

Raport z realizacji projektu zespołowego

Działalność w grupie badawczej Warsaw TPC

Paweł Gawron¹, Hubert Paszkiewicz¹, and Jakub Skwarek¹

¹Uniwersytet Warszawski, Wydział Fizyki

28 września 2026

Opiekun naukowy: dr hab. prof. ucz. Artur Kalinowski

Streszczenie

Niniejszy raport prezentuje przebieg oraz wyniki czteroosobowego projektu studenckiego realizowanego w ramach grupy badawczej eksperymentu Warsaw TPC. Głównym celem przedsięwzięcia było zaprojektowanie i rozwój narzędzi informatycznych służących do analizy danych pomiarowych. Projekt motywowany był przede wszystkim chęcią głębszego poznania specyfiki działania detektorów typu TPC (komór projekcji czasowej) oraz metodologii przetwarzania pochodzących z nich sygnałów, co ostatecznie służy badaniu procesów astrofizyki jądrowej, takich jak fotodezintegracja tlenu. W dokumencie opisano podstawy fizyczne i aparaturowe komory Warsaw TPC, a następnie zaprezentowano przebieg właściwych prac analityczno-programistycznych, które zostały podzielone na tematyczne pule zadań realizowane przez poszczególnych członków zespołu.

Spis treści

1	Wstęp i opis projektu	3
1.1	Kontekst fizyczny i motywacja	3
1.2	Aparatura badawcza: Warsaw TPC	3
1.3	Profil i cel główny projektu	3
1.4	Organizacja pracy i podział zadań	4
2	Realizacja zadań	4
2.1	Ewaluacja algorytmów rekonstrukcji zdarzeń	4
2.2	Dekonwolucja sygnału z elektroniki GET	5
2.3	Wpływ szumu na rekonstrukcję śladów w TPC	9
2.3.1	Motywacja fizyczna	9
2.3.2	Model szumu	9
2.3.3	Przygotowanie próbek MC	10
2.3.4	Wielkości analizowane w rekonstrukcji	10
2.3.5	Wyniki	11
2.3.6	Koszt czasowy	12
2.3.7	Podsumowanie	12
2.4	Optymalizacja rekonstrukcji z wykorzystaniem sieci neuronowych . .	13
2.4.1	Cel i założenia	13
2.4.2	Analiza modeli i interpretacja wykresów	13
2.4.3	Weryfikacja kryterium efektywności rekonstrukcji	21
2.4.4	Wyniki po korekcie kryterium efektywności	23
2.4.5	Eksperyment z przełącznikiem modeli	28
3	Podsumowanie i wnioski końcowe	30


1 Wstęp i opis projektu

1.1 Kontekst fizyczny i motywacja

Zrozumienie zjawisk gwiazdowej nukleosyntezy, a w szczególności procesów powstawania i rozpadu tlenu pod wpływem promieniowania, pozostaje jednym z wyzwań współczesnej astrofizyki jądrowej. Jedną z takich kluczowych reakcji jest fotodezintegracja tlenu. Badanie tego typu reakcji fotonuklearnych zachodzących przy niskich astrofizycznych energiach wymaga zastosowania wysoce precyzyjnej i wyspecjalizowanej aparatury. Odpowiedzią na te zapotrzebowania jest projekt detektora Warsaw TPC, rozwijany na Uniwersytecie Warszawskim.

1.2 Aparatura badawcza: Warsaw TPC

Detektor Warsaw TPC to komora projekcji czasowej z aktywną tarczą. W odróżnieniu od klasycznych eksperymentów na tarczy stałej, w tym rozwiązaniu gaz, pracujący często pod obniżonym ciśnieniem, spełnia rolę zarówno ośrodka detekcyjnego, w którym dochodzi do jonizacji, jak i tarczy, z którą zderza się nadbiegająca, monochromatyczna wiązka fotonów gamma. Aby właściwie zarejestrować powstające w wyniku zderzenia słabe sygnały, detektor stosuje powielacze elektronowe GEM do wzmacniania jonizacji pierwotnej. Takie podejście umożliwia trójwymiarowe obrazowanie i rekonstrukcję torów naładowanych produktów reakcji.



Rysunek 1: Schemat detektora WarsawTPC.

1.3 Profil i cel główny projektu

Zasadniczym celem projektu studenckiego był udział w pracach badawczych prowadzonych przez zespół eksperymentu Warsaw TPC. Mimo iż badane zjawiska fizyczne opierają się na zaawansowanej aparaturze detekcyjnej, wkład zespołu studenckiego koncentrował się na zagadnieniach analitycznych i programistycznych. Realizowane

zadania badawcze dotyczyły w głównej mierze rozwoju, testowania i optymalizacji algorytmów rekonstrukcji zdarzeń, a także procedur dekonwolucji sygnału z elektroniki odczytu. Opracowywane rozwiązania stanowią kluczowe ogniwo w łańcuchu przetwarzania danych, umożliwiając transformację surowych sygnałów z detektora w precyzyjne wielkości kinematyczne, niezbędne ostatecznie do wyznaczania przekrojów czynnych na astrofizyczne procesy jądrowe.

1.4 Organizacja pracy i podział zadań

Projekt realizowano w trzyosobowym zespole przy wsparciu jednego opiekuna naukowego. W ramach uczestnictwa w grupie badawczej wykonano cztery odrębne zadania, z których każde skupiało się na innym elemencie procesu analizy danych z detektora.

2 Realizacja zadań

2.1 Ewaluacja algorytmów rekonstrukcji zdarzeń

Wykonawca: Jakub Skwarek


Opis realizacji:

W ramach zadania przeprowadzono ewaluację metod rekonstrukcji zdarzeń, zaproponowanych przez poprzednie zespoły badawcze. Szczegółowej analizie poddano algorytm opracowany przez studentów z Wydziału Matematyki, Informatyki i Mechaniki UW (MIM UW) [1].

Testy przeprowadzono z wykorzystaniem początkowej próby 10000 wygenerowanych zdarzeń z symulacji Monte Carlo. Po zastosowaniu fizycznych cięć na długość zrekonstruowanego toru cząstki α w przedziale od 30 do 100 mm, do dalszej analizy zakwalifikowano 5269 przypadków. Próbkę ta dzieliła się niemal równomiernie na 2593 zdarzenia kinematycznie skierowane do przodu (ang. *Forward*, gdzie $z_{Alpha} > z_{Vtx}$) oraz 2676 zdarzeń skierowanych do tyłu (ang. *Backward*, gdzie $z_{Alpha} < z_{Vtx}$).

Otrzymane wyniki weryfikacji przedstawiono na Rysunku 2. Algorytm MIM UW poprawnie radził sobie niemal wyłącznie z topologią *Forward*. Co więcej, podczas wykonywania procedury odnotowano niestabilności numeryczne skutkujące błędami operacji matematycznych, co wskazuje na problemy z normalizacją wektorów. Ten asymetryczny spadek efektywności sugeruje fundamentalny błąd w zaimplementowanej logice obsługi geometrii śladów wstecznych, a nie fizyczne ograniczenie rozdzielczości samego detektora.

Biorąc pod uwagę zidentyfikowane problemy numeryczne oraz brak poprawnej i symetrycznej obsługi pełnego kąta bryłowego emisji cząstek, zbadany algorytm nie spełnia obecnie wymogów eksperymentu. Do czasu wdrożenia poprawek geometrycznych, standardowa metoda rekonstrukcji dostępna w pakiecie TPCReco pozostaje rozwiązaniem znacznie bardziej wszechstronnym i to ona jest rekomendowana do prowadzenia ostatecznej analizy fizycznej.



Rysunek 2: Wizualizacja wydajności algorytmu MIM UW w podziale na klasę zdarzeń. Po lewej: efektywność rekonstrukcji dla torów skierowanych do przodu (*Forward*). Po prawej: efektywność dla torów skierowanych do tyłu (*Backward*), ilustrująca znaczny spadek skuteczności metody.

2.2 Dekonwolucja sygnału z elektroniki GET

Wykonawca: Jakub Skwarek

Opis realizacji:

Kolejnym zadaniem w ramach projektu było opracowanie oraz walidacja metody dekonwolucji sygnału. Sygnał dryfujący z powielaczy GEM, rejestrowany przez elektronikę GET, ulega naturalnemu splutowi z jej odpowiedzią. Z tego powodu konieczne było zaimplementowanie algorytmu odwrotnego w celu odzyskania pierwotnego, fizycznego kształtu zdeponowanego ładunku.

Zastosowana metoda opierała się na dekonwolucji w dziedzinie częstotliwości z wykorzystaniem transformaty Fouriera. Podstawą teoretyczną oraz inspiracją do optymalizacji tego podejścia była praca [2]. Zgodnie z twierdzeniem o splocie, odzyskanie pierwotnego rozkładu ładunku $Q(t)$ z zarejestrowanego sygnału $S(t)$ wymaga operacji dzielenia ich widm. Zrekonstruowany sygnał wyraża się wzorem:

$$Q(t) = \mathcal{F}^{-1} \left(\frac{S(f)}{H_{reg}(f)} \cdot \Phi(f) \right)$$

gdzie $\mathcal{F}^{-1}$ to odwrotna transformata Fouriera, natomiast $S(f)$ oraz $H_{reg}(f)$ oznaczają odpowiednio transformatę sygnału zmierzonego oraz zregularyzowane widmo funkcji odpowiedzi elektroniki. Ponieważ proces dekonwolucji jest z natury podatny na silne wzmacnianie szumów wysokoczęstotliwościowych (powstających przy dzieleniu przez wartości mianownika bliskie zero), wprowadzono dolny próg bezpieczeństwa dla modułu $|H(f)|$.

Aby dodatkowo wygładzić sygnał, w algorytmie zaimplementowano odpowiedni filtr dolnoprzepustowy $\Phi(f)$ z ostrym odcięciem częstotliwości. Wykorzystano filtr Butter-

wortha rzędu n , zdefiniowany jako:

$$\Phi(f) = \frac{1}{1 + \left(\frac{f}{f_{cut}}\right)^{2n}}$$


gdzie f_{cut} stanowi zoptymalizowaną eksperymentalnie częstotliwość odcięcia, pozwalającą zachować rygorystyczny balans między wiernością rekonstrukcji śladu a tłumieniem szumu elektroniki.

Kluczowa dla powodzenia algorytmu funkcja odpowiedzi układu pomiarowego, niezbędna do wyznaczenia widma $H(f)$, została przyjęta za pracę [2]. Wyraża się wzorem:

$$h(t) = \mathcal{N}\left(\frac{t}{\tau}\right)^3 \exp\left(-3\frac{t}{\tau}\right) \sin\left(\frac{t}{\tau}\right) \cdot \Theta(t)$$

gdzie τ określa stałą czasową układu formującego (w analizowanych danych wynoszącą typowo 232 ns), $\mathcal{N}$ jest stałą normalizacyjną zapewniającą zachowanie wielkości całkowitego ładunku po splocie, a $\Theta(t)$ to funkcja skokowa Heaviside'a, gwarantująca przyczynowość sygnału. W celu zachowania fizycznego sensu ładunku, na ostatnim etapie przetwarzania odzyskany sygnał $Q(t)$ poddawano nieliniowemu zerowaniu niefizycznych ujemnych oscylacji u jego podstawy ($Q(t) \geq 0$).


W pierwszej fazie analizy wykorzystano uproszczony model analityczny. Pozwolił on na zbadanie zachowania algorytmu w kontrolowanych warunkach oraz uwypuklił kluczową rolę precyzyjnego doboru parametru odcięcia częstotliwości (f_{cut}). Jego rygorystyczne dostrojenie okazało się niezbędne do zachowania balansu między poprawnym odtworzeniem rdzenia sygnału a tłumieniem niepożądanych oscylacji tła.



Rysunek 3: Zastosowanie fourierowskiego algorytmu dekonwolucji dla sygnału wygenerowanego przy pomocy modelu analitycznego (*toy model*).

Po udanych testach na modelu analitycznym, zoptymalizowany algorytm zastosowano do rzeczywistych danych eksperymentalnych pochodzących z pomiarów wąskiego rezonansu w reakcji fotodezintegracji tlenu. Ewaluacja metody objęła zarówno

weryfikację jakościową, jak i rygorystyczną ocenę ilościową. Rezultaty wizualne zobrazowano za pomocą dwuwymiarowych map przestrzennych na płaszczyźnie detektora (Rysunek 4). Zestawienie danych surowych i zrekonstruowanych, zaprezentowane w skali liniowej oraz logarytmicznej, potwierdza skuteczne zawężenie profili śladów i redukcję rozmycia przestrzennego.




Rysunek 4: Dwuwymiarowe mapy przestrzenne sygnału z płaszczyzny odczytowej detektora TPC. Zestawienie przed (lewa kolumna) oraz po (prawa kolumna) zastosowaniu filtru dekonwolucji. Górny rząd prezentuje dane w skali liniowej, dolny w skali logarytmicznej w celu uwypuklenia struktury tła.

W celu ilościowej walidacji algorytmu przeprowadzono analizę kinematyczną zda-

rzeń (Rysunek 5). Analiza opierała się na sekwencyjnym filtrowaniu zdarzeń. W pierwszej kolejności zaaplikowano wstępne kryteria selekcji, narzucone już na etapie potoku rekonstrukcyjnego (wczytywane z predefiniowanych plików konfiguracyjnych). Następnie zastosowano dwuwymiarowe cięcia geometryczne na fizycznych zasięgach (długościach) śladów cząstek α oraz jąder odrzutu ^{12}C , co pozwoliło na skuteczną separację głównego kanału reakcji od tła. W końcowym etapie analizy dokonano transformacji zmiennych kinematycznych z układu laboratoryjnego do układu środka masy. Poprzez dopasowanie analitycznej funkcji Gaussa z uwzględnieniem tła, wyznaczono fizyczną szerokość połówkową (FWHM) pików rezonansowego.

Analiza wykazała, że zastosowanie procedury dekonwolucji zachowuje stabilność skali energetycznej oraz nie degraduje wrodzonej rozdzielczości detektora (FWHM dla obu zestawów danych utrzymało się w granicach błędu statystycznego na poziomie ~ 73 keV). Stanowi to bezpośredni dowód, iż zaimplementowany algorytm w sposób bezpieczny i bez wprowadzania niefizycznych zniekształceń modyfikuje geometrię śladów. Zaimplementowana z sukcesem procedura dekonwolucji stanowi punkt wyjścia do kolejnych etapów prac badawczych. Otwiera ona trzy główne ścieżki rozwoju: (1) dalszą optymalizację i ulepszanie samego algorytmu dekonwolucji, (2) ewaluację wpływu odzyskanego sygnału na skuteczność obecnych algorytmów rekonstrukcji zdarzeń, włączając w to ich ewentualną modyfikację w celu optymalnego wykorzystania zredukowanej szerokości śladów, oraz (3) wykorzystanie precyzyjniejszej lokalizacji łądunku do poprawy całkowitej rozdzielczości przestrzennej detektora, co bezpośrednio zredukuje niepewności w docelowych pomiarach kinematyki produktów reakcji.



Rysunek 5: Ilościowa walidacja algorytmu w przestrzeni energii. Widmo kinetyczne cząstek α w układzie środka masy po zastosowaniu odpowiednich cięć. Przerwanymi i ciągłymi liniami zaznaczono dopasowania funkcji Gaussa, z których wyznaczono fizyczną rozdzielczość (FWHM) na poziomie 72 keV. Zgodność wyników w granicach niepewności dowodzi braku niefizycznych zniekształceń sygnału po dekonwolucji.

2.3 Wpływ szumu na rekonstrukcję śladów w TPC

Wykonawca: Hubert Paszkiewicz

Opis realizacji:

2.3.1 Motywacja fizyczna

Ponieważ w rzeczywistym detektorze typu Time Projection Chamber (TPC) sygnał rejestrowany przez układ odczytowy nie jest idealnym odwzorowaniem jonizacji wywołanej przez przechodzącą cząstkę, do sygnału pochodzącego od zdeponowanej energii należy dołączyć fluktuacje (szum) związany np. z elektroniką, czy też oddziaływania stanowiące tło sygnału. Motywacją było dodanie szumu, pochodzącego głównie z elektroniki, wtedy amplituda zmierzona w pojedynczym kanale może być traktowana schematycznie jako

$$S_i^{\text{meas}} = S_i^{\text{signal}} + N_i, \quad (1)$$

gdzie S_i^{signal} jest sygnałem pochodzącym od jonizacji, natomiast N_i reprezentuje wkład szumu.

Uwzględnienie szumu jest istotne z punktu widzenia rekonstrukcji, ponieważ operuje ona również na zdigitalizowanym sygnale detektora. Te fluktuacje mogą wpływać między innymi na liczbę zidentyfikowanych hitów, długość rekonstruowanych segmentów, czy też stabilność dopasowania toru.

Celem przeprowadzonego testu było zatem sprawdzenie, czy wprowadzenie kontrolowanego poziomu szumu do sygnału TPC powoduje istotną zmianę podstawowych parametrów rekonstruowanych śladów.

2.3.2 Model szumu

W symulacji wykorzystano moduł `NoiseGenerator`, który dodano do `TPCReco`. Został on umieszczony w sekwencji przetwarzania pomiędzy digitizacją sygnału TPC a rekonstrukcją śladów. Można to schematycznie przedstawić jako:

$$\begin{aligned} \text{Generator} &\rightarrow \text{GeantSim} \rightarrow \text{TriggerSimulator} \rightarrow \text{TrackTruncator} \\ &\rightarrow \text{TPCDigitizerSRC} \rightarrow \text{NoiseGenerator} \rightarrow \text{Track3DBuilder}. \end{aligned} \quad (2)$$

Umieszczenie modułu jest istotne: szum jest dodawany do sygnału na poziomie danych detektorowych, a następnie poddawany tym samym procedurom rekonstrukcyjnym co sygnał bezszumowy. Dzięki temu porównanie pozwala badać bezpośredni wpływ dodatkowych fluktuacji na rekonstrukcję.

W konfiguracji wykorzystanej w analizie przyjęto

$$\sigma_{\text{incoherent}} = 3.0, \quad (3)$$

oraz

$$\sigma_{\text{common,mode}} = 1.5. \quad (4)$$

Pierwszy parametr opisuje niezależną składową fluktuacji poszczególnych kanałów, natomiast drugi odpowiada za składową wspólną (skorelowaną) dla kanałów. Taki podział wynika z założenia, że do sygnału należy dodać pewną składową stałą dla każdego odczytu i uwzględnić niedoskonałości (lokalne) elektroniki. Wtedy odczyt zależy również od kanału. Takie wartości przyjęto w celu sprawdzenia, czy dodanie jakiegokolwiek szumu wpłynie znacząco na wyniki. Stanowią one tylko wstęp i należy je raczej traktować jak test, niż rzeczywiste wartości.

Ważne, że w przyjętym modelu wartości $\sigma_{\text{incoherent}}$ i $\sigma_{\text{common,mode}}$ należy traktować jako parametry kontrolowanego modelu szumu, a nie jako wartości wyznaczone z kalibracji rzeczywistego detektora. Ich zadaniem jest wprowadzenie realistycznego jakościowo zaburzenia sygnału i sprawdzenie odporności rekonstrukcji na jego obecność.

W szczególności model ten pozwala odpowiedzieć na pytanie, czy rekonstrukcja zachowuje swoje podstawowe właściwości po odejściu od idealnego, pozbawionego szumu sygnału symulowanego.

2.3.3 Przygotowanie próbek MC

W celu izolacji wpływu szumu przygotowano dwie próbki Monte Carlo, różniące się wyłącznie obecnością modułu `NoiseGenerator`. Dla każdej konfiguracji wygenerowano 10,000 niepustych zdarzeń.

Próbka referencyjna, określana dalej jako *no noise*, nie zawierała modułu `NoiseGenerator`. W próbce *noise* moduł ten był aktywny z parametrami jak powyżej. Pozwala to porównać uzyskane wyniki w przypadku dołożenia szumu względem analogicznych wyników bez jego uwzględnienia. Pozostałe elementy konfiguracji pozostały niezmienione, żeby dodatkowo nie wpłynąć na wyniki. .

Dla próbki bez szumu generator musiał podjąć 12020 prób w celu uzyskania 10000 niepustych zdarzeń, co odpowiada efektywności

$$\epsilon_{\text{gen}} = \frac{10000}{12020} \approx 83.2 \quad (5)$$

Dla próbki z szumem uzyskano 10000 niepustych zdarzeń po 12111 próbach, czyli

$$\epsilon_{\text{gen}} = \frac{10000}{12111} \approx 82.6 \quad (6)$$

Różnica ta jest niewielka, co wskazuje, że obie próbki mają porównywalną statystykę wygenerowanych zdarzeń.

2.3.4 Wielkości analizowane w rekonstrukcji

Wpływ szumu badano na podstawie parametrów rekonstruowanych segmentów zapisanych w obiekcie `TPCRecoData`. Analizowano przede wszystkim długość segmentu oraz liczbę przypisanych do niego hitów 2D.

W ogólności oczekuje się dodatniej korelacji pomiędzy tymi wielkościami: dłuższy odcinek toru przechodzący przez aktywną objętość TPC powinien generować sygnał

w większej liczbie kolejnych elementów odczytu. Zależność tę można schematycznie zapisać jako $N_{\text{hits}} \sim \alpha L_{\text{seg}}$, przy czym współczynnik α zależy od geometrii detektora, sposobu digitalizacji oraz kryteriów rekonstrukcji.

Analizowano zarówno rozkłady jednowymiarowe N_{hits} i L_{seg} , jak również rozkład dwuwymiarowy $N_{\text{hits}}(L_{\text{seg}})$, pozwalający ocenić nie tylko średnią wartość liczby hitów, ale również rozrzut zależności.

2.3.5 Wyniki

Dla liczby hitów na rekonstruowany segment otrzymano następujące wartości:


	No noise	Noise
Entries	~ 60000	~ 60000
Mean N_{hits}	787.3	791.6
Std. Dev.	836.8	837.5

Tabela 1: Porównanie rozkładu liczby hitów 2D przypisanych do rekonstruowanych segmentów dla próbek bez szumu oraz z dodanym szumem.

Średnia liczba hitów zmieniła się z 787.3 do 791.6, co odpowiada względnej zmianie

$$\frac{791.6 - 787.3}{787.3} \times 100 \approx 0.55 \quad (7)$$

Odchylenie standardowe zmieniło się z 836.8 do 837.5, czyli o około 0.08%. Oznacza to, że na poziomie globalnych statystyk liczby hitów wpływ zastosowanego poziomu szumu jest niewielki.




Rysunek 6: Rozkład liczby hitów przypisanych do rekonstruowanych segmentów dla próbki bez szumu i z szumem.

Lepszego porównania dostarcza rozkład dwuwymiarowy liczby hitów w funkcji długości segmentu. W obu próbkach zachowana jest podobna ogólna zależność: wraz ze wzrostem długości rekonstruowanego segmentu rośnie liczba przypisanych hitów.

Oznacza to, że podstawowa zależność pomiędzy długością rekonstruowanego toru a ilością informacji detektorowej pozostaje zachowana po wprowadzeniu szumu. Całość widoczna jest na wykresach znajdujących się na Rysunku 2.

Jednocześnie w próbce z szumem obserwowany jest nieco większy rozrzut punktów wokół głównego obszaru zagęszczenia oraz niewielkie przesunięcie najbardziej zagęszczonego obszaru rozkładu. Efekt ten jest jakościowo zgodny z oczekiwaniem, że dodatkowe fluktuacje sygnału mogą powodować niewielkie zmiany w przypisywaniu hitów do rekonstruowanych segmentów.



Rysunek 7: Liczba hitów N_{hits} w funkcji długości rekonstruowanego segmentu L_{seg} . Kolor odpowiada liczbie segmentów w danym obszarze histogramu.

2.3.6 Koszt czasowy

Oprócz wpływu na rekonstrukcję zbadano również wpływ szumu na czas obliczeń. Dla próbki bez szumu całkowity czas przetwarzania wyniósł około 3919, s, czyli około 1,1 godziny, podczas gdy dla próbki z szumem około 8654, s, czyli około 2,4 godziny. Całkowity czas obliczeń wzrósł zatem około 2.2 razy po włączeniu modułu szumu.

2.3.7 Podsumowanie

Przeprowadzony test pokazuje, że dla zastosowanych parametrów modelu szumu wpływ na podstawowe globalne charakterystyki rekonstruowanych segmentów jest niewielki. Średnia liczba hitów zmieniła się o około 0.55%, natomiast jej odchylenie standardowe praktycznie się nie zmieniło. Również podstawowa zależność pomiędzy liczbą hitów i długością segmentu została zachowana. Jednocześnie analiza dwuwymiarowa wskazuje na niewielki wzrost rozrzutu dla próbki z szumem. Warto zauważyć, że użyte w symulacji parametry zostały z góry zadane - przeprowadzenie analogicznej analizy dla innych parametrów może prowadzić do innych wyników.

2.4 Optymalizacja rekonstrukcji z wykorzystaniem sieci neuronowych

Wykonawca: Paweł Gawron

2.4.1 Cel i założenia

Głównym celem projektu była optymalizacja rekonstrukcji trójwymiarowych śladów cząstek w detektorze WARSAW TPC przy użyciu konwolucyjnych sieci neuronowych (CNN). Zadaniem modelu jest precyzyjne przewidzenie współrzędnych przestrzennych (x, y, z) , określających wierzchołek reakcji oraz końce śladów cząstki alfa i jądra węgla. Punktem wyjścia była próbka 100 000 symulowanych zdarzeń Monte Carlo.

Praktycznym celem jest poprawa efektywności rekonstrukcji śladu cząstki α (szczególnie dla krótkich śladów) oraz ograniczenie zależności efektywności od kierunku emisji cząstki.

2.4.2 Analiza modeli i interpretacja wykresów

Przyjęta pierwotnie strategia obejmuje porównanie modeli o różnych rozmiarach filtrów, ustalenie zakresów ich skuteczności i sprawdzenie, czy ważenie modeli poprawia rekonstrukcję. Przetestowano modele o klasycznej architekturze z różnymi wymiarami filtrów konwolucyjnych (16×32 , 8×16 , 4×8 , 5×5 , 3×3) oraz architektury typu Inception, w których obraz przepuszczany jest równolegle przez filtry o różnych rozmiarach (w ten sposób sieć uczy się wykorzystywać połączone cechy uzyskane przy różnych rozmiarach filtrów).


Nazwy modeli określają rozmiar początkowego filtra konwolucyjnego (pierwszej warstwy). Nie oznaczają, że wszystkie warstwy danej sieci wykorzystują identyczny filtr. Ponadto, między częścią wariantów zmieniano również pooling oraz sposób łączenia kanałów. Różnic wyników nie można zatem przypisywać wyłącznie jako bezpośredniej konsekwencji zmiany rozmiaru pierwszego okna.

Każdy z prezentowanych poniżej zestawów zawiera cztery panele:


1. mapę efektywności w funkcji φ i $\cos \theta$
2. efektywność w funkcji kąta azymutalnego φ
3. efektywność w funkcji cosinusa kąta biegunowego $\cos \theta$
4. efektywność w funkcji długości śladu cząstki

Sama efektywność to odsetek zdarzeń, w których sieć neuronowa zrekonstruowała długość śladu α z błędem mniejszym niż 5%. Wartość 1 oznacza, że wszystkie zdarzenia w danym przedziale spełniają przyjęte kryterium sukcesu. Poniższe rysunki


przedstawiają wyniki otrzymane przed weryfikacją samego kryterium sukcesu. Podczas późniejszej kontroli stwierdzono, że stosowany warunek był jednostronny i nie odpowiadał tolerancji $\pm 5\%$, co zostanie dokładniej omówione w dalszej części pracy.




Rysunek 8: Okno 16×32 . Widoczny jest wzrost efektywności wraz z długością śladu (od ok. 0,55 dla 30 mm do blisko 1,0 przy 200 mm). Widoczna jest silna zależność od $\cos \theta$, gdzie efektywność drastycznie spada z ok. 0,9 do ok. 0,35 (dla $\cos \theta = 1$). Zależność od φ jest stosunkowo płaska i oscyluje wokół 0,6–0,8.




Rysunek 9: Okno 8×16 . Zmniejszenie jądra sprawiło, że zależność od $\cos\theta$ jest znacznie słabsza i bardziej symetryczna (oscyluje w przedziale 0,7–0,85) niż dla wariantu 16×32 . Zależność od azymutu φ wykazuje lekki spadek z 0,85 do 0,65. Dla najkrótszych śladów efektywność znajduje się na poziomie 0,55–0,65, a dla śladów długich przekracza stabilnie 0,9.




Rysunek 10: Okno 4×8 . Efektywność rośnie wraz z długością (od 0,6 do 0,9). Zmniejszenie filtra uwidocznilo jednak wyraźny spadek w funkcji kąta azymutalnego φ , gdzie dla wartości ok. 1,5 rad efektywność spada do 0,6. Relacja względem $\cos \theta$ charakteryzuje się powolnym wzrostem z 0,6 do 0,8.




Rysunek 11: Wariant kwadratowy 5×5 . Widzimy wysoki początek krzywej dla długości około 30–50 mm (dobijający do 0,9) i wyraźny spadek w okolicy 80 mm (do ok. 0,65), a następnie wyraźne odbicie do poziomu 0,9. Wykres dla φ posiada głębokie załamanie w środkowej części (spadek z 0,9 do 0,6), natomiast efektywność od $\cos \theta$ utrzymuje się w regionie 0,6 - 0,85. Wynik ten motywował próby łączenia modeli (architektura Inception).




Rysunek 12: Wariant kwadratowy 3×3 . Krzywa długości śladu rozpoczyna się w okolicy 0,65, i rośnie, oscylując wokół 0,9–1,0 dla dłuższych śladów. Zależność od azymutu φ jest tu dość stabilna (ok. 0,8), natomiast dla $\cos \theta$ widać wyraźny, liniowy wzrost efektywności (od 0,6 do 0,9).



Rysunek 13: Architektura Inception v1. Model z filtrami o różnych rozmiarach (5×5 , 8×16 i 16×32). Efektywność gładko zbliża się do jedności dla długich śladów. Model cierpi jednak na spadek efektywność w obu orientacjach: w funkcji φ skuteczność spada z 0,9 do 0,7, a zależność od $\cos \theta$ powieliła asymetrię z dużego jądra 16×32 (spadek z 0,9 do 0,5).



Rysunek 14: Architektura Inception v2 (rozmiary jądra 5×5 , 8×16). Wariant ten poprawia stabilność: zależność od $\cos \theta$ ma być znacznie stabilniejsza niż w wersji v1 (tworzy płytkie "siodło" w przedziale 0,7–0,9). Zależność od φ nadal wykazuje powolny spadek. Ślady najkrótsze startują od 0,6, szybko rosną i stabilizują się na poziomie 0,95–1,0.



Rysunek 15: Architektura Inception v3 (rozmiar jądra 5×5 , 8×16 , lecz ze zmianą `flatten` na `GlobalAveragePooling2D`). Widoczne są silne, nieregularne skoki zależności w funkcji obu kątów (φ oraz $\cos\theta$) Mimo to obserwujemy stały wzrost efektywności dla długości toru.

2.4.3 Weryfikacja kryterium efektywności rekonstrukcji

Po porównaniu wyników modeli przeprowadzono kontrolę kodu obliczającego efektywność rekonstrukcji. Sprawdzono funkcje z modułu `PythonAnalysis/python/plotting_functions.py` oraz komórki notebooka `WAWTPC_ML` odpowiedzialne za wybór poprawnie zrekonstruowanych zdarzeń i rysowanie wykresów.

Definicja błędu długości W funkcji `plotLengthPull(df, partName)` długości śladu symulowanego i zrekonstruowanego obliczane są jako odległości między wierzchołkiem zdarzenia a końcem śladu:

$$L_{\text{sim}} = \|\mathbf{r}_{\alpha, \text{sim}} - \mathbf{r}_{\text{Vtx}, \text{sim}}\|, \quad L_{\text{reco}} = \|\mathbf{r}_{\alpha, \text{reco}} - \mathbf{r}_{\text{Vtx}, \text{reco}}\| \quad (8)$$

gdzie $\mathbf{r}_{\text{Vtx}}$ to współrzędne (x, y, z) wierzchołka (początek reakcji i kreacji cząstki α), a $\mathbf{r}_{\alpha}$ to współrzędne końca śladu cząstki α . Funkcja ta zapisuje w kolumnie `pull` różnicę:

$$\Delta L = L_{\text{reco}} - L_{\text{sim}} \quad (9)$$

wielkość ta jest resztą długości wyrażoną w milimetrach. Względny błąd długości wynosi zatem:

$$\delta_L = \frac{L_{\text{reco}} - L_{\text{sim}}}{L_{\text{sim}}}. \quad (10)$$

Jednostronny warunek w notebooku W notebooku WAWTPC.ML kryterium sukcesu (czyli warunek na δ_L) występuje w zmiennych `goodReco` oraz `numeratorSelection`. Dotychczas stosowano warunek:

```
df_XYZ["pullAlpha"] / df_XYZ["dAlpha_sim"] < 0.05
```

czyli

$$\delta_L < 0,05 \quad (11)$$

warunek ten tworzy wyłącznie ograniczenie górne, ale nie tworzy dolnego. Przykładowo dla $L_{\text{sim}} = 40$ mm oraz $L_{\text{reco}} = 20$ mm otrzymujemy $\delta_L = -0,5$. Takie zdarzenie spełnia dotychczasowy warunek mimo błędu wynoszącego 50%.

Jeżeli celem jest ocena rekonstrukcji z tolerancją błędu $\pm 5\%$, należy zastosować warunek:

$$|\delta_L| < 0,05, \quad (12)$$

równoważny

$$0,95L_{\text{sim}} < L_{\text{reco}} < 1,05L_{\text{sim}} \quad (13)$$

odpowiada mu zapis:

```
goodReco = (
    df_XYZ["pullAlpha"].abs()
    / df_XYZ["dAlpha_sim"] < 0.05
)
```

Dla zadanego przedziału analizowanej zmiennej (inaczej binu histogramu, przykładowo dla śladów o rzeczywistej długości od 40 do 45 mm), efektywność rekonstrukcji definiujemy jako:

$$\varepsilon = \frac{N_{\text{poprawne}}}{N_{\text{cakowite}}} \quad (14)$$

Liczba N_{cakowite} obejmuje zdarzenia należące do danego przedziału i spełniające dodatkowo selekcję `goodFiducial` (jest to maska logiczna). Natomiast N_{poprawne} obejmuje te same zdarzenia, które dodatkowo spełniają warunek $|\delta_L| < 0,05$.

Kontrola wyników modeli po zmianie kryterium sukcesu Poniżej zestawiono ze sobą wskaźniki efektywności wyznaczone z użyciem poprawionego kryterium sukcesu. Dla ułatwienia zapisu wprowadzono następujące oznaczenia:

- ε_j – efektywność wyznaczona z wykorzystaniem dotychczasowego, jednostronnego warunku błędu względnego ($\delta_L < 0,05$),

- $\varepsilon_{\pm 5\%}$ – docelowa efektywność wyznaczona z użyciem, obustronnego warunku błędu ($|\delta_L| < 0,05$),
- ε_j^{30-50} oraz $\varepsilon_{\pm 5\%}^{30-50}$ – odpowiednie wskaźniki efektywności obliczone wyłącznie dla podzbioru krótkich śladów, których rzeczywista długość zawiera się w przedziale $30 \text{ mm} \leq L_{\text{sim}} < 50 \text{ mm}$.

Tabela 2: Zestawienie efektywności rekonstrukcji długości śladu dla badanych modeli z podziałem na warunek jednostronny (j) oraz dwustronny ($\pm 5\%$).

Model	ε_j [%]	$\varepsilon_{\pm 5\%}$ [%]	ε_j^{30-50} [%]	$\varepsilon_{\pm 5\%}^{30-50}$ [%]
Filtr 16×32	70,62	62,82	54,01	39,93
Filtr 8×16	75,98	65,83	58,95	42,72
Filtr 4×8	73,54	51,85	60,68	31,79
Filtr 5×5	80,06	12,08	86,19	8,04
Filtr 3×3	78,88	50,97	67,15	32,92
Inception v1	78,47	62,00	66,56	40,39
Inception v2	80,37	57,04	63,47	37,67
Inception v3	67,31	22,03	60,48	13,62

Najlepszy wynik wśród badanych wariantów

Wśród sieci o stałym rozmiarze jądra model wykorzystujący filtr 8×16 wykazuje najwyższą globalną skuteczność ($\varepsilon_{\pm 5\%} = 65,83\%$), zauważalnie przewyższając zarówno bazowe, największe okno 16×32 (62,82%), jak i warianty o mniejszych jądrach. Co istotne, okno 8×16 radzi sobie również najlepiej w przedziale krótkich śladów osiągając $\varepsilon_{\pm 5\%}^{30-50} = 42,72\%$.

Porażka małych filtrów

Tabela obrazuje iluzję modeli o bardzo małych oknach, z naciskiem na architekturę 5×5 . Stosując kryterium jednostronne, dla krótkich śladów model ten osiąga pozornie fenomenalną skuteczność ($\varepsilon_j^{30-50} = 86,19\%$). Jednakże implementacja poprawnego warunku weryfikuje ten wynik, obniżając go do zaledwie 8,04%.

Architektury Inception

Wśród badanych wariantów Inception najwyższą efektywność uzyskał Inception v1: 62,00% globalnie oraz 40,39% dla krótkich śladów. Globalnie wynik ten jest niższy niż dla modeli 8×16 i 16×32 . Warianty Inception v2 i v3 uzyskały niższe efektywności, przy czym dla v3 efektywność całkowita wyniosła 22,03%.

2.4.4 Wyniki po korekcie kryterium efektywności

Ponowne obliczenie efektywności nie wymagało ponownego treningu sieci. Wykorzystano zapisane wcześniej pliki CSV zawierające współrzędne symulacyjne i odpowiadające im przewidywania poszczególnych modeli. Przeprowadzono więc ponowną ocenę tych samych rekonstrukcji, stosując poprawione kryterium sukcesu. Nie są to

zatem wyniki nowych modeli, lecz poprawiona analiza wcześniejszych predykcji.

Poniższe rysunki przedstawiają odpowiedniki wcześniejszych zależności od kierunku i długości śladu. Efektywność obliczono zgodnie z równaniem (14), zachowując dotychczasową selekcję `goodFiducial`.

Analizowane wielkości i sposób obliczeń Dla każdego zdarzenia zdefiniowano wektor od wspólnego wierzchołka do końca symulowanego śladu:

$$\mathbf{d}_{\alpha,\text{sim}} = \mathbf{r}_{\alpha,\text{sim}} - \mathbf{r}_{\text{Vtx},\text{sim}} = (\Delta x, \Delta y, \Delta z) \quad (15)$$


Składowe Δx , Δy i Δz oznaczają różnice współrzędnych końca śladu i wierzchołka. Długość ramienia alfa wynosi:

$$L_{\alpha,\text{sim}} = \|\mathbf{d}_{\alpha,\text{sim}}\| = \sqrt{\Delta x^2 + \Delta y^2 + \Delta z^2} \quad (16)$$


jest to odległość między tymi punktami, wyrażona w milimetrach i zapisana w kolumnie `dAlpha_sim`. Analogicznie wyznaczono $L_{\alpha,\text{reco}}$ ze współrzędnych przewidzianych przez sieć.

Zmienne kątowe obliczono dokładnie według wzorów stosowanych w komórkach noteboka generujących wcześniejsze wykresy:


$$\cos \theta_{\text{sim}} = \frac{\Delta z}{L_{\alpha,\text{sim}}}, \quad \varphi_{\text{sim}} = \arccos \left(\frac{\Delta x}{\sqrt{\Delta x^2 + \Delta y^2}} \right). \quad (17)$$




Rysunek 16: Wariant 16×32 : efektywność całkowita 62,82%. Zależność od azymutu mieści się w przybliżeniu w zakresie 0,52–0,70. Widoczna jest silna asymetria względem $\cos \theta$: efektywność maleje od około 0,9 przy wartościach bliskich -1 do około 0,33 przy wartościach bliskich 1. Dla długości od około 35 do 100 mm rośnie z około 0,36 do ponad 0,8.




Rysunek 17: Warian 8 $\times$ 16: najwyższa efektywność całkowita w przedstawionym zestawie, 65,83%. W pobliżu $\cos\theta = 0$ występuje obniżenie efektywności do około 0,53. Skuteczność rośnie z około 0,38 dla najkrótszego pokazanego przedziału do około 0,85 przy 100 mm, osiągając dla wielu dłuższych śladów poziom około 0,9.




Rysunek 18: Warian 4 $\times$ 8: efektywność całkowita 51,85%. Przebieg azymutalny wykazuje lokalne maksima w okolicy 2 rad. Efektywność względem $\cos\theta$ ma minimum około 0,35 blisko zera i rośnie do około 0,7 dla dodatnich wartości bliskich jedności. W funkcji długości obserwuje się wzrost do około 0,7 przy 100–120 mm, bez wyraźnej dalszej systematycznej poprawy.




Rysunek 19: Warian 5 $\times$ 5: efektywność całkowita 12,08%. Efektywność pozostaje niska w całym zakresie $\cos\theta$, zwykle na poziomie około 0,10–0,15. Zależność od azymutu ma maksima w pobliżu 1,5 rad. W funkcji długości widoczne jest szerokie maksimum około 90–120 mm, około 0,2.




Rysunek 20: Warian 3 $\times$ 3: efektywność całkowita 50,97%. W obu zależnościach kątowych widoczne jest obniżenie w pobliżu zera; dla $\cos\theta$ minimum wynosi około 0,32. Efektywność rośnie z około 0,28 dla najkrótszych pokazanych śladów do około 0,7 przy 110–120 mm.




Rysunek 21: Inception v1, łączący jądra 5×5 , 8×16 i 16×32 : efektywność całkowita 62,00%. Zależność od azymutu ma kilka lokalnych maksimów, natomiast przebieg względem $\cos \theta$ jest asymetryczny, z obniżeniem w pobliżu zera i dla dodatnich wartości bliskich 1. W funkcji długości efektywność szybko rośnie, osiągając około 0,85–0,9 przy 100–120 mm. Jest to najlepszy wynik całkowity spośród pokazanych wariantów Inception, lecz niższy niż dla 8×16 i 16×32 .



Rysunek 22: Inception v2, łączący jądra 5×5 i 8×16 : efektywność całkowita 57,04%. Przebieg względem azymutu ma minimum około 0,35 w pobliżu zera i maksimum w okolicy 1,5 rad. Dla $\cos \theta$ widoczne jest szerokie obniżenie w środkowej części zakresu i wzrost do około 0,7 przy jego krańcach. Efektywność od długości toru rośnie do około 0,74 przy 100–120 mm, po czym maleje w części dalszego zakresu oraz zaczyna zachowywać się chaotycznie.



Rysunek 23: Inception v3 z gałęziami 5×5 i 8×16 oraz globalnym uśrednianiem map cech zamiast warstwy **Flatten**: efektywność całkowita 22,03%. Widoczna jest niska skuteczność w całym zakresie azymutu oraz głębokie minimum w pobliżu $\cos \theta = 0$, na poziomie około 0,06. Efektywność w funkcji długości osiąga maksimum około 0,4 w okolicy 125 mm, a następnie przeważnie maleje. W tym eksperymencie wariant v3 uzyskał najgorszy wynik spośród całej architektury Inception.



Rysunek 24: Wspólne porównanie modeli

Wyniki modeli Wciąż nie osiągnięto celu polegającego na uzyskaniu wysokiej i słabo zależnej od kierunku efektywności, szczególnie dla krótkich śladów. Nie wykazano również przewagi architektury Inception.

Ze względu na niesatysfakcjonującą wydajność samodzielnych modeli, w tym całkowitą porażkę wariantu 5×5 , należy odrzucić pomysł, iż sama kalibracja rozmiaru filtra w architekturze z wbudowanym przełącznikiem modelu wystarczy do rekonstrukcji krótkich torów. Konieczne staje się poszukiwanie metod alternatywnych. Uzasadnia to jednak sprawdzenie, czy gotowe modele mogą się w ogóle wzajemnie uzupełniać.

2.4.5 Eksperyment z przełącznikiem modeli

Celem eksperymentu jest sprawdzenie, czy analizowane modele uzupełniają się. Ze względu na niską efektywność w dotychczasowym porównaniu wyłączono z tego eks-

perymentu wariant 5×5 oraz Inception v3.

Zasada działania przełącznika Eksperyment został przeprowadzony na tych samych plikach CSV z predykcjami, które posłużyły wcześniej do analizy błędu rekonstrukcji. Każdy plik odpowiada jednemu przetrenowanemu modelowi (np. 8×16 czy 16×32) i zawiera zbiór 32 000 wierszy, gdzie każdy wiersz odpowiada jednemu wygenerowanemu zdarzeniu. Zdarzenia we wszystkich plikach są ułożone w identycznej kolejności, co umożliwia ich krzyżowe porównywanie.

Każdy wiersz w pliku można podzielić na dwie części:

- **Prawda symulacyjna (sufiks `_sim`):** wartości pochodzące wprost z symulatora wyznaczające bezbłędne położenie cząstek w detektorze.
- **Odpowiedź sieci (sufiks `_reco`):** wskazany przez sieć neuronową kompletny wektor 9 współrzędnych przestrzennych (wartości X, Y, Z dla wierzchołka, końca śladu cząstki α oraz końca śladu węgla).

Zbiór poprawnych geometrycznie zdarzeń (spełniających warunek `goodFiducial`) został losowo podzielony na dwie równe, rozłączne połowy:

- **Część optymalizacyjna (tune):** posłużyła wyłącznie do zbadania wszystkich możliwych kombinacji modeli oraz wyłonienia najlepszej reguły przełączania.
- **Część testowa (check):** posłużyła do ostatecznej weryfikacji skuteczności wybranego przełącznika. Zwycięska reguła została zaaplikowana na tych danych tylko raz.

Zasada działania przełącznika opiera się na wyborze jednego z dwóch modeli na podstawie przewidywanej długości śladu cząstki α .

Dla każdej rozpatrywanej pary modeli algorytm w części `tune` przeszukał progi decyzyjne długości w zakresie od 0 do 300 mm (z krokiem 5 mm). Załóżmy teraz, że mamy wybrany model bazowy A oraz model alternatywny B , a badany próg to 35 mm. Logika pojedynczego testu przebiegała następująco:

1. Sprawdzamy predykcję długości śladu wskazaną przez główny model w parze (liczoną poprzez zwykłą odległość euklidesową pomiędzy współrzędnymi wierzchołka a końca śladu)
2. Jeśli długość ta jest mniejsza niż testowany próg, system ostatecznie wybiera cały wektor współrzędnych z Modelu A.
3. Jeśli długość jest równa lub większa, system wybiera wektor współrzędnych z Modelu B

Należy podkreślić, że przełącznik zawsze pobiera z wybranego modelu pełny wiersz 9 liczb (nie występuje żadne mieszanie współrzędnych).

Górne ograniczenie teoretyczne Największy zysk na części `tune` przyniosło połączenie modelu 16×32 z modelem 8×16 . Algorytm wyznaczył optymalny próg przełączania na poziomie 35 mm. W praktyce jako pierwsza sprawdzana była predykcja modelu 16×32 ; jeżeli przewidywał on ślad krótszy niż 35 mm, ostateczną odpowiedź pobierano z tego właśnie modelu. Dla śladów o przewidywanej długości równej lub większej niż 35 mm, system przełączał się na ostateczną predykcję z modelu odniesienia 8×16 .

Do wyników zbadano również hipotetyczną sytuację, w której algorytm bezbłędnie i zawsze wybiera z puli sześciu modeli ten, który poprawnie zrekonstruował zdarzenie (o ile co najmniej jeden z nich tego dokonał). Wyniki zestawiono w poniższej tabeli:

Tabela 3: Porównanie efektywności modelu odniesienia, wybranego przełącznika oraz maksimum teoretycznego

Wariant	$\epsilon_{\pm 5\%}$ [%]	$\epsilon_{\pm 5\%}^{30-50}$ [%]
Pojedynczy model (8×16)	66,03	42,43
Przełącznik ($16 \times 32 \leftrightarrow 8 \times 16$)	66,30	43,28
<i>Maksimum teoretyczne</i>	<i>95,94</i>	<i>89,17</i>

Wprowadzenie przełącznika przyniosło minimalną poprawę wyników. Globalna efektywność systemu wzrosła o 0,27 punktu procentowego. Zysk był bardziej bardziej widoczny w przedziale najkrótszych śladów (30 – 50 mm), gdzie skuteczność wzrosła o blisko punkt procentowy (z 42,43% do 43,28%).

Hipotetyczny wybór poprawnej rekonstrukcji spośród sześciu modeli pozwala uzyskać efektywność 95,94% globalnie oraz 89,17% dla śladów o długości 30–50 mm. Oznacza to, że dla takiego odsetka zdarzeń przynajmniej jeden model spełnia kryterium dokładności długości toru. Wynik wskazuje na uzupełnianie się predykcji modeli. Wybór ten wykorzystuje prawdę symulacyjną, niedostępną podczas analizy rzeczywistych danych. Nie jest więc wynikiem praktycznego przełącznika ani gwarancją osiągnięcia podobnej efektywności przez bardziej złożony algorytm. Różnica między skutecznością prostego przełącznika a hipotetycznym wyborem uzasadnia sprawdzenie bardziej zaawansowanych reguł wyboru modelu. Nie pozwala jednak wykluczyć ograniczeń samych sieci CNN.

3 Podsumowanie i wnioski końcowe

Poniżej przedstawiono najważniejsze wnioski płynące z przeprowadzonych prac nad rozwojem i optymalizacją oprogramowania dla eksperymentu Warsaw TPC:

- **Ewaluacja zewnętrznych metod rekonstrukcji:** Testy algorytmu MIM UW ujawniły błędy numeryczne oraz drastyczny spadek skuteczności dla śladów

wstecznych (*Backward*). Wobec tych ograniczeń rozwiązanie odrzucono, rekomendując do dalszej analizy fizycznej stabilną, standardową rekonstrukcję z pakietu TPCReco.

- **Zaimplementowana z sukcesem procedura dekonwolucji sygnału:** Analiza wykazała, że zastosowanie dekonwolucji zachowuje stabilność skali energetycznej i nie degradowe wrodzonej rozdzielczości detektora (FWHM utrzymało się na poziomie ~ 73 keV). Stanowi to bezpośredni dowód, iż algorytm w sposób bezpieczny i bez wprowadzania niefizycznych zniekształceń modyfikuje geometrię śladów.
- **Analiza wpływu szumu na rekonstrukcję śladów:** Zbadano odporność algorytmów na symulowane fluktuacje sygnału z elektroniki, wykazując, że podstawowe parametry zrekonstruowanych segmentów pozostają stabilne (zmiana średniej liczby hitów zaledwie o $\sim 0.55\%$). Wprowadzenie modelu szumu nie zaburzyło kluczowej korelacji między długością toru a liczbą przypisanych hitów, jednak skutkowało ponad dwukrotnym wydłużeniem czasu trwania symulacji.
- **Rekonstrukcja z wykorzystaniem sieci neuronowych:** Porównano wiele wariantów sieci konwolucyjnych, w tym architektury Inception. W kodzie wyjściowym wykryto niezgodność kryterium efektywności z zakładaną tolerancją błędu długości $\pm 5\%$ i przeprowadzono ponowną ocenę modeli. Zbadano również potencjał ich wzajemnego uzupełniania się poprzez hipotetyczny wybór poprawnej predykcji oraz zastosowanie prostego przełącznika. Przetestowane zmiany architektury i reguły wyboru modelu nie zapewniły wysokiej efektywności dla krótkich śladów cząstki alfa. Wyniki uzasadniają dalsze badania bardziej zaawansowanych metod rekonstrukcji i wyboru modelu.

Bibliografia

- [1] grupa MIMUW. *Algorytm rekonstrukcji zdarzeń*. <https://github.com/bartix998a/MU-p1>. Dostęp: 27 września 2026. 2026.
- [2] J. Giovino et al. "GET electronics samples data analysis". In: *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment* 840 (2016), p. 15. DOI: [10.1016/j.nima.2016.10.005](https://doi.org/10.1016/j.nima.2016.10.005).