




National Research
Tomsk
State
University



Лаборатория
анализа данных
физики высоких энергий

Томского
государственного
университета

Физический анализ данных

Томский Государственный Университет

Мария Диденко от лица группы анализа данных

18.12.2025

Анализ данных физики высоких энергий

Что изучаем: фундаментальные частицы и их взаимодействия при экстремальных энергиях.



Роль анализа данных: выделение редких физических сигналов, измерение параметров Стандартной модели и проверка теоретических предсказаний.

Данные:

- **ATLAS Open Data 2015–2016** (формат DAODPhysLite*), **36 fb^{-1}**
 - Реальные данные, симуляции основных физических процессов и систематические вариации (электрослабые бозоны, Хиггс, QCD-джеты, топ-кварки и тд)
 - Масштаб: **~9 млрд событий, ~100 ТБ данных**

Подход и фокус работы:

Методы машинного обучения, статистический анализ и распределённые вычисления для воспроизведения результатов ATLAS и тестирования новых методов анализа на открытых данных CERN, то что можно использовать и для будущих экспериментов таких как NICA



* **DAOD** (Derived Analysis Object Data) — это «производные» данные, получаемые из исходных форматов ATLAS после реконструкции событий.

***PhysiLite** — «облегчённая» версия DAOD (стандартный стартовый формат)



Инфраструктура и воспроизведение анализа

Создание и валидация вычислительной среды:

- Развёрнута и протестирована вычислительная среда анализа данных на кластере ТГУ.
- Обеспечен **доступ к инфраструктуре ATLAS** с вычислительных узлов кластера ТГУ.
- Настроены распределённые вычисления на базе **HTCondor**.
- Реализован пайпайн обработки **DAOD PhysLight → ROOT ntuples** (фреймворк **Athena AnalysisBase v25.2.45**)

Воспроизведение физического анализа:

- На **финальной стадии** воспроизведение анализа - “*Measurements of top-quark pair to Z-boson cross-section ratios*”.
- Анализ используется как **тест корректности** программного обеспечения, сервисов и производительности вычислительного кластера.
- Выполнен полный статистический анализ на базе **TRExFitter**, реализующий **profile likelihood fit** с учетом вклада сигнала и фонов



Сравнение ML-алгоритмов


- Классификация сигнал / фон - **ключевая задача анализов БАК**
- Традиционно используются **BDT и NN**
- Альтернативные ML-подходы **систематически не сравниваются**
- **Цель:** оценить эффективность современных алгоритмов ML для задач классификации в физике частиц

Данные и физический процесс

- ATLAS Open Data (2015–2016) и HEPData
- Одиночное рождение топ-кварка + W-бозон ([ATLAS tW](#))

Реализованный подход и результаты

- Воспроизведены ключевые результаты анализа [ATLAS tW](#) → **референсная точка**
- Проведено **сравнение различных ML-классификаторов** (*BDT, BDTG, MLP, SVM, PCA*) в рамках единого анализа
- Получено согласие результатов между разными программными средами [TMVA/Python/R](#) → **воспроизводимость**
- **Методы на основе деревьев решений (BDT/BDTG)** → **эффективность** использования входных переменных и **устойчивость** при ограниченной статистике
- **Нейросетевые (MLP) и вероятностные методы (SVM, Naive Bayes)** → нет значительного выигрыша по качеству классификации для данного набора переменных и доступной статистики



Better Bootstrap Confidence Intervals

- Неопределённости в HEP → **не всегда корректно описываются асимптотикой**
- Параметр ROI (μ) → **смещение и асимметричное распределение**


BCa bootstrap:

- коррекция смещений и асимметрии
- устойчивые доверительные интервалы

Подход и результаты:

- **Анализ WVZ:** первичная валидация bootstrap → корректное распределение μ
- **Метод на открытых данных HEPData -** “Measurement of t -channel production of single top quarks and antiquarks”
 - **1000 bootstrap-реплик** (Poisson), 100% сходимость
 - Реализация в **pyhf**, кросс-проверка с **TRExFitter**
 - **Доверительные интервалы (μ):** построены **BC/BCa** интервалы, **BCa** (коррекция смещения и асимметрии) → устойчивые CI при отсутствии асимптотических ошибок

$$\mu_{BC}[\alpha] = \hat{G}^{-1} \left(\Phi \left(2z_0 + z^{(\alpha)} \right) \right)$$



Bootstrap-распределение силы сигнала μ с BC 95% CI

Antitop quark ($\bar{t}q$):

$z_0 = -0.0954$, $a = 0.0112$
Standard : [1.0166, 1.0790] (width=0.0624)
Percentile : [1.0153, 1.0797] (width=0.0644)
BC : [1.0132, 1.0760] (width=0.0628)

Будущие планы

Машинное обучение

- Переход к более современным ML-методам в средах **R** и **Python** (*DNN, ensemble methods, transformers*)
- Сравнение с BDT/BDTG при увеличенной статистике
- Анализ устойчивости и переобучения ML-классификаторов

Статистика и bootstrap

- Расширенная валидация **BCa bootstrap** (*coverage, closure tests*)
- Применение bootstrap к параметрам интереса и систематикам
- Сравнение с асимптотическими подходами

Методологическое развитие

- Объединение **ML** и **bootstrap** для оценки устойчивости физических измерений
- Подготовка воспроизводимого workflow (*HEPData* → *ML* → *статистика*)
- Формирование рекомендаций по применению **bootstrap** / **BCa** в НЕР-анализах

Спасибо за внимание!