

Использование машинного обучения в физике высоких энергий


Сессия-конференция СЯФ ОФН РАН
Новосибирск, 10-12 марта 2020

Ф. Ратников

НИУ ВШЭ



Концепция машинного обучения




- МО - приближение универсальной (многопараметрической) модели к многомерным данным
- градиент метрики качества должен аналитически пересчитываться в градиенты параметров модели

Типичные задачи машинного обучения


- С учителем
 - классификация
 - регрессия
 - генерация
- Без учителя
 - кластеризация
 - автоматическое выявление взаимосвязей

Задача классификации




- Автоматический поиск наилучшей разделяющей поверхности в многопараметрическом подпространстве общих функций в многомерном пространстве характеристик объектов

Первые применения в ФВЭ



Computer Physics Communications

Volume 49, Issue 3, June 1988, Pages 429-448



Bruce Denby, 1988



Neural networks and cellular automata in experimental high energy physics

B. Denby


[Show more](#)

[https://doi.org/10.1016/0010-4655\(88\)90004-5](https://doi.org/10.1016/0010-4655(88)90004-5)

[Get rights and content](#)


Abstract

Within the past few years, two novel computing techniques, cellular automata and neural networks, have shown considerable promise in the solution of problems of a very high degree of complexity, such as turbulent fluid flow, image processing, and pattern recognition. Many of the problems faced in experimental high energy physics are also of this



- Возможность использования МО в задачах поиска треков и кластеров в детекторах ФВЭ.

Практические применения МО




Типичные задачи в ФВЭ

- Физический анализ, оптимизация отделения сигнала от фона (MVA)
- Быстрый отбор событий в триггере
- Реконструкция в детекторах
- Идентификация частиц в детекторе
- Поиск аномалий
 - технические аномалии: качество данных
 - физические аномалии: поиск новой физики
- Ускорение MC генераторов
- Ускорение симуляции детекторов


Single Top Discovery 2008

arXiv:0809.2581



- Проявление эффекта в распределении выхода классификатора, а не физического параметра

Оптимизация анализа данных. LHC



- Активное использование MVA в экспериментах LHC
 - ~ 50% прирост значимости для измерений бозона Хиггса
- В 2020 трудно найти физический анализ без использования MVA для разделения сигнала и фона
- типична совместная оптимизация ~10 критериев физического отбора

Самая свежая статья LHCb

EUROPEAN ORGANIZATION FOR NUCLEAR RESEARCH (CERN)



CERN-EP-2020-020
LHCb-PAPER-2019-043
9 March 2020

Search for the lepton flavour violating decay $B^+ \rightarrow K^+ \mu^- \tau^+$ using B_{s2}^{*0} decays

LHCb collaboration[†]

Abstract

A search is presented for the lepton flavour violating decay $B^+ \rightarrow K^+ \mu^- \tau^+$ using a sample of proton–proton collisions at centre-of-mass energies of 7, 8, and 13 TeV, collected with the LHCb detector and corresponding to a total integrated luminosity of 9 fb^{-1} . The τ leptons are selected inclusively, primarily via decays with a single charged particle. The four-momentum of the τ lepton is determined by using B^+ mesons from $B_{s2}^{*0} \rightarrow B^+ K^-$ decays. No significant excess is observed, and an upper limit is set on the branching fraction

$$\mathcal{B}(B^+ \rightarrow K^+ \mu^- \tau^+) < 3.9 \times 10^{-5} \text{ at } 90\% \text{ confidence level.}$$

The obtained limit is comparable to the world-best limit.

Submitted to JHEP

© 2020 CERN for the benefit of the LHCb collaboration. [CC BY 4.0 licence](#).


[†]Authors are listed at the end of this paper.

5 Multivariate signal selection

We further improve the signal selection using a Boosted Decision Tree (BDT) classification with the Adaboost algorithm [30]. The BDT inputs are primarily chosen to distinguish additional tracks coming from signal τ lepton decays from various sources of background. Some examples are semileptonic b -hadron decays to charm where the charm hadron produces a kaon with charge opposite that of the muon, or b -hadron decays where the muon is produced in the semileptonic decay of a child charm hadron. The background training sample is taken from the SSK sample in the m_{miss}^2 region around m_τ^2 . This focuses the training on the sources of background which fall near the signal peak. We describe the signal with simulation samples that include only B_{s2}^{*0} decays; the effect of the BDT on non- B_{s2}^{*0} signal simulation is then estimated separately. The training makes use of different topological reconstructions of the $K^+ \mu^- t^+$ triple: in addition to the signal selection, we also first combine either the kaon and the track or the muon and the track into a pair before adding the third particle. The pair masses and the flight distance of the pair in each topology help to distinguish the signal from background, for instance when the pair comes from a charm hadron decay. We also include the flight distance of the τ , which we reconstruct as the distance along the τ trajectory found in the missing-mass calculation from the $K^+ \mu^-$ vertex to the point of closest approach of the third track.

Классификация распадов


Nature, **560**, 41-48 (2018)



- Нейтринный эксперимент NOvA


Классификация в триггерах

arXiv:1510.00572




mode	2.5 kHz	4. kHz
$B^0 \rightarrow K^*[K^+\pi^-]\mu^+\mu^-$	1.64	1.72
$B^+ \rightarrow \pi^+K^-K^+$	1.59	1.65
$B_s^0 \rightarrow D_s^-[K^+K^-\pi^-]\mu^+\nu_\mu$	1.14	1.47
$B_s^0 \rightarrow \psi(1S)[\mu^+\mu^-]K^+K^-\pi^+\pi^-$	1.62	1.71
$B_s^0 \rightarrow D_s^-[K^+K^-\pi^-]\pi^+$	1.46	1.52
$B^0 \rightarrow D^+[K^-\pi^+\pi^+]D^-[K^+\pi^-\pi^-]$	1.40	1.86

- 70% данных LHCb отбирается основанными на применении МО триггерами



- Задача: перевзвесить события симуляции так, чтобы воспроизводились определённые распределения в данных
 - без проблем для 1D
 - непросто для больших размерностей и ограниченной статистики
- Естественная задача для МО: перевзвесить так, чтобы распределения стали неразличимыми для классификатора


Доменная адаптация



- Сделать алгоритм зависящим от существенных свойств объектов, но нечувствительным к деталям обучающего набора данных

Доменная адаптация в ФВЭ


- сигнал: $\tau \rightarrow 3\mu$ МС arXiv:1912.08001
- фон: " τ " $\rightarrow 3\mu$ реальные данные вне массы τ
- контрольные данные: $D_s \rightarrow \phi\pi \rightarrow 3\mu$




← без ДА

← с ДА


Поиск аномалий в данных



Поиск технических аномалий



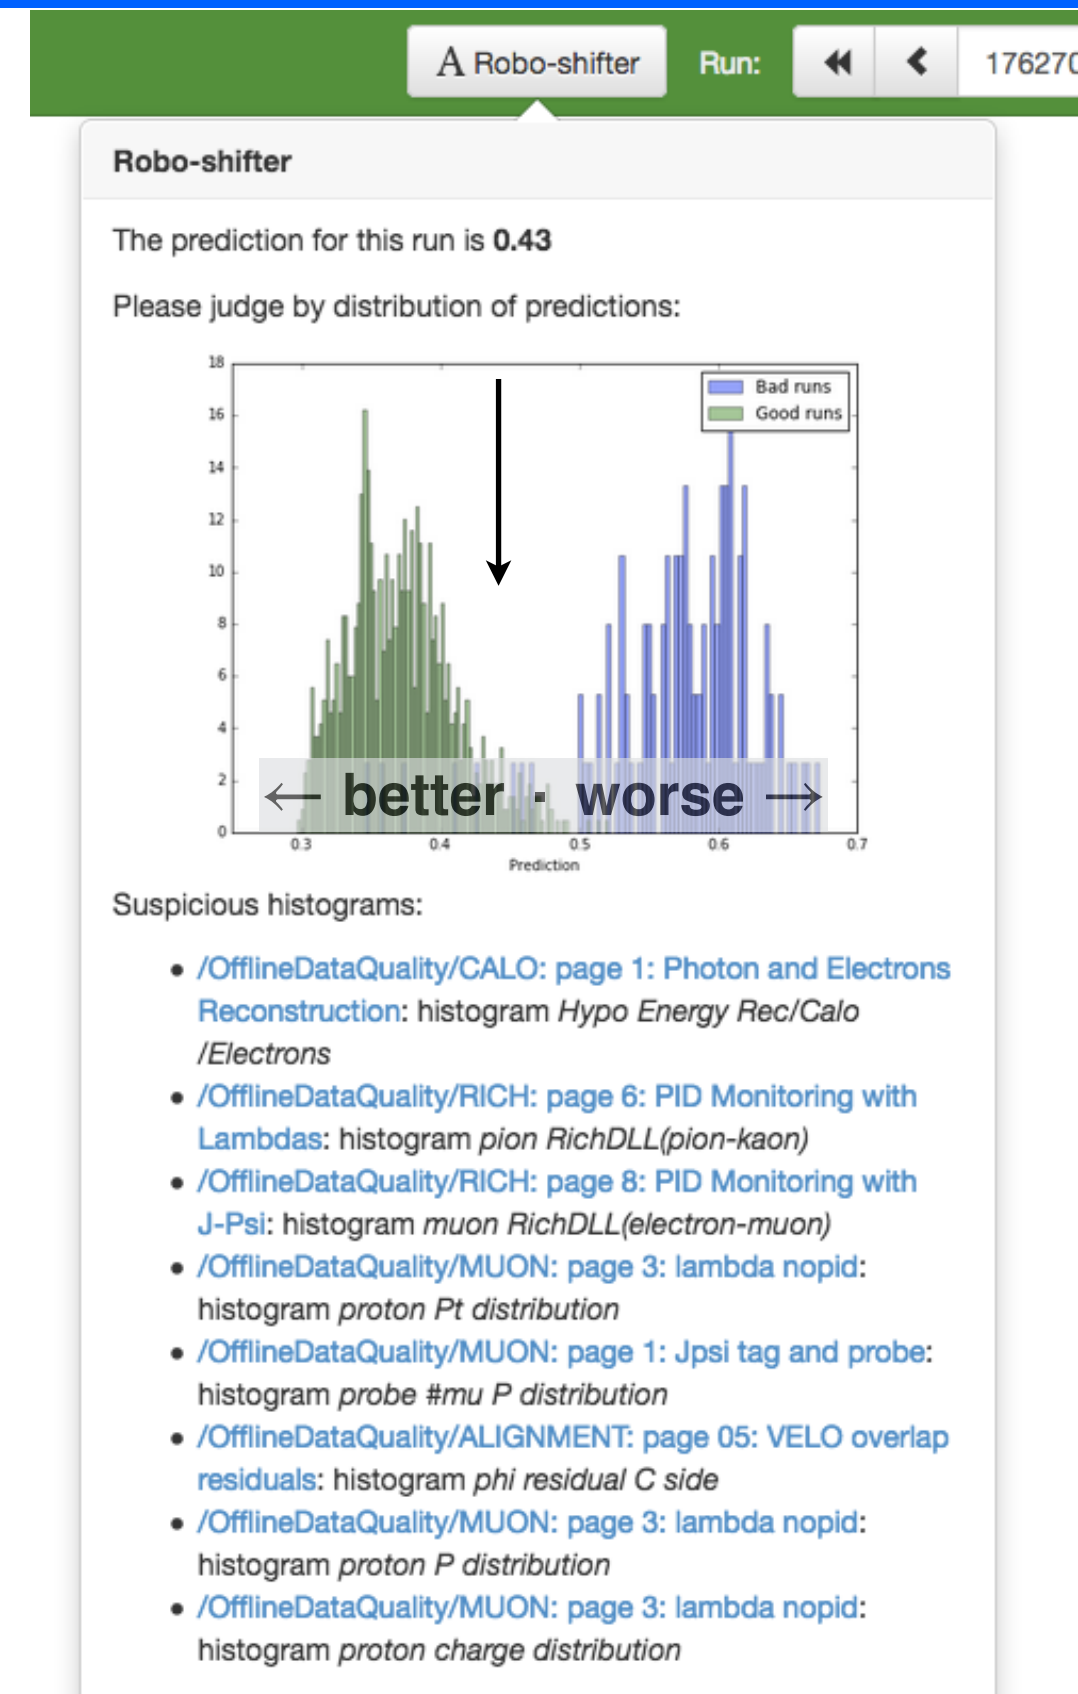
- Вход: кинематические распределения (процентили) для различных физических объектов в различных физических данных CMS
 - ~2500-D данные на входе
- Выход:
 - “данные OK”
 - “данные BAD”
 - “отдать эксперту для принятия решения”
 - < 20 % работы



Робошифтер (LHCb, DUNE)

- Основанный на МО помощник оператора
- Анализирует данные текущие высокоуровневые данные, делает предсказание о качестве текущих данных
- Подсказывает возможные источники проблем

J.Phys.Conf.Ser. 898 (2017) no.9, 092027



МО в теоретических исследованиях

- Machine Learning in the String Landscape
 - Carifio, J., J. Halverson, D. Krioukov, and B. D. Nelson (2017), JHEP 09, 157, arXiv:1707.00655 [hep-th].
- An equation-of-state-meter of QCD transition from deep learning
 - Pang, L.-G., K. Zhou, N. Su, H. Petersen, H. Stöcker, and X.-N. Wang (2018), Nature Commun. 9 (1), 210, arXiv:1612.04262 [hep-ph].
- Deep Learning and AdS/CFT
 - Hashimoto, K., S. Sugishita, A. Tanaka, (2018), Phys. Rev. D98 (4), 046019, arXiv:1902.05131 [hep-th].
- Machine learning action parameters in lattice quantum chromodynamics
 - Shanahan, P. E., D. Trewartha, and W. Detmold (2018), Phys. Rev. D97 (9), 094506, arXiv:1801.05784 [hep-lat].

12 месяцев в arXiv

Showing 1-41 of 41 results

hep-ex

Search v0.5.6 relea

Query: order: -announced_date_first; size: 50; hide_abstracts: True; date_range: from 2019-03-01 to 2020-03-08; classification: Physics (grp_physics)::High Energy Physics - Experiment (hep-ex); include_cross_list: True; terms: AND title=Machine Learning; OR title=deep learning

Refine query

New search

50 results per page. Sort results by Announcement date (newest first) Go

1. arXiv:2002.11516 [pdf, other] physics.data-an hep-ex

Automated detector simulation and reconstruction parametrization using machine learning

Authors: D. Benjamin, S. V. Chekanov, W. Hopkins, Y. Li, J. R. Love

Submitted 26 February, 2020; originally announced February 2020.

Comments: 12 pages, 7 figures

Report number: ANL-HEP-158616

2. arXiv:2002.09935 [pdf, other] physics.comp-ph hep-ex hep-ph quant-ph

Event Classification with Quantum Machine Learning in High-Energy Physics

Authors: Koji Terashi, Michiru Kaneda, Tomoe Kishimoto, Masahiko Saito, Ryu Sawada, Junichi Tanaka

Submitted 23 February, 2020; originally announced February 2020.

Comments: 11 pages, 11 figures, 4 tables

3. arXiv:2002.01427 [pdf, other] physics.data-an cs.LG hep-ex stat.ML

On the impact of modern deep-learning techniques to the performance and time-requiremen classification models in experimental high-energy physics

Authors: Giles Chatham Strong

Submitted 12 February, 2020; v1 submitted 3 February, 2020; originally announced February 2020.

Comments: Preprint V2: Added URL for framework and corrected timing information for final model

4. arXiv:2001.10814 [pdf, other] physics.data-an hep-ex

Deconvolution of the High Energy Particle Physics Data with Machine Learning

Authors: Bora İşildak, Alper Hayreter, Aidan R. Wiederhold

Submitted 29 January, 2020; originally announced January 2020.

Comments: 6 pages, 7 figures, 5 tables

Showing 1-17 of 17 results

hep-th

Search v0.5.6

Query: order: -announced_date_first; size: 50; hide_abstracts: True; date_range: from 2019-03-01 to 2020-03-08; classification: Physics (grp_physics)::High Energy Physics - Theory (hep-th); include_cross_list: True; terms: AND title=Machine Learning; OR title=deep learning

Refine query

New search

50 results per page. Sort results by Announcement date (newest first) Go

1. arXiv:2002.12927 [pdf, other] hep-th

Machine Learning $\mathcal{N} = 8, D = 5$ Gauged Supergravity

Authors: Chethan Krishnan, Vyshnav Mohan, Soham Ray

Submitted 28 February, 2020; originally announced February 2020.

Comments: 37 pages, mostly appendices. Code will soon be made available on GitHub

2. arXiv:2002.05169 [pdf, other] physics.comp-ph cond-mat.dis-nn cs.LG hep-ph hep-th stat.ML

Connecting Dualities and Machine Learning

Authors: Philip Betzler, Sven Krippendorf

Submitted 12 February, 2020; originally announced February 2020.

Comments: 35 pages, 19 figures

Report number: LMU-ASC 05/20, MPP-2020-14

3. arXiv:1911.07571 [pdf, other] hep-lat cond-mat.mes-hall cs.LG hep-th

Casimir effect with machine learning

Authors: M. N. Chernodub, Harold Erbin, I. V. Grishmanovskii, V. A. Goy, A. V. Molochkov

Submitted 18 November, 2019; originally announced November 2019.

Comments: 7 pages, 4 figures

4. arXiv:1911.02008 [pdf, other] math.NT cs.LG hep-th stat.ML

Machine Learning meets Number Theory: The Data Science of Birch-Swinnerton-Dyer

Authors: Laura Alessandretti, Andrea Baronchelli, Yang-Hui He

Submitted 4 November, 2019; originally announced November 2019.

Comments: 40 pages, 19 figures

5. arXiv:1910.08605 [pdf, other] hep-th math.AG stat.ML

12 месяцев в arXiv

Showing 1-41 of Showing 1-14 of 14 results

cs

Search v0.5.6 released 2020

Search v0.5.6

Query: order: -announced_date_first;
classification: Physics (grp_physics);
AND title=Machine Learning; OR title=

Query: order: -announced_date_first; size: 50; hide_abstracts: True; date_range: from 2019-03-01 to 2020-03-08;
classification: Computer Science (cs); include_cross_list: True; terms: AND title=HEP; OR title=High Energy Physics

Refine query

New search

50

results per page. Sort results by

Announcement date (newest first)

Go

1. [arXiv:2002.01427](#) [pdf, other] physics.data-an cs.LG hep-ex stat.ML

On the impact of modern deep-learning techniques to the performance and time-requirements of classification models in experimental high-energy physics

Authors: Giles Chatham Strong

Submitted 12 February, 2020; v1 submitted 3 February, 2020; originally announced February 2020.

Comments: Preprint V2: Added URL for framework and corrected timing information for final model

2. [arXiv:2001.06880](#) [pdf, other] stat.ML cs.LG stat.AP

A meta-algorithm for classification using random recursive tree ensembles: A high energy physics application

Authors: Vidhi Lalchand

Submitted 19 January, 2020; originally announced January 2020.

Comments: MPhil Thesis (Scientific Computing, Physics, Machine Learning)

3. [arXiv:2001.06033](#) [pdf, other] stat.ML cs.LG stat.AP

Extracting more from boosted decision trees: A high energy physics case study

Authors: Vidhi Lalchand

Submitted 16 January, 2020; originally announced January 2020.

Comments: Second Workshop on Machine Learning and the Physical Sciences (NeurIPS 2019), Vancouver, Canada

4. [arXiv:1912.08001](#) [pdf, other] cs.LG stat.ML

Sim-to-Real Domain Adaptation For High Energy Physics

Authors: Marouen Baalouch, Maxime Defurne, Jean-Philippe Poli, Noëlie Cherrier


Submitted 17 December, 2019; originally announced December 2019.

Comments: Accepted at the NeurIPS 2019 workshop on Machine Learning for the Physical Sciences (<https://ml4physicalsciences.github.io>)


5. [arXiv:1912.07999](#) [pdf, other] cs.LG stat.ML

МО для извлечения эффективных параметров модели

arXiv:1805.00013




- Для конвертации наблюдаемых в параметры модели требуется аккуратное вычисление значений функции правдоподобия данных для различных моделей
 - сложная задача
- Зависящие от модели партонные распределения можно отфакторизовать от эффектов детектора
 - ... и оценить значение отношения функций правдоподобия методами МО




Генеративные модели

- Генерация объектов в соответствии с заданной (изученной) вероятностью распределения $p(X | c)$
 - X - объект, c - условия



StyleGAN (NVIDIA)




arXiv:1912.04958

видео: <https://youtu.be/c-NJtV9Jvp0>

Генеративные модели (FastSim)


- Более 80% вычислительных ФВЭ тратится на симуляцию данных экспериментов
- Закон Мура вышел в насыщение
 - требуются новые решения для данных высоких светимостей LHC
- GEANT - переходная функция между (немногими) параметрами частицы и (макроскопическим) откликом детектора
 - вычисляемая на микроскопическом уровне детализации
- Идея: натренировать (более простую и быструю) суррогатную модель для воспроизведения этой переходной функции



Генеративные модели для калориметров

GEANT Simulated


$\log_{10}(\text{cell energy})$



GAN Generated


GEANT Simulated

$\log_{10}(\text{cell energy})$



GAN Generated


Генеративные модели



- Сгенерировать выглядящие похоже отклики - несложно
- Сложно воспроизвести маргинальные распределения
 - особенно, если их список не известен *a priori*


Генеративные модели (bumper to bumper)

- Симуляция RICH включает:
 - симуляцию прохождения частицы через радиатор
 - генерацию черенковских фотонов
 - распространение фотонов, отражение, преломление, рассеяние
 - симуляцию HPD
- Все эти вычисления требуют существенных компьютерных ресурсов
- при этом воспроизводимость получаемых параметров идентификации частиц оказывается не настолько хорошей, как хотелось бы



Генеративные модели (bumper to bumper)

- Симуляция RICH включает:
 - симуляцию прохождения частицы через радиатор
 - генерацию черенковских фотонов



- **Используем МО:**


- натренируем генеративную модель переводить кинематику трека непосредственно в параметры идентификации
- можно тренироваться прямо на калибровочных образцах данных

получаемых параметров идентификации частиц оказывается не настолько хорошей, как хотелось бы

0 100 200 z (cm)

Генеративные модели RICH




arXiv:1903.11788




- Хорошо или плохо?

Генеративные модели на реальных данных


- $\mathcal{NB}$: сравнение генеративной модели с независимыми данными
- малые расхождения уходят в систематику




Использование МО для R&D детекторов



Использование МО для R&D детекторов



Использование МО для R&D детекторов



arXiv:2003.05118

Заключение

- Применение машинного обучения, искусственный интеллект, анализ больших данных оказывают существенное влияние на развитие современной цивилизации
- Полученные наработки широко адаптируются и используются в современной ФВЭ
- Навык владения аппаратом МО стал существенным аспектом успеха физических программ современных экспериментов ФВЭ
- ... а также, использование МО для задач ФВЭ повышает мотивацию научной молодёжи, поскольку эти навыки высоко ценятся и имеют широчайшую область применения

Интеллект и навыки

François Chollet (Google)

