



Abstrakt Popularnonaukowy. Tytuł: Algorytm AI do monitorowania leczenia przerzutów nowotworowych do mózgu z uwzględnieniem hybrydowej niepewności predykcji wraz z niepewnością wyjaśnialności modelu w odniesieniu do zmienności w segmentacjach radiologów.

Przerzuty nowotworowe do mózgu — czyli nowotwory, które rozprzestrzeniły się do mózgu z innych części ciała — są często monitorowane za pomocą rezonansu magnetycznego (MR) w celu oceny skuteczności leczenia. W ostatnich latach metody oparte na sztucznej inteligencji (AI) wykazały duży potencjał w analizie tych obrazów, zwłaszcza w zakresie wykrywania i pomiaru zmian nowotworowych. Jednak lekarze nadal w dużej mierze opierają się na prostych, dwuwymiarowych pomiarach do oceny przerzutów. Modele AI osiągnęły postęp w segmentacji przerzutów w ujęciu 3D, ale małe zmiany są nadal trudne do wykrycia z odpowiednią dokładnością, a wiele systemów AI nie jest jeszcze stosowanych w szpitalach, ponieważ działają one jak "czarne skrzynki" — nie dostarczając informacji o przyczynach swoich decyzji ani o poziomie (nie)pewności. Dodatkowo, badania wskazują na wątpliwą jakość segmentacji części danych wykorzystywanych do trenowania modeli AI, a oprócz tego, radiolodzy-eksperti często różnią się między sobą w interpretacji tych samych obrazów. Wynika to z faktu, że interpretacja obrazów medycznych przez człowieka to raczej spektrum ocen niż jedna, stała prawda. Zmienność pomiędzy (inter-) i wewnątrz (intra-) oceniających odzwierciedla złożoność i subiektywność interpretacji obrazów, co istotnie wpływa na rozwój algorytmów segmentacji. Zamiast traktować te różnice jako szum i błąd, należy wykorzystać je do modelowania zmienności i zwiększenia odporności oraz użyteczności klinicznej algorytmu. Celem naszego projektu jest stworzenie systemu AI, który nie tylko segmentuje przerzuty do mózgu w obrazach MR, ale także jasno komunikuje, jak bardzo „pewny” jest co do swoich wyników oraz wyjaśnia, dlaczego podjął określoną decyzję — wraz z oceną niepewności tego wyjaśnienia. Nasze podejście, które nazywamy UQ-XAI (wyjaśnialna AI z pomiarem niepewności), łączy dwie innowacje: szacowanie niepewności predykcji (czyli określenie, czego algorytm „nie jest pewien”) i niepewności wyjaśnialności (czyli pokazanie, dlaczego algorytm podjął określoną decyzję i jak to wyjaśnienie jest pewne). System będzie uczony rozpoznawania dwóch typów niepewności — tych wynikających z danych (np. jakość obrazu, szumu na granicach zmiany) oraz tych wynikających z samego modelu AI (np. brak doświadczenia w danych przypadkach). W projekcie wykorzystujemy zbiór danych obejmujący 75 badań MR, z których każde zostało posegmentowane przez 8 niezależnych ekspertów. Nasze wstępne prace (Figura) koncentrują się na wyznaczeniu „konsensusu eksperckiego”, który posłuży do walidacji naszego modelu AI. Sprawdzimy hipotezę, że obszary niepewności modelu pokrywają się z obszarami niezgodności pomiędzy radiologami. Zbadamy również, czy zmiany poziomu niepewności w czasie — na przykład, gdy jakiś obszar guza staje się trudniejszy do zdefiniowania — mogą być wskaźnikiem (biomarkerem) heterogennej odpowiedzi na leczenie, niezależnie od tego, czy guz się powiększa, czy zmniejsza. Projekt ma potencjał znacząco poprawić sposób monitorowania przerzutów do mózgu w czasie. Jeśli zakończy się sukcesem, nasze podejście doprowadzi do powstania narzędzi AI, które będą nie tylko dokładniejsze, ale także bardziej przejrzyste i godne zaufania. W dłuższej perspektywie planujemy zintegrować tę technologię z systemami szpitalnymi (PACS), aby wyposażać neuroradiologów w segmentacje objętościowe uwzględniające poziom niepewności i zawierające wyjaśnienia — wspierając ich w podejmowaniu decyzji terapeutycznych. Będzie to ważny krok w kierunku bezpiecznego i skutecznego wdrażania AI w neuroonkologii.

A. Przykład 8 segmentacji przedstawiających cały guz, zdefiniowany jako martwiczyc rdzeń oraz guz wzmacniający się po kontraście, pochodzący z wyzwania BraTS-METS. Pozostałe etykiety segmentacji zostały pominięte.



B. Przegląd metody – obliczenie segmentacji konsensusowej jako średniej z 8 adnotacji dla każdego przypadku, uzupełnione mapą entropii jako mapą niepewności.



C. Analiza konsensusu dla przykładowych przypadków.

