



Zastosowanie wybranych algorytmów uczenia maszynowego do wykrywania zmian patologicznych w obrazach rezonansu magnetycznego mózgu

Julia Nocuń

Opiekun pracy: dr hab. inż. Agnieszka Wosiak

Politechnika Łódzka

- Guzy mózgu zajmują 12. miejsce wśród przyczyn zgonów z powodu nowotworów na świecie.
- Wczesne wykrycie zmian za pomocą rezonansu magnetycznego znacząco zwiększa szanse pacjentów na wyleczenie.
- Złożoność obrazów wykonanych rezonansem magnetycznym stanowi ogromne obciążenie czasowe dla lekarzy radiologów.
- Istnieje pilna potrzeba stworzenia systemów automatyzujących diagnostykę, aby zredukować czas oczekiwania na diagnozę i zmniejszyć ryzyko błędu ludzkiego.





Różnorodność danych

Niespójność skanów wynikająca z użycia różnych urządzeń i protokołów (T1, T2, FLAIR), co utrudnia uogólnianie modeli sztucznej inteligencji.



Złożona morfologia

Zmienna wielkość, nieregularne kształty i rozmyte granice guzów, utrudniające precyzyjne odseparowanie zdrowej tkanki od zmienionej chorobowo.



Niezbalansowane klasy

Dominacja pikseli tła w stosunku do niewielkich, ale krytycznych struktur nowotworowych (np. jądro martwicze).

Architektury splotowych sieci neuronowych

W celu rozwiązania problemu segmentacji zaimplementowano następujące modele sieci neuronowych:

- **3D U-Net:** Klasyczna struktura enkoder-dekoder.
- **3D ResUNet:** Wzbogacona o połączenia rezydualne, eliminująca problem zanikającego gradientu.
- **3D SegResNet:** Zoptymalizowana pamięciowo architektura dedykowana segmentacji medycznej.

Zbiór danych i optymalizacja

Wykorzystano multimodalny zbiór BraTS 2020 obejmujący 369 badań.

- Rozwiązano problem rzadkości danych metodą próbkowania fragmentów.
- Zastosowano hybrydową funkcję straty (Weighted Dice Loss + Focal Loss), by wymusić skupienie sieci na rzadkich, małych strukturach guza.



Warstwa prezentacji

Aplikacja webowa
zaimplementowana w React.
Intuicyjna, niewymagająca
instalacji, pozwalająca na
bezpośredni, interaktywny
podgląd przekrojów z plików
NIFTI/DICOM.



Warstwa logiki




Serwer Flask z frameworkiem
TensorFlow. Zarządza rejestrem
modeli, przetwarza żądania
asynchroniczne i realizuje złożoną
inferencję splotowych sieci
neuronowych.



API (REST)

Modułowa komunikacja
pozwalająca na bezpieczne
przetwarzanie danych, wyliczanie
objętości guzów oraz
automatyczne generowanie
szczegółowych raportów PDF.

- Wszystkie analizowane architektury osiągnęły zbliżoną, wysoką dokładność globalną przekraczającą 91%.
- Wspólnym wyzwaniem dla wszystkich modeli pozostała detekcja jądra martwiczego, co wynika z jego niewielkiej objętości oraz trudnych do zdefiniowania granic morfologicznych.
- Mimo różnic w charakterystyce segmentacji, każda z sieci osiągnęła zadowalające wyniki, tym samym pokazując skuteczność wykorzystania modeli uczenia maszynowego jako narzędzi wspomagających proces automatycznej analizy obrazów rezonansu magnetycznego mózgu
- Modele oparte na blokach rezydualnych wykazały tendencję do generowania bardziej konserwatywnych i precyzyjnych wyników.







System precyzyjnie rozróżnia trzy kluczowe komponenty nowotworu: martwicze jądro guza (NCR), obrzęk okołoguzowy (ED) oraz obszar wzmacniający się kontrastowo (ET).



Obliczanie objętości guza w cm^3 , procentowego udziału w całkowitej objętości mózgu oraz wyznaczanie geometrycznych wymiarów ograniczających.



Możliwość natychmiastowego wygenerowania pliku PDF zawierającego wizualizacje (oryginał, maska, nałożony kontur) oraz pełne zestawienie statystyczne gotowe do analizy lekarskiej.

Zrealizowane cele

Opracowano w pełni funkcjonalny, gotowy do wdrożenia system wspierający proces diagnostyczny.

- Aplikacja automatyzuje i przyspiesza identyfikację zmian, zmniejszając obciążenie radiologów.
- System generuje czytelne raporty zawierające dane dotyczące wykrytej zmiany, umożliwiając prostą archiwizację wyników.
- Aplikacja posiada potencjał jako narzędzie edukacyjne dla studentów medycyny i wsparcie kampanii profilaktycznych.

Kierunek dalszych badań

Modułowa architektura aplikacji pozwala na płynną rozbudowę systemu w przyszłości.

- **Metadane kliniczne:** Integracja danych dotyczących m.in. wieku i płci pacjentów.
- **Incremental Learning:** Archiwizacja przypadków i ciągłe douczanie modeli na nowych danych.
- **Wizualizacja 3D:** Rozszerzenie wizualizacji wgranych obrazów o trójwymiarowe, interaktywne modele renderowane w przeglądarce.