

Министерство науки и высшего образования Российской Федерации
Федеральное государственное автономное образовательное учреждение высшего
образования

Национальный исследовательский ядерный университет «МИФИ»

Отчет о научно-исследовательской работе
на тему:



Монте Карло моделирование и разделение по форме
импульса низкоэнергетических событий эксперимента
DarkSide-50

Выполнил:
Студент гр. М19-115
Ильясов А.И.
Научный руководитель:
к.ф.-м.н.
Гробов А.В.



Москва, 2020



Эксперимент DarkSide-50



Данные Монте Карло моделирования ^{39}Ar





Функция распределения Хинкли:

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

$$f_{90} = \frac{\int_0^{90\text{ns}} S_1 dt}{\int_0^{7\mu\text{s}} S_1 dt}$$

Statistic/ p-value	old data	new data
f_{90}	26.721/1.0	1.239/1.0
S_1	0.084/1.0	0.025/1.0
N событий	52 тыс.	607 тыс.

Данные Монте Карло моделирования ^{40}Ar



Функция распределения Хинкли:

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

$$f_{90} = \frac{\int\limits_{0}^{90ns} S_1 dt}{\int\limits_{0}^{7\mu s} S_1 dt}$$

Statistic/ p-value	old data	new data
f_{90}	12.271/1.0	0.781/1.0
S_1	0.003/1.0	0.0003/1.0
N событий	1.3 млн.	1.3 млн.

Классификаторы


Многослойный перцептрон

Преимущества:

- Лёгок в понимании
- Легко настраивается
- Мало гиперпараметров

Недостатки:

- Легко **переобучается**
- Требует большую **статистику**
- **Долго** работает




Градиентный бустинг над деревьями решений

Преимущества:

- **Быстро** работает
- Работает хорошо с малой статистикой
- Хорошо **защищён от переобучения** с помощью гиперпараметров

Недостатки:

- **Трудно** настраивается
- Тяжелее в **понимании**



Оценка классификатора и используемые данные

Оценка Метрики:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$


$$Precision = \frac{TP}{TP + FP} \quad Recall = \frac{TP}{TP + FN}$$

Параметры, необходимые для вычисления метрик		Истинные метки	
Предсказание классификатора	1	TP	FP
	0	FN	TN

ROC-кривая - Зависимость ***recall*** от ***background rejection rate***:

$$BRR = \frac{TN}{FP+TN}$$

- Поиск параметров по сетке
- Рандомизированный поиск параметров




Используемые переменные:

- $f_{30}, f_{60}, f_{90}, f_{200}, S_1$
- $\log(f_{30}, f_{60}, f_{90}, f_{200}, S_1)$
- Попарные произведения
- \log от попарных произведений


Результаты

Переменная


Важность переменных после оптимизации



Предсказание классификатора XGBoost GS, log масштаб



ROC-кривая











*Систематические неопределенности не учтены





Заключение

- Применение функции Хинкли уменьшает общую ошибку распределения, что позволяет применять данные Монте Карло моделирования для обучения моделей машинного обучения;
- ★ Из малого количества основных параметров (5) было получено большое количество пользовательских (33) параметров;
- ★ Все 4 модели имеют схожую эффективность. Каждая из них может быть выбрана в соответствии с поставленной задачей;
- ★ При пороговом значении в 99% режекции фоновых событий имеем 100% акцептанс сигнальных событий;
- ★ При пороговом значении 99.9% режекции фоновых событий имеем ~90% принятия сигнальных событий.

Backup slides









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


TP событий: 182944




FP событий: 734









FN событий: 23




TN событий: 182516




Используемые переменные






Используемые переменные



Correlation matrix



Градиентный бустинг над деревьями решений

$$y \approx \hat{f}(x),$$



$$\hat{f}(x) = \arg \min_{f(x)} L(y, f(x))$$

Где:

x - входные переменные,

y - целевые переменные,

L - функция потерь



Randomized Search/GridSearch

Randomized Search:

- 1) Задается набор значений для каждого интересующего параметра
- 2) Задается количество проверок M
- 3) Задается метрика проверки
- 4) Проверяется M классификаторов с параметрами, случайно взятыми из набора и выдаются параметры классификатора с наилучшим результатом по оцениваемой метрике

Grid Search:

- 1) Задается пространство гиперпараметров
- 2) Задается метрика проверки
- 3) Проверяются любые возможные комбинации параметров и выдаются параметры классификатора с наилучшим результатом по оцениваемой метрике

