

Częstochowa, dn. 15 grudnia 2023 r.

prof. dr hab. inż. Rafał Scherer
Katedra Inteligentnych Systemów Informatycznych
Wydział Inżynierii Mechanicznej i Informatyki
Politechnika Częstochowska
al. Armii Krajowej 36
42-200 Częstochowa

Recenzja

rozprawy doktorskiej mgr inż. Mateusza Korycinskiego, pt.: A Hybrid Method for Tractography in Neurosurgery Using Artificial Neural Networks and Path Search Algorithms.

Niniejszą recenzję opracowano na wniosek Rady Naukowej Instytutu Badań Systemowych Polskiej Akademii Nauk. Promotorem jest prof. dr hab. inż. Ewa Niewiadomska-Szynkiewicz, promotorem pomocniczym dr inż. Konrad Andrzej Ciecierski.

1. Charakterystyka tematu, celu i tezy badawczej rozprawy

Systemy komputerowego wspomaganie mogą pomagać neurochirurgom w wykonywaniu bardziej precyzyjnych i dokładnych zabiegów. Zastosowanie zaawansowanych narzędzi wspomagających nawigację w czasie operacji pozwala na minimalizację uszkodzeń tkanek zdrowych. Zaawansowane oprogramowanie umożliwia neurochirurgom planowanie operacji, analizę struktury mózgu pacjenta oraz identyfikację odpowiednich jego obszarów. Systemy komputerowe pozwalają na integrację różnych rodzajów obrazowania medycznego, takich jak rezonans magnetyczny i funkcjonalny, tomografia komputerowa czy obrazy trójwymiarowe z aktualną wiedzą dziedzinową, co daje lekarzom bardziej kompleksowy obraz struktury mózgu. Recenzowana rozprawa prezentuje nowe metody obrazowania medycznego, niedostępne do tej pory przy użyciu samych tylko urządzeń obrazujących. Celem pracy było stworzenie metody obrazującej opartej na sieciach neuronowych i metodach poszukiwania najkrótszej ścieżki do określenia położenia włókien nerwowych, czyli tworzenia traktogramów.

2. Zawartość rozprawy

Recenzowana praca mgr inż. Mateusza Korycińskiego składa się z dziesięciu rozdziałów, spisu rysunków, tabel, skrótów, symboli oraz bibliografii. Dokument liczy 113 stron.

Pierwszy rozdział jest krótkim wprowadzeniem do tematyki, którą jest obrazowanie mózgu wspomagające pracę neurochirurga działającego inwazyjnie na otwartym mózgu. Badania przeprowadzone i opisane w tej dysertacji skoncentrowały się na stworzeniu algorytmu tworzenia traktogramów włókien nerwowych z użyciem sztucznej sieci neuronowej połączonej z efektywnym algorytmem przeszukiwania ścieżki. Użycie sztucznej sieci neuronowej do przetwarzania danych pochodzących z technik MRI opartych na tensorze dyfuzji pozwala na korzystanie z danych poddanych tylko wstępnym krokom przetwarzania. Dodatkowo, przetwarzanie danych małymi porcjami umożliwia trenowanie modelu na niewielkich zbiorach danych, ponieważ pojedyncze skany dostarczają licznych przykładów treningowych. Odpowiednia modyfikacja algorytmu poszukiwania najszybszej ścieżki pozwoli na określenie miejsc występowania włókien w pobliżu miejsca operacji, łączących różne obszary mózgu i różnicowanie punktów krzyżowania włókien.

Rozdział 2 opisuje aspekty medyczne badań: anatomię układu nerwowego, w tym organizację substancji białej w mózgu, glejaki wraz z ich leczeniem. Przedstawiono także charakterystykę rezonansu magnetycznego oraz planowanie przedoperacyjne z użyciem traktografii jako kluczowe kroki przed operacją mózgu. Opisano bardzo dokładnie istotę rezonansu magnetycznego, obrazowanie T1, T2 i dyfuzyjne, rezonans funkcjonalny oraz traktografię przedoperacyjną.

Rozdział 3 omawia sztuczne sieci neuronowe, począwszy od perceptronu i sieci jednokierunkowych, przez sieci splotowe, rekurencyjne, mechanizm uwagi oraz uczenie za pomocą algorytmu wstecznej propagacji błędów i jego modyfikacji jak SGD, ADAM czy Sharpness-Aware Minimization (SAM). Sieci rekurencyjne są opisane, ale nieużywane w badaniach. Być może miały być wprowadzeniem do mechanizmu uwagi (która w formie stosowanej w sieciach Transformer, również nie jest używana). Powyższe zagadnienia związane z sieciami neuronowymi potraktowane są skrótowo, natomiast dużo miejsca poświęcono funkcjom aktywacji i wyjaśnieniu, dlaczego nowsze funkcje jak ReLU czy LeakyReLU lepiej radzą sobie z problemem zanikającego gradientu. Dalej omówiono wybrane zastosowania uczenia maszynowego w naukach medycznych, a mianowicie w genomice i proteomice, gdzie ze względu na ogromne ilości danych generowanych przez sekwencjonowanie następnej generacji, analiza tych danych jest bardzo trudna lub niemożliwa bez zaawansowanych algorytmów, w tym uczenia maszynowego i głębokiego uczenia, w systemach wsparcia decyzji klinicznych, które integrują doświadczenia lekarza, wyniki badań pacjenta i wiedzę naukową w zakresie medycyny, oraz w radiologii czyli w klasyfikacji i analizie obrazów uzyskiwanych za pomocą różnych technik, takich jak promieniowanie rentgenowskie, tomografia komputerowa, rezonans magnetyczny i ultrasonografia. W dwóch

ostatnich zastosowaniach uczenie maszynowe uzyskuje zazwyczaj lepsze wyniki niż pojedynczy lekarz.

Rozdział 4 dotyczy algorytmów poszukiwania najkrótszej ścieżki. Doktorant opisał algorytm Dijkstry, A* czyli wariant algorytmu Dijkstry, który przypisuje wagę każdemu nieodwiedzonemu węzłowi równą wadze tego węzła zwiększonej o przybliżoną odległość między sprawdzanym węzłem a docelowym węzłem. Tę odległość przybliża funkcja heurystyczna, co odróżnia to podejście od oryginalnej koncepcji. Rozdział ten zajmuje jedynie dwie strony, mógłby być częścią poprzednich rozdziałów.

Rozdział 5 omawia traktografię istoty białej, która umożliwia uwidocznienie kierunku i ciągłości przebiegu włókien nerwowych z techniki obrazowania tensora dyfuzji metodą rezonansu magnetycznego. Autor dokonał podziału metod dostępnych w literaturze na metody matematyczne, deterministyczne i probabilistyczne oraz na metody oparte o uczenie maszynowe oraz dokonał przeglądu literaturowego tych metod. I znowu, rozdział ten jest krótki, zajmuje sześć stron i, być może, mógłby być częścią większego rozdziału.

Rozdział 6 omawia autorską hybrydową metodę śledzenia włókien nerwowych, nazwaną HyTract (HT). Metoda ta łączy sztuczną sieć neuronową z algorytmem przeszukiwania ścieżki w celu obliczenia topologii włókien nerwowych. Ponieważ planowanie przedoperacyjne nie wymaga trajektogramu całego mózgu, dlatego analiza całego skanu jest zbędna, a sieć neuronowa przetwarza małe próbki pobrane z całego badania. Przyjmuje ona jako wejście trójwymiarową próbkę o z góry określonym rozmiarze, np. kilkadziesiąt wokseli. Sieć na wyjściu generuje tensor prawdopodobieństw o takim samym kształcie (rozmiarze) jak wejście, zawierający wartości skalarnie używane przez algorytm przeszukiwania ścieżki do obliczenia topologii traktu nerwowego. Pierwszą próbą była sieć neuronowa MLP, mająca jako dane wejściowe tablice gradientów oraz wektor dyfuzji i generująca na wyjściu trójwymiarową macierz prawdopodobieństw dla każdego woksela. Drugą architekturą była sieć neuronowa, która miała te same dane wejściowe i wyjściowe, ale pierwsza warstwa składała się z dwóch grup neuronów, oddzielnie dla wartości gradientów i dyfuzji. Trzecim modelem była ta sama sieć, ale wyjścia dwóch bloków pierwszej warstwy były mnożone przez wagi mające tworzyć mechanizm uwagi. Następną architekturą była sieć neuronowa, której pierwsza warstwa miała również dwie grupy neuronów, ale jedną z nich była warstwa spłotowa. Dzięki temu miała ona wielokrotnie mniej parametrów od poprzednich modeli.

Dalej doktorant zaproponował zmodyfikowany algorytm A*, który pracuje na grafie zbudowanym na macierzy wyjściowej ze wspomnianych wcześniej sieci neuronowych. Funkcją heurystyczną występującą w algorytmie A* jest odległość Euklidesowa pomiędzy bieżącym węzłem, a docelowym. Algorytm zapewnia obsługę w sytuacji, w których włókna rozdzielają się na dwie drogi. Ścieżki obliczane przez algorytm mają małą rozdzielczość, przez co mogą mieć nienaturalnie ostre zmiany kierunku. Algorytm wygładza takie miejsca za pomocą średniej kroczącej, tworząc bardziej naturalny przebieg ścieżki.

Rozdział 7 omawia tworzenie danych dyfuzji służących do uczenia sieci neuronowych. Do stworzenia zbiorów uczących wykorzystano dane MRI z obrazowania tensorowego dyfuzji oraz obrazowania anatomicznego. Po odpowiednim przygotowaniu zostały one użyte do tworzenia traktogramów za pomocą trzech dostępnych metod w bibliotece Dipy. Włókna potwierdzone co najmniej dwiema metodami zostały wykorzystane do tworzenia etykiet. Autor w ten sposób znacząco zmniejszył liczbę fałszywych wyników pozytywnych. W celu otrzymania oetykietowanych zbiorów uczących, należało zarejestrować skany dyfuzyjne i anatomiczne. Podrozdział 7.2 opisuje bardzo skomplikowaną procedurę otrzymywania różnych masek ze skanów MRI, które służyły do otrzymania ostatecznych traktogramów, a podrozdział 7.3 metody obliczania traktogramów. Ostatecznie, podrozdz. 7.4 pokazuje jak zapisywane są etykiety z meta-traktogramów.

Rozdział 8 jest opisem eksperymentów porównujących działanie różnych wariantów sieci neuronowych wraz z algorytmem poszukiwania najkrótszej ścieżki. Zostały użyte zbiory z kolekcji Human Connectome Project (HCP), transformowane procedurami opisanymi w rozdziale 7. Meta-traktogramy zostały podzielone na uczące i testujące w proporcji 8:2. Wykonano eksperymenty z różnymi modelami opisanymi rozdziale 6 oraz z różnymi algorytmami służącymi do optymalizacji i regularyzacji uczenia sieci. Eksperymenty te były wykonane z rozmiarem danych (kostek) $5 \times 5 \times 5$, natomiast sprawdzono jeszcze inne rozmiary danych wyjściowych: $7 \times 7 \times 7$ i $9 \times 9 \times 9$.

Eksperymenty wykazały, że architektura MLP z dwoma blokami warstwy wejściowej z wagami tworzącymi mechanizm uwagi dała najlepsze wyniki.

Rozdział 9 jest opisem eksperymentów testujących zaproponowany algorytm HyTract na nowych danych nie używanych w czasie uczenia i testowania sieci neuronowych.

Rozdział 10 jest podsumowaniem rozprawy.

Pracę kończy bibliografia składająca się z 134 pozycji.

3. Ocena rozprawy

W ramach rozprawy doktorskiej Doktorant zaproponował oryginalne rozwiązanie wspierające pracę neurochirurgów w czasie planowania i wykonywania operacji. Stworzone autorska metoda znajdowania traktów nerwowych w mózgu po integracji z istniejącymi systemami nawigacji komputerowej pozwoli na dalsze usprawnienie pracy chirurga już w czasie operacji.

Rozprawa doktorska uwidacznia wysoką ogólną wiedzę teoretyczną i praktyczną mgra inż. Mateusza Korycińskiego. Mgr Mateusz Koryciński opublikował trzy prace naukowe, w czasopiśmie oraz w materiałach konferencji. Zaprezentowany materiał pokazuje, że Doktorant zrealizował cel pracy. Praca napisana jest bardzo przejrzysto i zrozumiale.

Rozprawa doktorska wykazuje umiejętność samodzielnego prowadzenia pracy naukowej mgra inż. Mateusza Korycińskiego. Opracował wprowadzenie do tematyki traktografii i różnych

metod obrazowania MRI i dokonał przeglądu literatury. Przeprowadził serię dobrze zaplanowanych eksperymentów. Zadał o popularyzację wyników swoich badań.

Rozprawa doktorska stanowi oryginalne rozwiązanie problemu naukowego. Zaproponowane metody mają duże znaczenie dla medycyny i społeczeństwa, dzięki stworzeniu nowatorskich metod bezinwazyjnego obrazowania medycznego pomocnych w bardzo skomplikowanych operacjach neurochirurgicznych. Można mieć nadzieję, że metoda polepszy jakość zabiegów oraz zminimalizuje ryzyko wystąpienia skutków ubocznych, co jest wysoce istotne przy operacjach na otwartym mózgu. Metoda, w porównaniu do wcześniejszych metod traktograficznych, cechuje się większą wyjaśnialnością dostarczając graf wokseli.

W trakcie czytania pracy nasunęły mi się poniższe wątpliwości i pytania:

Czy architektura sieci z blokiem splotowym w pierwszej warstwie, przedstawiona na rysunku 6.6 również mogłaby korzystać z wag ustalających istotność (rys. 6.5)?

Sieć z rysunku 6.5 ma dwie wagi, których wartości są dobierane w czasie uczenia dla całego zbioru danych. W pracy pada stwierdzenie, że naśladują one mechanizm uwagi. W obecnej terminologii uwaga jest wyznaczana dynamicznie równolegle lub sekwencyjnie dla poszczególnych wartości z sekwencji danych wejściowych. Rozwiązanie z rys. 6.5 jest bardziej wyznaczeniem globalnej ważności poszczególnych sekcji sieci neuronowej, w tym przypadku wynikającej z ważności rodzajów danych.

Czy mogłoby być celowym użycie zamiast modelu z rysunku 6.6 sieci w pełni splotowej na przykład podobnej do modelu zaproponowanego w Shelhamer E, Long J, Darrell T. "Fully Convolutional Networks for Semantic Segmentation", 2014, lub do sieci U-Net (Ronneberger O, Fischer P, Brox T., "U-Net: Convolutional Networks for Biomedical Image Segmentation", 2015). Być może pozwoliłoby to dalej zmniejszyć liczbę parametrów. Oczywiście, przy obecnych mocach komputerów prędkość uczenia czy zapotrzebowanie na pamięć w proponowanej metodzie nie są newralgiczne, gdyż system przygotowuje się przed zabiegiem.

Na stronie 24 pada stwierdzenie dotyczące sieci typu Transformer: "Such architecture has better parallelization capabilities and trains faster than the standard approach...". Można się domyślać, że podejście standardowe to różne typy sieci rekurencyjnych, szczególnie LSTM, ale nie jest to jasne.

Rozdziały 6, 7 oraz 9 zaczynają się rysunkiem, który w takiej formie mógłby być „graficznym abstraktem” rozdziału. Nie ma tu jednak konsekwencji w całej rozprawie, gdyż Rys. 7.8 jest częścią rozdziału 7, a znajduje się nad tytułem rozdziału 8.

4. Wnioski końcowe recenzji

Podsumowując recenzję stwierdzam, że Pan mgr inż. Mateusz Koryciński w rozprawie doktorskiej „A Hybrid Method for Tractography in Neurosurgery Using Artificial Neural

Networks and Path Search Algorithms” zrealizował cel rozprawy. Zaprezentowane rezultaty stanowią oryginalny wkład Autora w rozwój dyscypliny informatyka techniczna i telekomunikacja. Pan Mateusz Koryciński wykazał się umiejętnością samodzielnej pracy badawczej, znajomością literatury światowej i wiedzą w zakresie uczenia maszynowego, obrazowania medycznego oraz komputerowego wspomaganie decyzji w medycynie. Recenzowana praca spełnia wymagania ustawy o tytule i stopniach naukowych w dyscyplinie naukowej informatyka techniczna i telekomunikacja. Wnoszę o jej przyjęcie i dopuszczenie do dalszych etapów postępowania doktorskiego. Jednocześnie, ze względu na wysoki poziom rozprawy oraz opublikowanie rezultatów w renomowanych czasopismach i materiałach konferencyjnych wnioskuję o jej wyróżnienie.

