

Mgr inż. Maciej Witold Majewski
Katedra Oddziaływań i Detekcji Cząstek
Wydział fizyki i Informatyki Stosowanej

Streszczenie rozprawy doktorskiej

Zastosowanie metod uczenia maszynowego do analizy danych kalibracyjnych detektora LHCb VELO, badania właściwości naświetlonych sensorów pikselowych oraz rekonstrukcji przypadków rozprożeń neutrin w e LArTPC

Praca ta łączy wiele tematów dotyczących detektorów cząstek i nowatorskich zastosowań inteligencji obliczeniowej w celu usprawnienia analizy danych przez nie wytwarzanych. Jako ekspert i entuzjasta AI, moim głównym przedmiotem badań jest zastosowanie metod uczenia maszynowego do rozwiązywania problemów w dziedzinie detektorów cząstek wysokich energii. Istota tego dokumentu dotyczy spektrometru LHCb i jego wysokoprecyzyjnego krzemowego detektora Vertex Locator zarówno w wersji paskowej, jak i zmodernizowanego - w wersji pikselowej. LHCb jest jednym z detektorów przy Wielkim Zderzaczu Hadronów, a jego odkrycia przyczyniły się do pogłębionego rozumienia fizyki cząstek elementarnych. W dwóch okresach zbierania danych, Run 1 (2011-2012) i Run 2 (2015-2018), zgromadzono próbki danych o zintegrowanej świetlności około 9fb⁻¹. Eksploatacja detektorów krzemowych w tak intensywnym polu promieniowania wiąże się z kosztem w postaci uszkodzeń radiacyjnych. Fakt ten był głównym powodem unowocześnienia wstępnego projektu dla nadchodzących Run 3 i 4.

Unikalne wymagania i warunki, w jakich musi pracować detektor Velo, wymagają szeroko zakrojonej fazy badawczej związanej nie tylko z badaniami sprzętowymi, ale także z nowymi metodami monitorowania i analizy stanu detektora. Te ostatnie zostały przedstawione w niniejszej rozprawie. Rozdziały początkowe, do Rozdziału 3 włącznie, zawierają niezbędne teoretyczne i techniczne wprowadzenie do szczegółowych celów badawczych, konstrukcji detektora i metod analizy. Rozdziały poruszające unikalną analizę kalibracji detektora Velo w Runs 1 i 2 zawarte są w Rozdziale 4, a badania zmodernizowanego detektora w Rozdziale 5.

W pierwszej części prezentowanych badań badane są dwa parametry kalibracyjne pochodzące od sygnału szumu odbieranego przez sensory krzemowe detektora, pedestal (średnia szumu) i threshold (odchylenie standardowe szumu). Parametry te badane są pod różnymi kątami i w różnych wymiarach. Analiza trendu piedestałów nie wykazała żadnych utrzymujących się efektów, co potwierdza, że adaptacja napięcia podawanego do detektora mieściła się w akceptowalnych zakresach. Analiza parametrów progowych wykazała wpływ szkodliwego promieniowania na sensory. Zainspirowała ona stworzenie nowatorskiego algorytmu opartego na uczeniu maszynowym do oceny kalibracji. Stworzyłem i zaimplementowałem algorytm o nazwie "outlierness" i z powodzeniem wprowadziłem go do monitorowania detektora Velo w 2018 roku.

Duża wymiarowość problemu (duża liczba indywidualnych kanałów odczytu sensorów) przyczyniła się do testów algorytmów redukcji wymiarowości (PCA i autoencoder). Testy wykazały iż oba algorytmy mogą ujawnić anomalie w funkcjonowaniu detektora. Subtelne przesunięcia w relacji kalibracji do szumu występującego w detektorze podczas pobierania danych skłoniły nas do wykorzystania tego efektu i użycia rekurencyjnej sieci neuronowej do przewidywania czasu niezbędnej kalibracji detektora.

Nowy detektor Velo w nadchodzącym Run 3 wykorzystuje pikselową matrycę jako sensor i zwiększa liczbę poszczególnych kanałów o ponad dwa rzędy wielkości. Brałem udział w tworzeniu

nowatorskiej metody wyszukiwania i śledzenia skupisk zamaskowanych (wadliwych) pikseli, wykorzystującej strumień danych kalibracyjnych. Ta metoda pozwoli na bardziej świadome podejmowanie decyzji o konieczności wykonania kalibracji detektora.

O ile większość metod analizy kalibracji detektora bazujących na uczeniu maszynowym może być wykorzystana dopiero gdy detektor jest już w pełni uruchomiony i funkcjonuje, o tyle dane testowe detektorów mogą być wykorzystane do badania skutków promieniowania. Nowy sensor VeloPix rejestruje sygnał przekroczenia progu czasowego, który za pomocą funkcji zastępczej ("surrogate function") można powiązać z energią zdeponowaną w sensorze wyrażoną w eV.

Okazuje się że zmiana parametrów funkcji rekonstruującej ładunek jest powiązana z ilością całkowitego promieniowania dostarczonego do sensora. Badałem ten efekt, co doprowadziło do opracowania podstaw przełomowej inteligentnej metody oceny fluencji sensora.

Doświadczenia z pracy z Velo doprowadziły do opracowania niezbędnych i nowatorskich rozwiązań problemów praktycznych przedstawionych w rozdziale 6. Kontakt z danymi kalibracyjnymi i świadomość potrzeby narzędzi do ich przetwarzania, przyczyniły się do stworzenia webowego serwisu bazodanowego o nazwie Storck, który jest w trakcie wprowadzania do systemów LHCb podczas rozruchu detektora. Wraz z systemem bazodanowym prezentowany jest open source'owy framework do efektywnego tworzenia narzędzi monitorujących - Titania. Storck i Titania są generycznymi narzędziami open-source, które mogą być używane niezależnie w dowolnym eksperymencie. Kierowałem rozwojem obu tych projektów wraz z kilkoma programistami.

Zastosowania metod uczenia maszynowego w detektorach fizyki wysokich energii wykazują zwykle dużą specyfikę i dostosowanie do szczegółowego celu badawczego z zakresu fizyki i konstrukcji detektora. O ile zwykle konieczne jest opracowanie rozwiązań dla konkretnych problemów, o tyle o problemie śledzenia i identyfikacji cząstek można myśleć jako o bardziej uniwersalnym. Prace nad uogólnieniem algorytmów uczenia maszynowego na potrzeby eksperymentów fizyki cząstek są w dużej mierze dziewiczym terenem badań. Duży i otwarty zbiór danych stworzony przez kolaborację DeepLearnPhysics jest okazją do wczesnego poszukiwania bardziej ogólnej AI zdolnej do zrozumienia zasad rządzących naszym wszechświatem. Szansa ta została wykorzystana przez ambitną próbę zbadania zastosowania metody uczenia wzmacniającego do śledzenia i identyfikacji cząstek w zbiorze danych LARTPC. Badania te zostały przedstawione w rozdziale 8, a wprowadzenie teoretyczne w rozdziale 7.