



UNIWERSYTET
WARSZAWSKI

Warszawa, 29 grudnia 2025

Imię i nazwisko recenzenta:

.....

dr hab. Katarzyna Grzelak

Dane adresowe:

.....

Wydział Fizyki

Uniwersytet Warszawski

ul. Pasteura 5

02-093 Warszawa

Recenzja pracy doktorskiej
Sabina Hashmi

pod tytułem: Real-Time Machine Learning-Enhanced Reconstruction of Long-Lived Tracks in LHCb High-Level Trigger and Calibration Analysis of the UT Detector

przygotowanej pod kierunkiem:

prof. dr hab. inż. Tomasza Szumlaka

1. Podstawa opracowania

Recenzja została wykonana na zlecenie Rady Dyscypliny Nauki Fizyczne Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie. Podstawa prawna art. 187 Ustawy z dnia 20 lipca 2018 r. „Prawo o szkolnictwie wyższym i nauce” (z późn. zm.)

2. Charakterystyka i opis rozprawy

Rozprawa doktorska, która jest przedmiotem recenzji, została wykonana w ramach międzynarodowego eksperymentu LHCb. Składa się z dwóch części. Pierwsza, stanowiąca większość pracy, poświęcona jest opracowaniu i zastosowaniu metod uczenia maszynowego (ML) do poprawy rekonstrukcji torów cząstek pochodzących z rozpadów cząstek długo-życiowych w detektorze LHCb. Druga, krótsza część opisuje prace autora związane z kalibracją detektora śladowego UT (Upstream Tracker), między innymi przy wykorzystaniu sieci neuronowej RNN (Recurrent Neural Network).

Rozprawa została napisana w języku angielskim i jest podzielona na osiem rozdziałów, poprzedzonych opisem na czym polegał wkład autora do prac eksperymentu LHCb.

Rozdział pierwszy zawiera bardzo zwięzły opis motywacji fizycznej stojącej za badaniami prowadzonymi przy akceleratorze LHC i w eksperymencie LHCb, krótkie

wprowadzenie do Modelu Standardowego Cząstek i Oddziaływań Fundamentalnych oraz do najważniejszych pojęć związanych z akceleratorem LHC i eksperymentem LHCb. Opis detektora LHCb jest tak krótki, że nie znalazło się w nim zdanie mówiące o roli układu wyzwalania. W podrozdziale 6, w rozdziale pierwszym znajduje się rysunek detektora, ale nie ma nigdzie opisu jego głównych składowych. Bardziej szczegółowy jest opis systemu detektorów śladowych i poziomów układu wyzwalania eksperymentu LHCb, co jest niezbędne w zrozumieniu głównych rozdziałów pracy. Największym mankamentem rozdziału pierwszego jest jednak brak wyjaśnienia jaka motywacja fizyczna stoi za poszukiwaniem tytułowych „long-lived tracks”. Jednocześnie samo określenie „long-lived tracks” wydaje się być zbyt dużym skrótem myślowym.

W rozdziale drugim zostało opisane jak klasyfikuje się tory cząstek w detektorze LHCb, w zależności od detektorów w jakich zostały zarejestrowane; co jest wyzwaniem przy rekonstrukcji torów powstałych z rozpadów długożyciowych cząstek i jakie są elementy standardowego algorytmu do rekonstrukcji tych torów. W tym rozdziale została również omówiona cała struktura oprogramowania eksperymentu.

Rozdział trzeci zawiera wprowadzenie do uczenia maszynowego, krótki przegląd stosowanych w jego ramach metod, wyjaśnienie używanych pojęć i opis sposobów ewaluacji uzyskanych wyników. Drobnym uchybieniem jest to, że rysunek 13 w tym rozdziale wydaje się być opisem szczególnego przypadku użycia regresji liniowej, ale ten przykład nie został w pracy opisany i nie wiadomo co dokładnie rysunek przedstawia.

W rozdziałach czwartym i piątym opisane są główne wyniki pracy dotyczące zastosowania metod uczenia maszynowego do poprawy rekonstrukcji torów cząstek powstałych z rozpadów cząstek długożyciowych.

Pierwszy etap polegał na opracowaniu klasyfikatora segmentów torów (SciFi Track Classifier) w detektorze SciFi, które są używane jako zaczątki (seed) całych torów. Usunięcie jak największej liczby fałszywych zaczątków torów jest z pewnością jednym z ważniejszych elementów rekonstrukcji śladów cząstek. Widać tu dużą pracę włożoną w przetestowanie różnych metod uczenia maszynowego, wybór najlepszych danych wejściowych i najlepszej metody ML. W tej części nie zostało niestety wyjaśnione jak ostatecznie została przygotowana próbka użyta do treningu metod. Z opisu wynika, że stosunek liczby fałszywych torów do prawdziwych został wzmocniony, ale nie jest jasne w jaki sposób zostało to zrobione. Prawdopodobnie torów prawdziwych i fałszywych było tyle samo, co byłoby dobrym podejściem. Jedyne zdanie opisujące procedurę jest niestety niezrozumiałe: „Within the data set used for training, the ratio of Ghost Tracks to true tracks is significantly high, while the Ghost Track ratio is relatively small compared to the true track as shown in Figure 21.” Zastanawiające jest dlaczego przy typowej dla eksperymentów przy LHC gęstości torów, fałszywych torów na rysunku 21 jest tak mało w porównaniu do tych prawdziwych.

Drugi etap polegał na przygotowaniu klasyfikatora torów cząstek zbudowanych z sygnałów w detektorze SciFi i znajdującym się bliżej punktu oddziaływania detektorze UT, ale nie w detektorze wierzchołka. Takie tory są kandydatami na ślady cząstek pochodzących z rozpadu cząstek długożyciowych. Zadaniem klasyfikatora jest odróżnianie torów fałszywych od prawdziwych.

W przypadku obu klasyfikatorów użyto tych samych plików Monte Carlo. Ich cha-

rakterystyki opisane są jedynie w tabelach 2 i 8, a z nich nie wynika co dokładnie zawierają. Piąty rozdział zawiera podobnie szczegółową jak w rozdziale czwartym analizę wejściowych zmiennych i porównanie działania różnych metod uczenia maszynowego. W obu przypadkach badania zakończyły się wyborem modelu Catboost.

Rozdział szósty opisuje etap integracji opracowanych klasyfikatorów z istniejącym środowiskiem układu wyzwania (High-Level Trigger) eksperymentu LHCb, ich optymalizację i ewaluację, w tym porównanie z modelem bazowym.

Opracowane modele znacznie wydajniej usuwają fałszywe tory kosztem niewielkiego obniżenia efektywności rekonstrukcji prawdziwych torów. Dodatkowo w przypadku próbki z wynikami symulacji $K_S^0 \rightarrow \pi^+ \pi^-$ sprawdzono, że zastosowanie przygotowanych algorytmów nie obciąża próbki zrekonstruowanych torów, nie deformuje rozkładów kinematycznych zmiennych i nie wpływa na rozkład masy niezmienniczej w okolicach masy K_S^0 , co potwierdza poprawność działania opracowanej metody. Trzeba jednak zauważyć, że ewaluacja działania klasyfikatorów wydaje się być zrobiona w oparciu o symulację w której stosunek liczby fałszywych torów do prawdziwych jest niski.

Rozdział siódmy opisuje prace autora związane z usprawnieniem procedur kalibracyjnych detektora UT, między innymi przy użyciu sieci neuronowej RNN.

Praca została wyjątkowo ładnie i starannie złożona. Z przyjemnością bierze się ją do ręki. Ma przejrzysty i logiczny układ. Mało jest drobnych pomyłek i niedoskonałości, takich jak pomyłka w podpisie rysunku 38, gdzie w nawiasie powinno być napisane Balanced zamiast Unbalanced. Rysunki są wysokiej jakości. Wyjątkiem jest tutaj rysunek 64, gdzie legenda jest nieczytelna.

Opisy pod rysunkami w wielu wypadkach są za oszczędne. Przykładowo, w jednym z najważniejszych rozdziałów pracy, rysunki 21, 22 i 23 wymagałyby zdecydowanie obszerniejszych podpisów: jaka dokładnie próbka została użyta do wykonania rysunku 21; co przedstawiają kolejne elementy na rysunku 22; dlaczego na rysunku 23, na środku jest prostokątne okno w którym brakuje tylko prawdziwych punktów (hits); z której warstwy detektora SciFi pochodzą narysowane punkty. W opisie rysunku 62 nie skomentowany jest nietypowo duży udział fałszywych torów dla małych p_T w przypadku bazowego modelu.

Spis literatury zawiera 48 pozycji. Powinny się w nim znaleźć pozycje uzasadniające zainteresowanie tytułowymi „long-lived tracks” w kontekście fizyki poza Standardowym Modelem Fizyki Cząstek (BSM). Nie ma też odnośnika do pozycji wyjaśniającej czym jest ONXX i do szerszego opisu standardowych algorytmów rekonstrukcyjnych. W ostatnim przypadku prawdopodobnie dlatego, że jest on dostępny tylko w postaci wewnętrznych not eksperymentu. Z drobnych uwag, w tytułach zawartych w spisie literatury słowa: Cp, lhcb, lhc, higgs, kalman zapisane są małymi literami, niezgodnie z obowiązującymi konwencjami.

Poniżej przedstawiam opinię o rozprawie:

(a) Ogólna wiedza o dyscyplinie

W pierwszym rozdziale autor demonstruje podstawową znajomość fizycznej motywacji stojącej za budową eksperymentu LHCb i opisuje podstawy Standardowego Modelu Cząstek i Oddziaływań Fundamentalnych. Praca zawiera również cały rozdział (trzeci) poświęcony podstawom uczenia maszynowego. Dodatkowo, w rozdziale siódmym opisane są procesy fizyczne zachodzące w krzemowych detektorach, z powodu których konieczna jest częsta kalibracja

pedestałów w poszczególnych kanałach detektora.

Ogólną wiedzę autora o dyscyplinie oceniam pozytywnie, pomimo poważnego braku opisu motywacji fizycznej stojącej za poszukiwaniem tytułowych „long-lived tracks”.

- (b) Umiejętność samodzielnego prowadzenia pracy naukowej
W rozprawie doktorskiej sformułowane zostało zadanie polegające na opracowaniu algorytmu opartego na uczeniu maszynowym, który zredukowałby liczbę fałszywych torów i poprawił rekonstrukcję torów cząstek pochodzących z rozpadów cząstek długożyciowych. To zadanie zostało przez autora zrealizowane, poczynając od wybrania zmiennych wejściowych do algorytmów uczenia maszynowego, poprzez opracowanie dwóch klasyfikatorów a kończąc na zintegrowaniu stworzonych algorytmów ze złożonym środowiskiem programistycznym eksperymentu LHCb i przetestowaniu ich działania. W mojej opinii, tym samym autor rozprawy wykazał się umiejętnością prowadzenia samodzielnej pracy naukowej.
- (c) Oryginalne rozwiązanie problemu naukowego
W rozprawie doktorskiej wykorzystane zostały nowoczesne metody uczenia maszynowego do usuwania fałszywych torów w procesie rekonstrukcji i do kalibracji jednego z detektorów śladowych. W obu przypadkach jest to bez wątpienia oryginalne i nowatorskie podejście, co należy wysoko ocenić.

Pytania:

- (a) Co było główną motywacją fizyczną, stojącą za wysiłkiem związanym z poprawą rekonstrukcji tytułowych „long-lived tracks”?
- (b) Proszę o rozszyfrowanie skrótów z tabeli nr 2 i 8, opisujących parametry użytych symulacji Monte Carlo, a w szczególności jak należy rozumieć „Event Type MinBias” i „MagDown”.
- (c) Dla jakiej próbki i po jakich cięciach przygotowane zostały rysunki 21 i 40?
- (d) Jak wygląda porównanie rozkładów zmiennych wejściowych dla torów prawdziwych i fałszywych w przypadku klasyfikatorów z rozdziału 4 i 5?
- (e) Czy istnieje proste wyjaśnienie dlaczego w modelu Catboost (rys. 36) zmienna X ma dużo większy wpływ na końcowy wynik niż w liniowym modelu (rys.28)?
- (f) Jak należy rozumieć zdanie z podsumowania: „The main impact of the enhanced algorithm, using the current working point tuning, is related to the reduced time of processing in the HLT trigger” w świetle czasów procesowania danych pokazanych w tabeli 16?

3. Wniosek końcowy

Podsumowując stwierdzam, że recenzowana rozprawa spełnia wymagania określone w art. 187 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (z późn.zm.) i wnioskuję o jej dopuszczenie do dalszych etapów postępowania o nadanie stopnia doktora w dziedzinie nauk ścisłych i przyrodniczych w dyscyplinie nauki fizyczne.

Kotarski Gniedzi