left(-\frac{x^2 + c^2}{2}\right)$$

2. *gausshyper* – стандартная функция распределения, которая наилучшим образом фитировала распределение ^{241}Am - 9Be . Ее функция плотности вероятности имеет вид:

$$f(x, a, b, c, z) = Cx^{a-1}(1-x)^{b-1}(1+zx)^{-c}$$

3. Эмпирическая функция распределения, которая используется в статье [6]. Функция плотности вероятности для NR событий следующая:

$$F^{NR}(f, q) = \Gamma(1-f; 1-\bar{f}, b) * Gauss(f; \sigma), \quad (2.1)$$

$$\text{где:} \quad (2.2)$$

$$\Gamma(f; \bar{f}, b) = \frac{\bar{f}^b f^{b-1} e^{-\bar{f}f}}{\Gamma(b)}, \quad (2.3)$$

$$Gauss(f; \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{f^2}{2\sigma^2}}, \quad (2.4)$$

параметры $\bar{f}(q)$, $b(q)$ и $\sigma(q)$ выражаются следующим образом:

$$\begin{aligned}\bar{f}(q) &= a_0 + \frac{a_1}{q-a_2} + \frac{a_3}{(q-a_4)^2}, \\ b(q) &= a_5 + \frac{a_6}{q} + \frac{a_7}{q^2}, \\ \sigma(q) &= a_8 + \frac{a_9}{q} + \frac{a_{10}}{q^2},\end{aligned}$$

а переменные q , $a_0 - a_{10}$ – фитирующие параметры.

4. Функция распределения Дэвида Хинкли [7–9] для фитирования величины, которая является отношением двух нормально распределенных случайных величин с математическими ожиданиям μ_p и μ_l и дисперсиями σ_p и σ_l соответственно. Ее плотность вероятности имеет следующий вид:

$$f(x) = \frac{\sigma_l^2 \mu_p x + \sigma_p^2 \mu_l (1-x)}{\sqrt{2\pi}(\sigma_l^2 x^2 + \sigma_p^2 (1-x)^2)^{3/2}} \times \exp\left[-\frac{(\mu_l x - \mu_p (1-x)^2)}{2(\sigma_l^2 x^2 + \sigma_p^2 (1-x)^2)}\right] \quad (2.5)$$

где σ_l , σ_p , μ_l и μ_p были взяты в качестве параметров фита. В нашем случае эта функция очень хорошо описывала распределение параметров f_{30} , f_{60} , f_{90} и f_{200} .

В результате статистического преобразования данных Монте Карло моделирования были получены результаты, представленные на Рисунках 2.1 - 2.5 для ^{39}Ar и 2.6 - 2.10 для ^{40}Ar а также в Таблице 2.2. Эти данные в дальнейшем использовались для тренировки и тестирования моделей машинного обучения.

Statistic/p-value	^{39}Ar	^{40}Ar
f_{90}	0.781/1.0	1.239/1.0
S_1	0.0003/1.0	0.025/1.0
Кол-во событий	607 тыс.	1.3 млн.

Таблица 2.2: Результаты двустороннего критерия χ^2 для данных Монте Карло моделирования после статистического преобразования

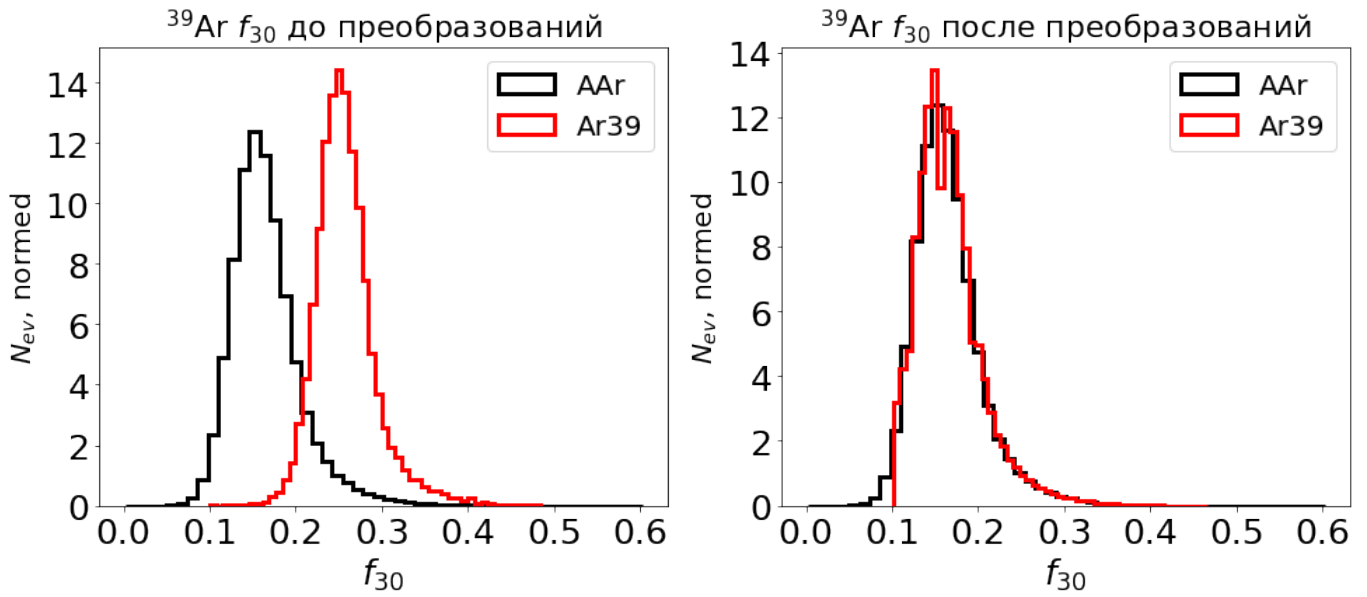


Рис. 2.1: Статистическое преобразование параметра f_{30} Монте Карло моделирования ^{39}Ar

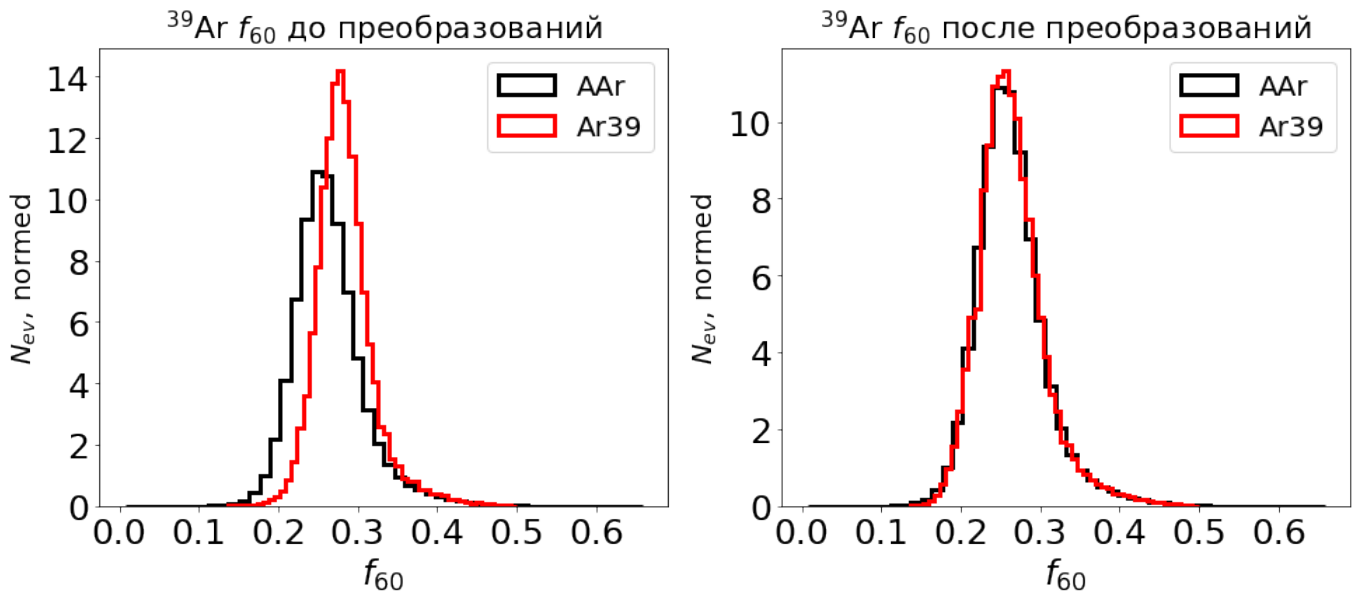


Рис. 2.2: Статистическое преобразование параметра f_{60} Монте Карло моделирования ^{39}Ar




Рис. 2.3: Статистическое преобразование параметра f_{90} Монте Карло моделирования ^{39}Ar

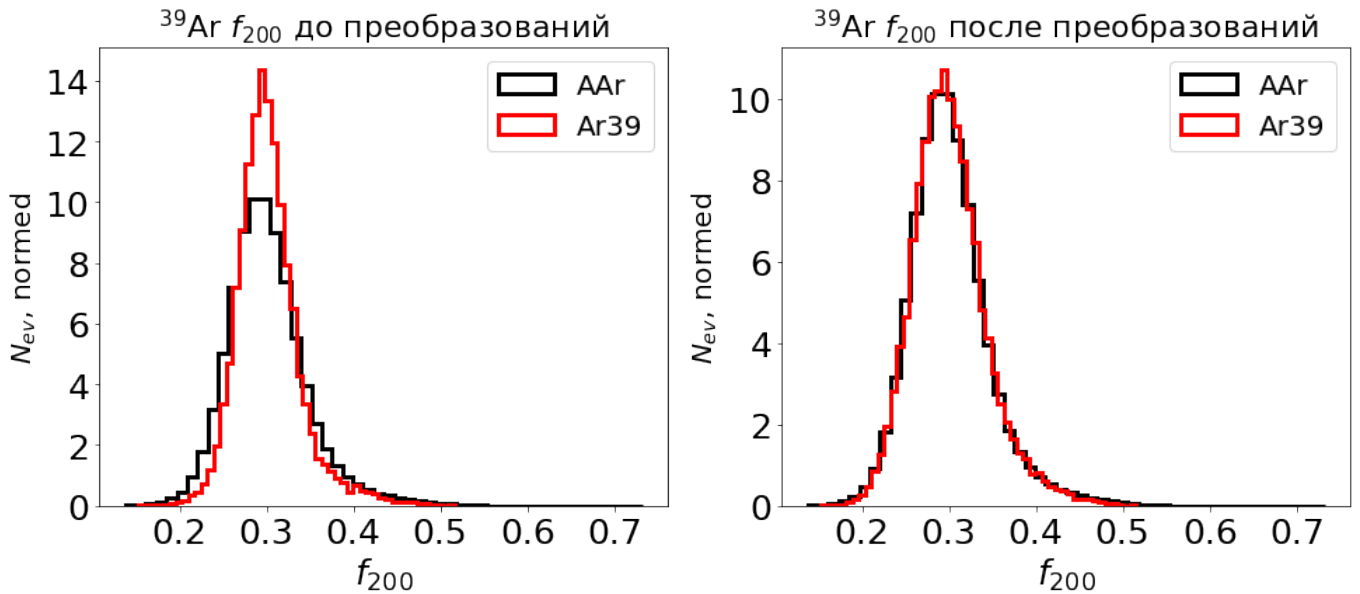


Рис. 2.4: Статистическое преобразование параметра f_{200} Монте Карло моделирования ^{39}Ar

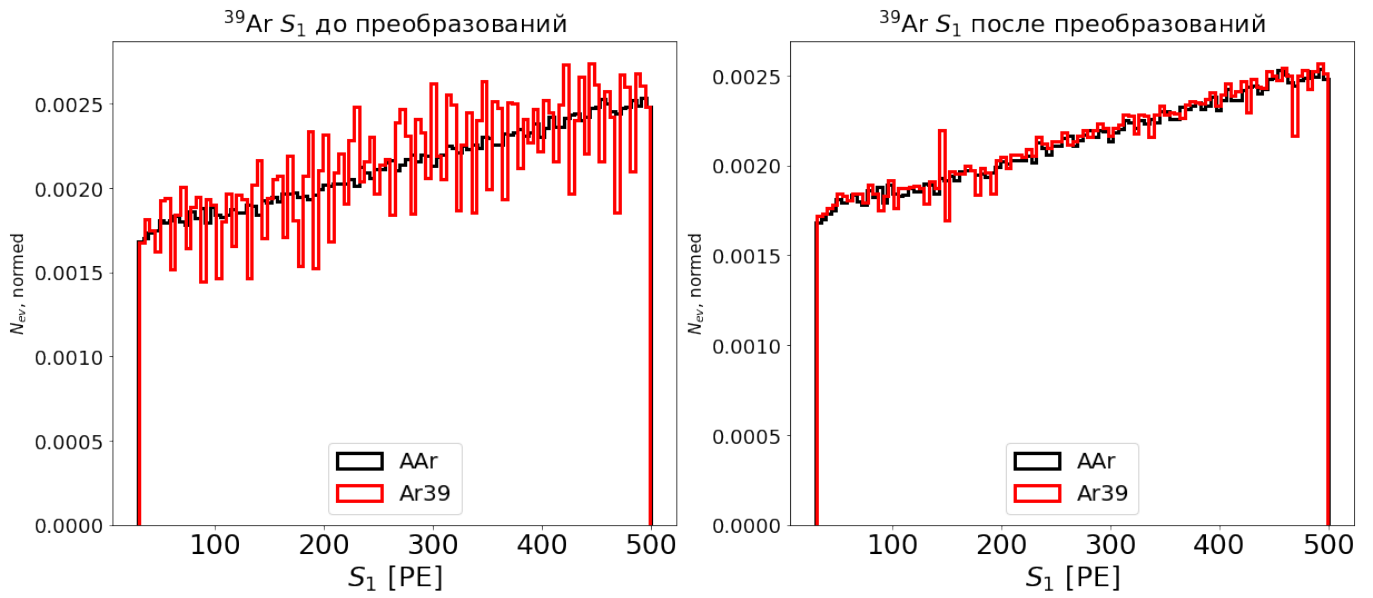


Рис. 2.5: Статистическое преобразование параметра S_1 Монте Карло моделирования ^{39}Ar

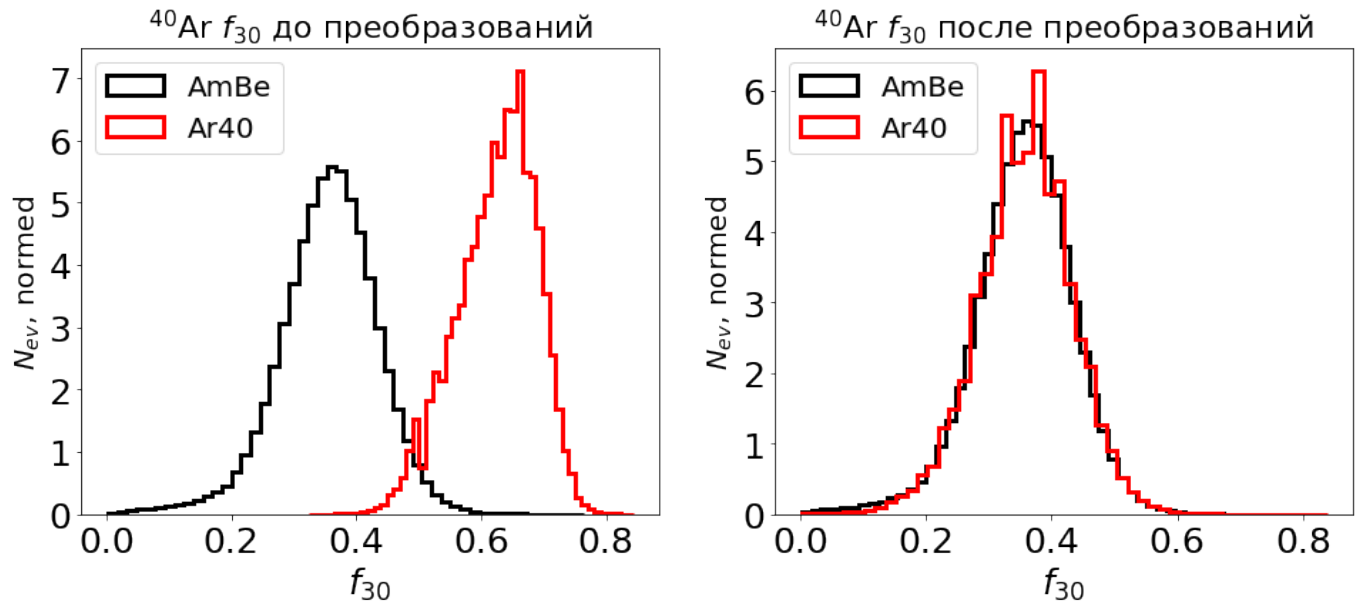


Рис. 2.6: Статистическое преобразование параметра f_{30} Монте Карло моделирования ^{40}Ar

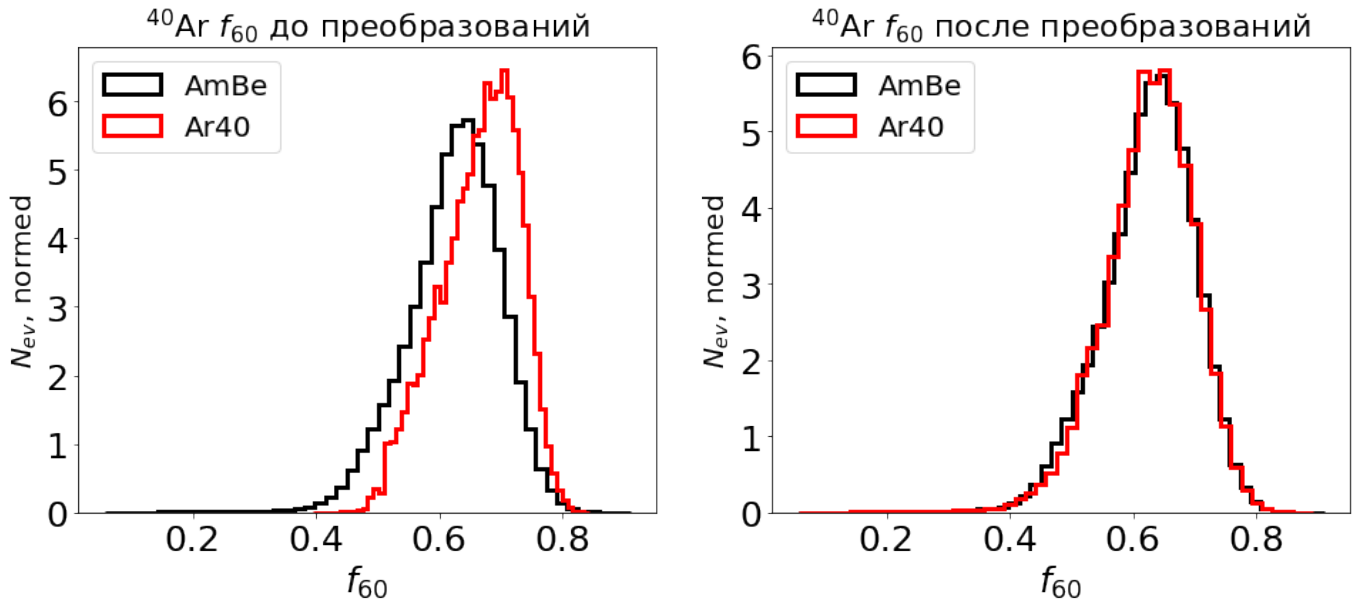


Рис. 2.7: Статистическое преобразование параметра f_{60} Монте Карло моделирования ^{40}Ar




Рис. 2.8: Статистическое преобразование параметра f_{90} Монте Карло моделирования ^{40}Ar




Рис. 2.9: Статистическое преобразование параметра f_{200} Монте Карло моделирования ^{40}Ar

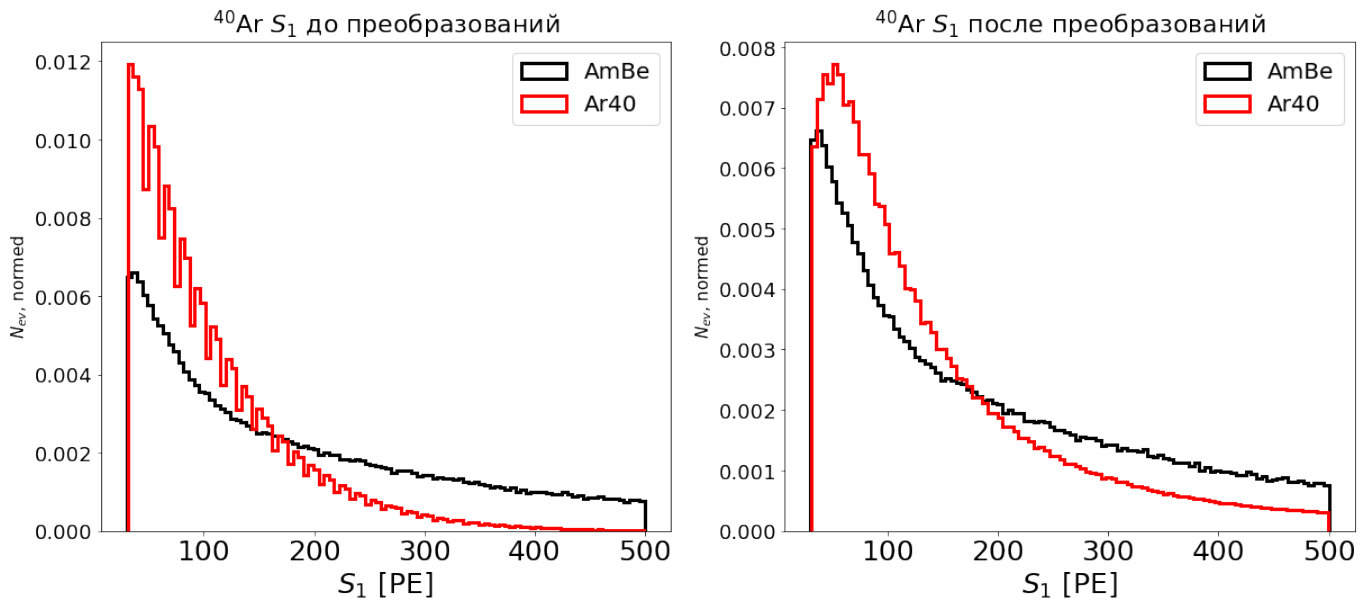


Рис. 2.10: Статистическое преобразование параметра S_1 Монте Карло моделирования ^{40}Ar

Глава 3

Машинное обучение

Машинное обучение - это метод анализа данных с помощью системы, которая обучается на множестве уже проанализированных данных. Зачастую эти данные имеют закономерности, благодаря которым алгоритм обучается. Основная идея состоит в том, чтобы не задавать модель решения задачи вручную, а получить его из данных. Задачи машинного обучения в целом можно разделить на 2 части: классификация (присвоение событию метки определенного класса) и регрессия (предсказание одной непрерывной случайной величины). В данной работе рассматривается задача классификации.

Само машинное обучение можно разделить на 3 части: представление (Representation), оценка (Evaluation) и оптимизация (Optimization) [10].

Представление

Представление - это обозначение пространства разрешенных моделей. Это значит, что выбираются те модели машинного обучения, которые могут быть эффективны для решения данной задачи.

В условиях нашей задачи перспективно показали себя модель на основе деревьев решений и искусственная нейронная сеть на основе многослойного перцептрона по Румельхарту (Multilayer Perceptron). Отметим, что обе модели обучаются с учителем — то есть предварительно часть данных подается на вход классификатору с метками.

Деревья решений представляют собой алгоритм, который содержит в себе набор правил, по которым вычисляется результат. Графически модель выглядит как

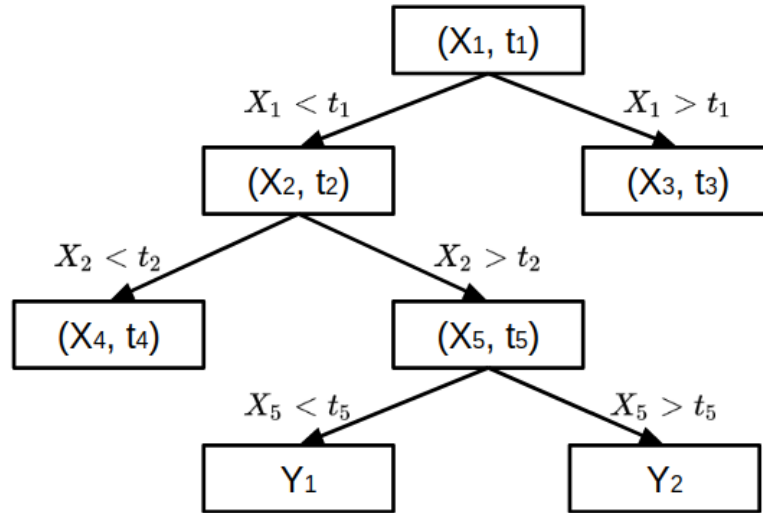


Рис. 3.1: Структура дерева решений: x_{1-5} - параметры событий, t_{1-5} - пороговые значения, $Y_{1,2}$ - выходная метка класса [11].

структура дерева. Алгоритм обучается сравнивая значения переменных с некоторыми пороговыми значениями (Рисунок 3.1). Основным её преимуществом является простота понимания вычислений (т.н. «белая коробка»), однако данный алгоритм используется вместе с методом градиентного бустинга, так как в данном случае деревья менее склонны к перетренированности.

Градиентный бустинг — это метод машинного обучения для задач регрессии и классификации, который создает модель прогнозирования в виде множества моделей слабого прогнозирования (наиболее часто используются деревья решений). Он строит модель поэтапно, как и другие методы повышения, и обобщает их, позволяя оптимизировать произвольную дифференцируемую функцию потерь. Градиентный бустинг работает следующим образом: предположим, что решается задача классификации с обучающей выборкой $X = (x_i)$ и метками класса $Y = (y_i)$, где $y_i = 0$ (фоновое событие) или $y_i = 1$ (сигнальное событие). Такой набор данных называется тренировочным. Каждое событие в этом наборе имеет N параметров $x_i(x_{i,1}, x_{i,2}, \dots, x_{i,j})_{j=N}$. на основе этих параметров строится предсказание $\bar{y}_i = \sum_j w_j x_{i,j}$ для определения принадлежности события x_i метке класса 1/0, где w_j - весовое значение каждого параметра события. Сравнивая результат

с истинной меткой y_i мы можем настроить модель с помощью изменения весов.

Искусственная нейронная сеть — это математическая модель, построенная по принципу организации и функционирования биологических нейронных сетей. Нейрон — вычислительная единица, которая получает информацию, производит над ней простые вычисления и передает ее дальше. Нейроны подразделяются на входные, выходные и скрытые. Для каждого нейрона есть набор входных и выходных данных. Входные данные — это результат работы всех нейронов с предыдущего слоя. Выходные данные — результаты работы этого нейрона. Группа нейронов образует слой. Таким образом, мы имеем дело с 3 типами слоев: входной слой, в которую передаем данные, скрытые слои, в которых происходят математические вычисления, и выходной слой, с которого снимается результат. Объединение слоев в одно целое образует конкретную математическую модель. Простейший модель которая состоит из входного, выходного и одного скрытого слоя называется перцептроном.

Многослойный перцептрон — это математическая модель с входным, выходным и более чем одним скрытым слоем (Рисунок 3.2).

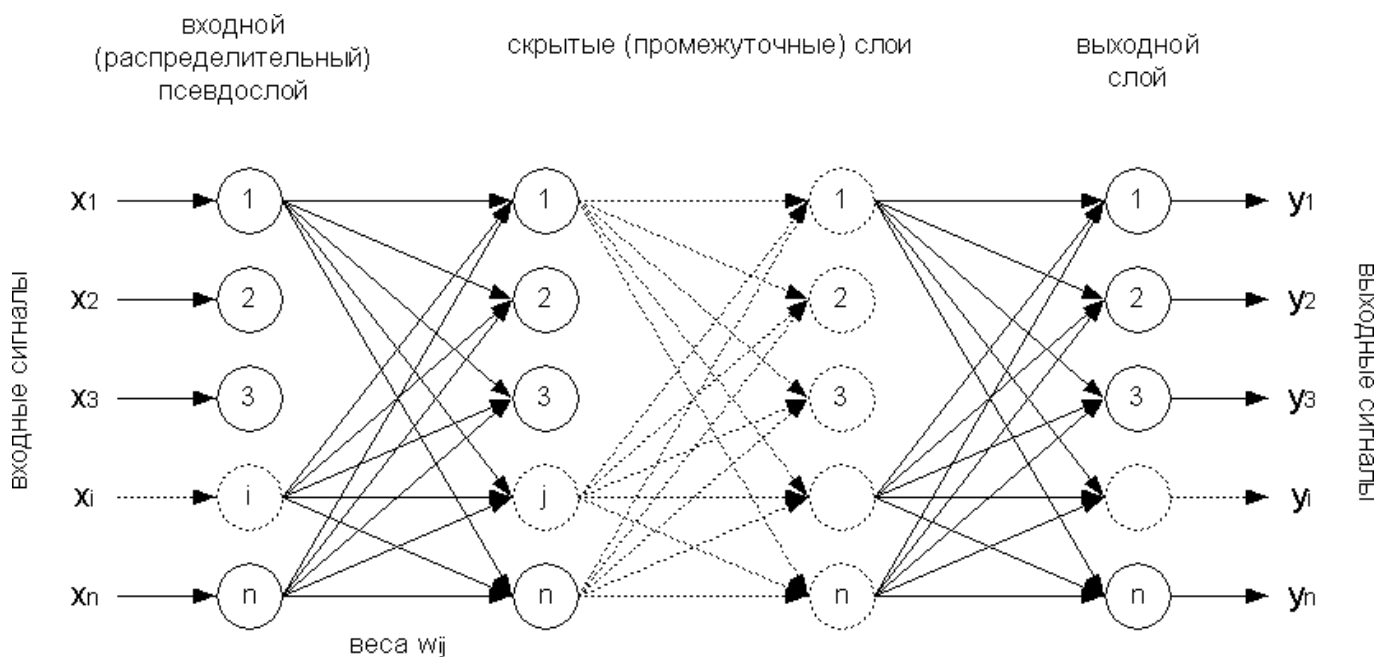


Рис. 3.2: Схема многослойного перцептрона

У данной модели есть параметры, изменяя которые можно менять эффектив-

ность сети. Например, количество скрытых слоев, количество нейронов в них и количество циклов обучения. Их выбор зависит от сложности задачи, размерности обучающей выборки, количества данных, требуемого количества входов и выходов сети и от имеющихся технических ресурсов. Чем больше нейронов и слоев, тем шире возможности сети, однако тем медленнее она обучается и работает и тем более нелинейной может быть зависимость вход-выход [12]. Выходное значение нейрона является результатом действия функции активации.

Функция активации нейрона — это функция, которая определяет выходное значение нейрона в зависимости от результата взвешенной суммы входов и порогового значения. Существует несколько функций активации — пороговая, линейная, гиперболический тангенс, сигмоида и т.д., которая выбирается в зависимости от целей задачи. Таким образом, каждое событие проходит через всю нейронную сеть. На выходе мы получаем для всех событий некоторое значение — вероятность принадлежности данной частицы к конкретному классу.

Оценка

Оценка - процесс оценивания качества модели в контексте решения задачи, выбор лучшей модели из нескольких.

На данный момент существует 4 наиболее популярные метрики, благодаря которым можно оценивать эффективность того или иного классификатора: Accuracy, Precision, Recall и F-score. Они определяются следующим образом:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3.2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.3)$$

$$F\text{-score} = 2 \frac{P * R}{P + R} \quad (3.4)$$

Где:

Accuracy — доля истинных результатов (как положительных, так и отрицательных) среди общего числа исследованных событий;

Precision — доля объектов, названных классификатором положительными и при этом действительно являющиеся положительными;

Recall — доля объектов положительного класса от всех объектов положительного класса, которая определяется классификатором.

F-score — среднее гармоническое точности и полноты

TP (True Positive) — NR события, определенные как NR;

TN (True Negative) — ER события, определенные как ER;

FP (False Positive) — NR события, определенные как ER;

FN (False Negative) — ER события, определенные как NR.

ROC-кривая — график, отображающий соотношение между долей верно определенных сигнальных событий от общего количества сигнальных событий (Signal Acceptance - SA) и долей неверно определенных фоновых событий от общего количества фоновых событий (Background Rejection Rate - BRR).

Оптимизация

На данный момент было использовано два метода улучшения характеристик классификаторов: рандомизированный поиск (randomized search, RS) параметров модели для многослойного перцептрона и поиск по сетке (grid search, GS) и оптимизации модели на основе деревьев решений.

Randomized search (случайный поиск) — это метод поиска перспективного набора гиперпараметров классификатора путем случайного перебора этих параметров определенное количество раз. Изначально задается матрица значений гиперпараметров, количество итераций — то, сколько различных наборов параметров

будет использоваться, и метрика, по которой будут сравниваться результаты. Таким образом можно найти один из лучших наборов параметров за сравнительно небольшое время.

Grid search (поиск по сетке) — это метод поиска наилучшего набора гиперпараметров путем обычного перебора всех возможных параметров. Недостатком такого метода является то, что при большом количестве различных параметров поиск может занимать продолжительное время.

Глава 4

Результаты

Для обучения модели использовалось по 607 тыс. событий Монте Карло моделирования ^{39}Ar и ^{40}Ar после статистического преобразования. Для обучения использовались стандартные переменные - f_{30} , f_{60} , f_{90} , f_{200} , S_1 а также их комбинации:

- Логарифм от стандартной переменной: $\log(S_1)$, $\log(f_{30})$, $\log(f_{60})$, $\log(f_{90})$, $\log(f_{200})$;
- Попарные произведения S_1 , f_{30} , f_{60} , f_{90} , f_{200} ;
- Логарифм от попарных произведений.

Корреляционная матрица (то есть матрица, которая показывает зависимость одной переменной от другой) получившихся параметров изображена на Рисунке 4.1.

Отметим, что практически не существует в этом наборе абсолютно скоррелированных величин. Это говорит о том, что каждый параметр внесет свой вклад в результат работы классификатора. Дальнейшие шаги по обучению модели:

1. Перемешать набор данных для того, чтобы избежать перетренированности и разделить его в соотношении 70:30 на тренировочную и тестовую выборку;
2. Применить ненастроенные алгоритмы машинного обучения для проверки их работоспособности на имеющихся данных. Если accuracy, precision и recall выдают значения больше 0.5 - значит алгоритм работает исправно.



Рис. 4.2: Таблица важности переменных в работе классификатора.

3. Настроить параметры моделей с помощью техник рандомизированного поиска или поиска по сетке;
4. Вывести результат в виде значений значений метрик качества а также кривой ошибок.

Алгоритм	TP	TN	FP	FN
XGBoost	182512	182941	738	26
XGBoost GS	182516	182944	734	23
MLP	182493	182960	757	7
MLP RS	182506	182952	744	15

Таблица 4.1: Количество TP, TN,FP,FN событий для каждого из четырех обученных моделей.




Рис. 4.3: Двумерные гистограммы S_1 vs. F_{90} для TP, TN, FP, FN событий для модели XGBoost GS.

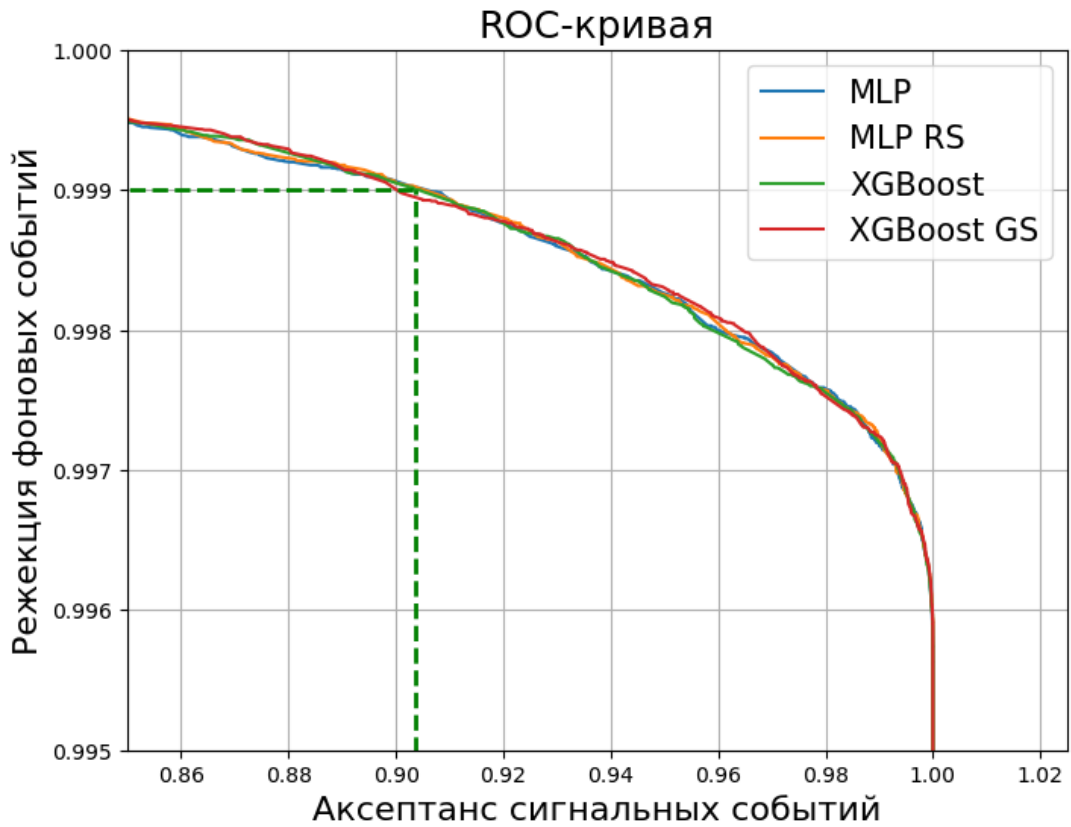


Рис. 4.4: Кривая ошибок для всех четырех классификаторов.

Глава 5

Заключение

Применение данных Монте Карло моделирования привело к следующим результатам и наблюдениям:

1. Несмотря на малое количество исходных параметров, можно получить большое количество нескоррелированных пользовательских параметров (Рисунок 4.1), причем некоторые из них вносят бóльший вклад в работу классификатора (Рисунок 4.2).
2. Все четыре модели имеют высокую эффективность (Таблица 4.1). Каждую конкретно стоит выбирать под те нужды, которые необходимо достичь (например, исключить наибольший процент фоновых событий, или сохранить как можно больше сигнальных событий).
3. При первом пороговом значении в 99% режекции фоновых событий любой из этих классификаторов сохранит все 100% сигнальных событий (Рисунок 4.4). Однако при втором пороговом значении в 99.9% режекции фоновых событий - акцептанс сигнальных событий составляет $\sim 90\%$. Такое значение акцептанса позволяет начать применять классификатор на реальных данных. Отметим, что систематические неопределенности для каждого классификатора на данном графике не учтены.

Список литературы

- 1 *Горбунов Д. С., Рубаков В. А.* Введение в теорию ранней Вселенной. Теория горячего Большого взрыва. — Российская акад. наук, Ин-т ядерных исслед., 2007.
- 2 *Wright A.* The DarkSide Program at LNGS // Astroparticle, Particle, Space Physics and Detectors For Physics Applications-Proceedings of the 13th ICATPP Conference. Edited by Giani Simone et al. Published by World Scientific Publishing Co. Pte. Ltd., 2012. ISBN# 9789814405072, pp. 414-420. — 2012. — с. 414—420.
- 3 The veto system of the DarkSide-50 experiment / P. Agnes [и др.] // Journal of Instrumentation. — 2016. — т. 11, № 03. — P03016.
- 4 Direct search for dark matter with DarkSide / P. Agnes [и др.] // Journal of Physics: Conference Series. т. 650. — IOP Publishing. 2015. — с. 012006.
- 5 First results from the DarkSide-50 dark matter experiment at Laboratori Nazionali del Gran Sasso / P. Agnes [и др.] // Physics Letters B. — 2015. — т. 743. — с. 456—466.
- 6 Search for dark matter with a 231-day exposure of liquid argon using DEAP-3600 at SNOLAB. 2019 / D. Collaboration [и др.] // arXiv preprint arxiv:1902.04048. —
- 7 *Hinkley D. V.* On the ratio of two correlated normal random variables // Biometrika. — 1969. — т. 56, № 3. — с. 635—639.
- 8 *Lidgard J. J.* Pulse shape discrimination studies in liquid argon for the DEAP-1 detector. — Queen's University, 2008.
- 9 Scintillation time dependence and pulse shape discrimination in liquid argon / W. Lippincott [и др.] // Physical Review C. — 2008. — т. 78, № 3. — с. 035801.

- 10 *Domingos P.* A few useful things to know about machine learning // Communications of the ACM. — 2012. — т. 55, № 10. — с. 78—87.
- 11 *Ilyasov A., Grobov A.* Boosted decision trees approach to neck alpha events discrimination in DEAP-3600 experiment // Physica Scripta. — 2020.
- 12 *Заенцев И.* Нейронные сети: основные модели. — 1999.