

Algorytmy władzy

Guru okulistycznej sztucznej inteligencji – Prof. Andrzej Grzybowski, Prof. Linda Zangwill, Prof. Michael F. Chiang, Prof. Damien Gatineau, Dr. Paisan Ruamviboonsuk i Prof. Michael D. Abramoff – zastanawiają się, gdzie i jak technologia może pomóc w zapewnieniu najwyższej jakości diagnostyki chorób oczu.



Prof. Andrzej Grzybowski

Zagrożenia i potencjalne problemy urządzeń medycznych AI

Andrzej Grzybowski, profesor okulistyki i kierownik Katedry Okulistyki Uniwersytetu Warmińsko-Mazurskiego w Olsztynie oraz kierownik Instytutu Badań Okulistycznych Fundacji Wspierania Rozwoju Okulistyki w Poznaniu

Ostatnio zaobserwowaliśmy znaczny rozwój wielu technologii i aplikacji związanych ze sztuczną inteligencją (AI, *artificial intelligence*), a obietnice sztucznej inteligencji w opiece

zdrowotnej są bardzo entuzjastyczne. Obejmują one m.in. poprawę wyników leczenia pacjentów, ułatwienie pracy zespołów medycznych, a także obniżenie kosztów dzięki unikaniu błędów i niepotrzebnych procedur. Wkroczyliśmy w czwartą fazę rewolucji przemysłowej, a sztuczna inteligencja jest jej najważniejszym elementem. Ambitne oczekiwania wobec sztucznej inteligencji w opiece zdrowotnej obejmują osiąganie lepszych wyników wśród lekarzy, pomoc w diagnozowaniu tego, czego obecnie nie da się zdiagnozować, pomoc w leczeniu tego, co obecnie nieuleczalne, przewidywanie nieprzewidywalnego i klasyfikowanie tego, co niesklasyfikowane. Sztuczna inteligencja może pomóc zachować relację lekarz-pacjent i przenieść ją z obecnej „płytkiej medycyny” w „głęboką medycynę” opartą na głębokiej empatii i relacji lekarz-pacjent. Obecnie średni czas wizyty w przychodni w USA dla ustalonego pacjenta wynosi 7 minut, a dla nowego pacjenta – 12 minut, a w wielu krajach azjatyckich wynosi on do 2 minut na pacjenta. Co gorsza, część tego czasu trzeba poświęcić na wypełnienie elektronicznej dokumentacji medycznej.

„Medycyna głęboka” (chodzi tu o nawiązanie do tzw. głębokich sieci neuronalnych oraz głębokiego uczenia) oparta na sztucznej inteligencji może dać nam więcej czasu na kluczowe relacje z naszymi pacjentami – a tych nie da się zastąpić technologią. Wykazano, że technologie oparte na sztucznej inteligencji wykorzystujące podejście głębokiego uczenia (DL) wspierają decyzje w wielu specjalnościach medycznych, w tym radiologii, kardiologii, onkologii, dermatologii i okulistyce. Wykazano, że modele AI/DL skracają czas oczekiwania na leczenie, poprawiają przestrzeganie przez pacjentów stosowanie leków, pomagają lepiej dostosowywać dawki insuliny i interpretować obrazy rezonansu magnetycznego. Wykazano, że algorytmy AI/DL wykrywają stany chorobowe na podstawie analizy obrazu, w tym choroby siatkówki na podstawie zdjęć dna oka i skanów OCT, choroby płuc na podstawie radiogramów klatki piersiowej oraz choroby skóry na podstawie zdjęć skóry. Dwa autonomiczne urządzenia medyczne oparte na sztucznej inteligencji do wykrywania retinopatii cukrzycowej

zarejestrowane są w USA, a kilka innych jest dostępnych w Unii Europejskiej. Algorytmy sztucznej inteligencji są wykorzystywane do badań przesiewowych retinopatii cukrzycowej w wielu częściach świata.

W Polsce opracowałem i rozpocząłem projekt badań przesiewowych retinopatii cukrzycowej w oparciu o sztuczną inteligencję w 2017 roku, a od 2018 roku mój zespół prowadzi duży projekt, którego celem jest przebadanie ponad 40 000 pacjentów z cukrzycą w Wielkopolsce, finansowany przez UE. Nowym i bardzo obiecującym zastosowaniem jest wykorzystanie obrazów oka do identyfikacji ryzyka chorób sercowo-naczyniowych lub neurodegeneracyjnych.

Jednak mówiąc o rosnącym entuzjazmie i perspektywach związanych ze sztuczną inteligencją w okulistyce, musimy również wspomnieć o rosnących problemach, które należy rozwiązać, zanim urządzenia medyczne oparte na sztucznej inteligencji zostaną wprowadzone do praktyki klinicznej. Jednym z głównych problemów jest brak jasności, co stanowi dowód wpływu i możliwych do wykazania korzyści dla wielu wyrobów medycznych wykorzystujących sztuczną inteligencję oraz kto może ocenić dowody tych korzyści.

Przyszły rozwój dziedziny AI zależy od łatwiejszego – a najlepiej nieograniczonego – dostępu do danych medycznych przechowywanych w elektronicznej dokumentacji medycznej. Dostęp ten nie może jednak stanowić nadużycia prywatności tych bardzo wrażliwych danych. Według amerykańskiego Narodowego Instytutu Standardów i Technologii dane biometryczne, w tym obrazy siatkówki, są informacjami umożliwiającymi identyfikację osoby i powinny być chronione przed nieodpowiednim dostępem. Chociaż wykazano, że obecne modele sztucznej inteligencji diagnozują i oceniają niektóre choroby oczu na podstawie obrazów, w tym zdjęć dna oka, OCT i danych z pola widzenia, większość algorytmów sztucznej inteligencji została przetestowana na zbiorze danych, który nie odpowiada dobrze warunkom rzeczywistym. Populacje pacjentów były zazwyczaj jednorodne pod względem pochodzenia etnicznego,

wieku, braku chorób współistniejących i niskiej jakości obrazów. Ponadto wykazano, że niektóre algorytmy błędnie przedstawiają i nasilają problemy zdrowotne w grupach mniejszościowych. Przyszłe zbiory danych powinny lepiej opisywać, kto jest reprezentowany i w jaki sposób, aby uniknąć błędów strukturalnych (patrz jedna z ostatnich inicjatyw na www.datadiversity.org).



Źródło: <https://www.canva.com/>

W związku z tym potrzebne są przyszłe badania nad walidacją algorytmów na rzeczywistych obrazach oka z heterogennych populacji, w tym obrazów dobrej i niskiej jakości. W przeciwnym razie możemy spotkać się z dobrą sztuczną inteligencją prowadzącą do nieprawidłowych wyników. Wybieranie przez autorów badań najlepszych wyników, co jest częstą praktyką, może jeszcze pogorszyć sytuację. Należy podkreślić, że algorytmy oparte na sztucznej inteligencji mogą zachowywać się nieprzewidywalnie, gdy są stosowane w warunkach rzeczywistych. Wykazano, że działanie algorytmu pogarsza się, gdy stosuje się go

do obrazów generowanych przez inne urządzenie lub w innym środowisku klinicznym niż zestaw treningowy. Wszystkie te problemy mogą prowadzić do błędnej diagnozy i błędnych propozycji leczenia, podważając zaufanie do technologii sztucznej inteligencji. Wreszcie powinniśmy być w stanie wyobrazić sobie, że jeśli system sztucznej inteligencji popełni błąd, może zaszkodzić setkom, a nawet tysiącom pacjentów. Dlatego lubię cytować Tetlocka i Gardnera (Superprognozowanie), którzy powiedzieli: *„Jeśli nie otrzymujesz informacji zwrotnej, twoja pewność siebie rośnie znacznie szybciej niż dokładność”*.

Jedno z ostatnich niezależnych badań porównujących siedem różnych algorytmów wykazało, że jeden z testowanych algorytmów był znacznie gorszy od oceniających ludzi na wszystkich poziomach nasilenia retinopatii cukrzycowej – przeoczył ponad 25% przypadków zaawansowanej retinopatii, co może potencjalnie prowadzić do poważnych konsekwencji (1) . Badanie to wykazało możliwe problemy i zagrożenia bezpieczeństwa pacjenta związane z klinicznym wykorzystaniem niektórych algorytmów. Obejmują one ograniczenia związane z uczeniem algorytmu na określonej grupie demograficznej, obejmującej jednorodnie pochodzenie etniczne, wiek, płeć, oraz jego dalsze wykorzystanie na innej populacji. Ponadto wiele badań wyklucza obrazy niskiej jakości, traktowane jako obrazy nie podlegające ocenie, oraz pacjentów ze współistniejącymi chorobami oczu, co sprawia, że w mniejszym stopniu odzwierciedlają one warunki rzeczywistego życia.

Należy również pamiętać, że algorytmy AI można zaprojektować tak, aby działały w nieetyczny sposób. Na przykład oprogramowanie Ubera, Greyball, zostało zaprojektowane, aby umożliwić firmie identyfikowanie i obchodzenie lokalnych przepisów, a algorytm Volkswagena pozwalał pojazdom przejść testy emisji poprzez zmniejszenie emisji tlenu azotu podczas badań diagnostycznych. Co więcej, algorytmy wspomagające podejmowanie decyzji klinicznych mogą być zaprojektowane tak, aby generować większe zyski dla ich właścicieli, takie jak polecenie konkretnych leków, testów i nie tylko, bez świadomości samych lekarzy i

pacjentów. Wreszcie, systemy sztucznej inteligencji są podatne na tzw. cyberataki, które mogą spowodować błędną klasyfikację informacji medycznych przez algorytm. Po więcej informacji na ten temat sięgnij do naszej najnowszej publikacji Sztuczna inteligencja w okulistyce (2).

1. Lee AY, et al. Multicenter, Head-to-Head, Real-World Validation Study of Seven Automated Artificial Intelligence Diabetic Retinopathy Screening Systems. *Diabetes Care*. 2021 May;44(5):1168-1175.

2. *Artificial Intelligence in Ophthalmology*, A. Grzybowski (ed), Springer 2021. <https://link.springer.com/book/10.1007/978-3-030-78601-4>




Prof. Linda Zangwill

AI i jaskra

Prof. Linda Zangwill, współdyrektor ds. badań klinicznych, dyrektor Centrum Jaskry Hamiltona, Centrum Koordynacji Danych, Shiley Eye Institute, UC San Diego, Kalifornia, USA

Dlaczego AI powinna być stosowana w jaskrze? Jakie korzyści daje sztuczna inteligencja w tej dziedzinie?

Stosowanie sztucznej inteligencji do pomocy w podejmowaniu decyzji klinicznych dotyczących wykrywania i leczenia jaskry niesie ze sobą wiele korzyści. Sztuczna inteligencja może poprawić dokładność i spójność wykrywania jaskry na wszystkich poziomach opieki okulistycznej. Może być również stosowana do wykrywania osób z jaskrą postępującą, które wymagają dokładniejszej obserwacji lub w innych przypadkach sugerować, że jaskra pacjenta jest stabilna i wymaga rzadszych obserwacji. Ponadto, dostarczając informacji o prawdopodobieństwie wystąpienia jaskry, lekarz może włączyć te informacje do swoich decyzji dotyczących postępowania z pacjentem. Co więcej, sztuczna inteligencja może pomóc w badaniach przesiewowych osób wysokiego ryzyka pod kątem jaskry w placówkach podstawowej opieki zdrowotnej, dzięki czemu choroba może zostać zdiagnozowana na najwcześniejszym, uleczalnym stadium.



Źródło: <https://www.canva.com/>

Czy wiemy, które algorytmy AI są lepsze: te oparte na OCT czy te opracowane na obrazach dna oka?

Algorytmy AI do wykrywania jaskry oparte na obrazach OCT i zdjęciach dna oka mają wysoką dokładność diagnostyczną (1, 2). Oba są przydatne, ponieważ mogą być cenne w różnych sytuacjach. OCT to standard opieki w klinicznym leczeniu jaskry w większości klinik okulistycznych. Jednak w wielu społecznościach, szczególnie na obszarach o niedostatecznym zasięgu, fotografia dna oka jest znacznie bardziej dostępna niż obrazowanie OCT. Ponadto wykrywanie jaskry za pomocą fotografii dna oka może być łatwiej zintegrowane z badaniami przesiewowymi w kierunku innych chorób oczu, takich jak retinopatia cukrzycowa i zwyrodnienie plamki żółtej w warunkach podstawowej opieki zdrowotnej. Dlatego ważne jest, aby opracować dokładne algorytmy sztucznej inteligencji zarówno dla obrazowania OCT, jak i dna oka.


Czy algorytmy wykrywania jaskry oparte na sztucznej inteligencji mogą być w przyszłości stosowane w badaniach przesiewowych jaskry?

Wierzę, że algorytmy wykrywania jaskry oparte na sztucznej inteligencji będą wykorzystywane do celowanych badań przesiewowych w kierunku jaskry osób wysokiego ryzyka w ramach podstawowej opieki zdrowotnej i/lub środowisk społecznych. Badania przesiewowe jaskry zostaną prawdopodobnie zintegrowane z istniejącymi algorytmami wykrywania retinopatii cukrzycowej i innych chorób oczu. Ponieważ algorytmy sztucznej inteligencji zapewniają prawdopodobieństwo wystąpienia jaskry, punkt odcięcia używany do skierowania do kontrolnego badania okulistycznego można ustawić na wysoką swoistość niezbędną do badań przesiewowych. Należy zauważyć, że grupa zadaniowa ds. badań prewencyjnych USA ds. badań przesiewowych w kierunku pierwotnej jaskry otwartego kąta stwierdziła niedawno w ogólnej populacji bezobjawowych dorosłych w wieku 40 lat i starszych, iż „obecne

dowody są niewystarczające do oceny bilansu korzyści i szkód związanych z badaniami przesiewowymi w kierunku pierwotnej otwartej jaskry kąta jaskra kąta” (3). Z tych powodów należy rozważyć integrację badań przesiewowych na jaskrę z innymi chorobami oczu oraz ukierunkowane badania przesiewowe na populacje wysokiego ryzyka.

Bibliografia

1. JH Wu, “Performances of machine learning in detecting glaucoma using fundus and retinal optical coherence tomography images: A meta-analysis,” *Am J Ophthalmol*, 237, 1 (2022). PMID: 34942113.
2. AK Chaurasia, “Diagnostic accuracy of artificial intelligence in glaucoma screening and clinical practice,” *J Glaucoma*, 31, 285 (2022). PMID: 35302538.
3. US Preventive Services Task Force et al., “Screening for primary open-angle glaucoma: US Preventive Services Task Force Recommendation Statement,” *JAMA*, 27, 1992 (2022). PMID: 35608574.



Prof. Michael Chiang

Perspektywa retinopatii wcześniaków

Michael F. Chiang, dyrektor, National Eye Institute, National Institutes of Health, Bethesda, Maryland, USA

Dlaczego potrzebna była nowa klasyfikacja retinopatii wcześniaków (ROP)? Co ciekawe, wczesne badania nad ROP, zwanym wówczas fibroplazją pozasoczewkową, prowadził, dziś w większości zapomniany, amerykański okulista polskiego pochodzenia Tadeusz S. Szewczyk. Jako pierwszy wskazał na związek między rozwojem ROP a wysoką ekspozycją na tlen w inkubatorze lub zbyt szybkim poborem tlenu. Co zmieniło się w rozumieniu patofizjologii ROP w ciągu ostatnich 50 lat?

Niedawno opublikowaliśmy trzecią wersję międzynarodowego systemu klasyfikacji ROP, ponieważ pojawiło się wiele nowych wyzwań od poprzedniej z 2005 r.: (i) obawy o subiektywność w krytycznych elementach klasyfikacji postaci ROP, takich jak choroba plus i występowanie zmian w odpowiednich strefach, (ii) innowacje w obrazowaniu okulistycznym i sztucznej inteligencji, (iii) nowe terapie farmakologiczne (takie jak leki anty-VEGF) o unikalnych cechach regresji i reaktywacji po leczeniu w porównaniu z fotokoagulacją laserową oraz (iv) rozpoznanie, że cechy choroby w niektórych regionach świat nie pasowały do poprzedniego systemu klasyfikacji.

Dlaczego ROP jest tak obiecującym obszarem dla urzędzeń medycznych opartych na sztucznej inteligencji?

Po pierwsze, istnieją niezaspokojone potrzeby w zakresie opieki ROP na całym świecie, takie jak wyzwania dotyczące kadry medycznej, problemy dot. diagnozy klinicznej oraz znaczna odpowiedzialność prawna w zakresie medycyny. Po drugie, istnieje międzynarodowy system klasyfikacji ROP, więc istnieje standardowa metoda diagnozy klinicznej stosowana na całym świecie. Po trzecie, istnieje standardowe podejście do postępowania klinicznego oparte na dziesięcioleciach wielośrodkowych wspólnych badań klinicznych, takich jak CRYO-ROP,

ETROP i BEAT-ROP. Wreszcie, istnieją urządzenia do obrazowania siatkówki u dzieci połączone z infrastrukturą do przekazywania danych diagnozy klinicznej i wyników. Wszystkie te czynniki razem tworzą dobre środowisko do wdrażania sztucznej inteligencji i badań ewaluacyjnych.



Źródło: <https://www.canva.com/>

Co wiemy o problemach związanych z różnicami między diagnozami lekarzy?

Klasycznie diagnozujemy choroby okulistyczne badając morfologię oka. Te obserwacje kliniczne są typowo jakościowe i często przekształcamy te obserwacje morfologiczne w ustrukturyzowane klasyfikacje (na przykład „stadium 1” lub „zaawansowana choroba” w ROP, „neowaskularyzacja poza tarczą nerwu wzrokowego” w retinopatii cukrzycowej i podobne). My i wielu innych pokazaliśmy, że te kliniczne diagnozy i klasyfikacje są subiektywne i że często występują znaczące różnice, nawet wśród ekspertów, w dokonywaniu tych

diagnostycznych rozróżnień. Jest to fundamentalne wyzwanie, które ogranicza dokładność i spójność klinicznej diagnozy okulistycznej.



Prof. Damien Gatinel

Segment przedni i sztuczna inteligencja

Damien Gatinel, kierownik oddziału przedniego odcinka i chirurgii refrakcyjnej, Rothschild Foundation Hospital, Paryż, Francja

Jakie są różnice między uczeniem nadzorowanym i nienadzorowanym w sztucznej inteligencji?

Czy druga opcja jest wystarczająco bezpieczna, skoro nie rozumiemy, jak działa algorytm?


W obu przypadkach warunek jest identyczny; mieć dużą ilość danych dobrej jakości. W przypadku uczenia nadzorowanego wykorzystujemy dane oznaczone etykietami i trenujemy algorytm, aby klasyfikować dane jako dane wejściowe w najbardziej efektywny sposób lub dokonywać predykcji. W patologii przedniego odcinka badanie przesiewowe w kierunku stożka rogówki jest oczywistym zastosowaniem. Aby opracować skuteczny algorytm, trzeba mieć dane treningowe z różnych grup (stożek rogówki kontra normalna rogówka). Bez względu

na rodzaj zastosowanego algorytmu (regresja logistyczna, drzewa decyzyjne, sieci neuronowe), używa się danych wejściowych, których pochodzenie jest wyraźnie określone. W przypadku nadzorowanego uczenia się podejście jest znacząco odmienne; problem polega zwykle na odkryciu ukrytych i nieznanymi relacji obecnych w odmiennym zbiorze danych lub poszukiwaniu nieznanymi wzorców. Jest to nie tyle kwestia przewidywania, co odkrywania powiązań między pewnymi danymi, które pozwalają na ich grupowanie, co umożliwia klasyfikację dużych ilości danych. Algorytmy pozwalają zmniejszyć wymiarowość danych wprowadzanych do systemu i oszacować odległość w mniejszej przestrzeni rezydualnej między danymi, które chcemy pogrupować. Wykorzystaliśmy ten proces do oceny możliwości automatycznej klasyfikacji dużej liczby badań topograficznych, które mogą być bardzo interesujące dla szybkiego odnalezienia określonych kategorii (oczy operowane z powodu chirurgii refrakcyjnej, stożka rogówki itp.). W każdym razie ważne jest, aby wyjaśnić możliwe nieporozumienia; jeśli algorytmy są budowane zgodnie z dobrze zidentyfikowanym podejściem, zmienne wykorzystywane do tworzenia grupowań nie zawsze są łatwe do zidentyfikowania. Zawsze trzeba być ostrożnym i mieć metody, aby ograniczyć ryzyko przetrenowania algorytmu (overfitting) i zapewnić, że rozwijany model będzie mógł być stosowany wobec innych pacjentów.

Ważnym osiągnięciem jest opracowanie formuły PEARL-DGS – formuły obliczania mocy soczewek wewnątrzgalkowej opartej na sztucznej inteligencji. Jakie są jego parametry i jak mogą być dziś wykorzystywane i testowane przez praktyków?

Formuła PEARL-DGS opiera się na modelu optycznym wykorzystującym formuły grubych soczewek, algorytmy AI do przewidywania anatomicznego położenia implantu oraz krzywizny tylnej powierzchni rogówki (gdy ta powierzchnia nie jest mierzona). Zastosowane metody odpowiadają uczeniu nadzorowanemu, które było możliwe dzięki uzyskaniu dużego zestawu danych jakościowych z oczu pseudofakijnych zawierających przedoperacyjne dane

biometryczne i uzyskany wynik refrakcji. Wykorzystuje również wartość długości osiowej jako przybliżoną lub dokładną sumę segmentów, jeśli biometr podaje tę wartość. Umożliwia uwzględnienie historii operacji refrakcyjnej rogówki oraz wyników uzyskanych dla pierwszej operacji oka w celu poprawy precyzji obliczenia mocy. Wszystkie kroki użyte do obliczenia mocy implantu zostały opublikowane, a kod został zdeponowany w internetowym katalogu. Formuła dostępna jest pod następującym linkiem: www.iolsolver.com.



Źródło: <https://www.canva.com/>

Jakie będą kolejne aplikacje oparte na sztucznej inteligencji w segmencie przednim?

Patologie przedniego odcinka oka to szeroki zakres obszarów, w których można rozważyć zastosowanie sztucznej inteligencji. Obliczenie mocy implantu jest oczywiście już częścią problemu, ale pracujemy nad wykorzystaniem sieci neuronowych i wysokiej rozdzielczości obrazów OCT przedniego odcinka w celu ustalenia obiektywnej diagnozy zmętnienia soczewki. Dla bardziej obiektywnego rozróżnienia między potwierdzoną zaćmą (wizualnie znaczące zmętnienie) a soczewkami przejrzystymi. Ten sam proces zastosowano również do

scharakteryzowania obecności obrzęku rogówki. W obu przypadkach możliwe jest uzyskanie wzbogaconego obrazu, w którym dla każdego piksela pokazane jest prawdopodobieństwo zmętnienia soczewki lub obrzęku rogówki. Inne interesujące zastosowania obejmują poprawę adaptacji soczewek kontaktowych do rogówek o nieregularnych lub zmienionych kształtach poprzez szybkie przewidywanie parametrów soczewki, lepsze przewidywanie rozmiaru implantów fakijnych na podstawie danych biometrycznych i refrakcyjnych. Można również przewidzieć urządzenia wspomagające diagnostykę w oparciu o banki obrazów przedniego odcinka przy użyciu konwencjonalnych metod rozpoznawania obrazu. Na koniec byliśmy zainteresowani przewidywaniem subiektywnej refrakcji na podstawie obiektywnego pomiaru czoła fali i aberracji optycznych wysokiego stopnia. To tylko przykłady, ale granice tkwią w Twojej wyobraźni!



Dr. Paisan Ruamviboonsuk

O uczeniu transferowym, sieci generatywne i więcej

Paisan Ruamviboonsuk, profesor kliniczny okulistyki, College of Medicine, Rangsit University, zastępca dyrektora szpitala Centers of Medical Excellence; Centre of Excellence for Vitre of Vitre and Retinal Disease, Rajavithi Hospital, Bangkok, Tajlandia

Co to jest uczenie transferowe się i dlaczego uważasz, że może przynieść korzyści w opiece zdrowotnej i okulistyce?

Uczenie transferowe (Transfer learning, TL) to rodzaj modelu głębokiego uczenia, który wykorzystuje inne, już dostępne modele głębokiego uczenia (DL) lub inne zbiory danych. TL może być używany do łatwiejszego opracowania modelu DL lub do poprawy dokładności modelu DL. Na przykład wiele dzisiejszych modeli zostało opracowanych na podstawie informacji przesłanych z ImageNet, który jest modelem open source dostępnym w Internecie. W okulistyce informacje z zestawów danych OCT można na przykład przenieść do odpowiednich zestawów danych kolorowych obrazów dna oka w celu opracowania modelu DL do przeprowadzania analizy zdjęć dna oka, który może zapewnić lepszą dokładność niż tradycyjne DL opracowane wyłącznie na podstawie danych zdjęć dna oka. Dzieje się tak, ponieważ model uczy się więcej zarówno z zestawów danych zdjęć dna oka, jak i OCT. Korzyści obejmowałyby więcej opracowanych modeli AI o lepszej wydajności.

Jakie są ograniczenia tradycyjnych modeli AI?

Tradycyjne modele sztucznej inteligencji mogą wymagać bardzo dużego zestawu danych opracowanego w celu osiągnięcia wystarczająco wysokiej wydajności. Ponadto dostępnych jest obecnie wiele danych z obrazowania multimodalnego w okulistyce, ale tradycyjna sztuczna inteligencja może być w stanie wykorzystywać jednocześnie tylko jeden rodzaj danych.

Czym są sieci generatywne i jak mogą pomóc okulistom?

Sieci generatywne (GAN, Generative adversarial network) to model DL opracowany w celu tworzenia nowych obrazów z istniejących obrazów, a zatem GAN jest z natury modelem TL. Istnieje wiele zastosowań GAN w branży filmowej i reklamowej, na przykład podczas tworzenia obrazu zebry z obrazu konia. W medycynie GAN są wykorzystywane do tworzenia obrazów mniej powszechnie stosowanych metod, takich jak MRI, z obrazów metod, które mogą być częściej stosowane, takich jak tomografia komputerowa. Nowe obrazy mogą być wykorzystywane w badaniach nad sztuczną inteligencją lub jako wskazówki dla lekarzy w badaniach klinicznych. W naszym badaniu wykorzystaliśmy GAN do stworzenia obrazów z biomikroskopii ultradźwiękowej (UBM) przedniego odcinka na podstawie odpowiednich obrazów OCT przedniego odcinka w celu wykrycia zespołu płaskiej tęczówki (iris plateau). W innym badaniu naukowcy wykorzystali GAN do stworzenia obrazów dna oka, aby odblokować czarną skrzynkę DL. Naukowcy biorący udział w tym badaniu opracowali model DL, aby wykryć, gdzie warstwa włókien nerwowych lub obwód nerwowo-siatkówkowy tarczy nerwu wzrokowego ulega przerzedzeniu na obrazach dna oka z jaskrą. Wykorzystali GAN do stworzenia obrazu dna oka, na którym ten cienki obszar miał normalną grubość i innego obrazu, w którym ten obszar był wyjątkowo cienki. Te nowe obrazy podkreśliły, gdzie na obrazach dna oka model DL używany do diagnozowania jaskry i okuliści mogli wykorzystać te obrazy utworzone przez GAN do oceny czy model wskazał prawidłowe obszary.



Prof. Michael D. Abramoff

Sztuczna inteligencja: autonomiczna lub wspomagająca

Michael D. Abràmoff, The Robert C. Watzke profesor okulistyki, profesor inżynierii elektrycznej i komputerowej oraz inżynierii biomedycznej, Klinika Okulistyki i Nauk Procesu Widzenia, Uniwersytetu Iowa, Iowa, USA

Jaka jest różnica między autonomicznymi a wspomagającymi urządzeniami medycznymi AI?

Termin „pomocniczy” odnosi się do systemów sztucznej inteligencji, w których lekarz podejmuje ostateczną decyzję medyczną na ich podstawie, podczas gdy termin „autonomiczny” jest zarezerwowany dla tych systemów, w których sztuczna inteligencja podejmuje ostateczną diagnozę medyczną i to twórca AI ponosi odpowiedzialność za wydajność AI, a nie użytkownik (1). Jeśli ktoś twierdzi, że sztuczna inteligencja jest autonomiczna, kolejnym pytaniem powinno być, czy odpowiedzialność spoczywa na użytkowniku (1).

Kto powinien odpowiadać za potencjalny błąd popełniony przez wyrób medyczny AI?

Wraz z kolegami wcześniej proponowaliśmy, aby twórcy autonomicznych systemów sztucznej inteligencji wzięli na siebie odpowiedzialność za szkody spowodowane przez diagnostyczne urządzenia, gdy są ono używane prawidłowo i zgodnie z jego wskazaniem (2). Artykuł stwierdza, że jest to niezbędne do ich stosowania: nieprawidłowe jest, gdy lekarze korzystający z autonomicznej sztucznej inteligencji do podejmowania diagnozy klinicznej, mogą jednak ponosić pełną odpowiedzialność medyczną za szkody spowodowane przez tę autonomiczną sztuczna inteligencję. Pogląd ten został niedawno poparty przez Amerykańskie Stowarzyszenie Medyczne w swojej polityce AI z 2019 roku. Taki paradygmat odpowiedzialności jest bardziej złożony w przypadku wspomagającej sztucznej inteligencji, gdzie odpowiedzialność medyczna może spaść tylko na usługodawcę, który z niej korzysta, ponieważ to on jest ostatecznie odpowiedzialny za decyzję medyczną (3).

Jakie są główne problemy związane ze sztuczna inteligencją i jak można się z nimi uporać?

Wszyscy interesariusze w systemie opieki zdrowotnej mają uzasadnione obawy dotyczące sztucznej inteligencji, którymi należy się zająć. Zainteresowane strony to pacjenci, organizacje pacjentów, lekarze i inni świadczeniodawcy, bioetycy, eksperci medyczno-prawni, organy regulacyjne, takie jak amerykańska FDA i amerykańska FTC i Wspólna Komisja oraz płatnicy, tacy jak CMS (Medicare i Medicaid) oraz prywatni płatnicy. Czy z zastosowania sztucznej inteligencji wynikają korzyści dla pacjentów lub populacji, takie jak poprawa wyników? Sztuczną inteligencję, która jest technologicznie atrakcyjna, ale nie oferuje korzyści pacjentom, nazwałbym „AI z przepychu”. Czy zwiększa dysproporcje zdrowotne lub w inny sposób negatywnie wpływa na niektóre populacje? Czy istnieją uprzedzenia rasowe, etniczne lub inne w zakresie bezpieczeństwa lub skuteczności sztucznej inteligencji? Kto ponosi odpowiedzialność, jeśli coś pójdzie nie tak? Co dzieje się z danymi pacjenta, gdy wykorzystywana jest sztuczna inteligencja i w jaki sposób dane pacjenta są wykorzystywane w rozwoju i użytkowaniu?



Źródło: <https://www.canva.com/>

Mogą istnieć inne, jeszcze nieprzewidywane obawy. Jedynym sposobem rozwiązania tych znanych i nieznanymi obaw są ramy etyczne dla sztucznej inteligencji, które zaczynają się od podstawowych zasad bioetycznych sprzed tysiącleci, takich jak autonomia, sprawiedliwość, dobroczynność i nieszkodzenie oraz odpowiedzialność. Mierząc, na ile dany system AI spełnia każdą z tych bioetycznych zasad, twórcy AI mogą budować systemy, które rozwiązują wszystkie obawy w sposób możliwy do udowodnienia (falsyfikowalny); nazywa się to miernikami etyki. Ja i inni publikowaliśmy obszernie na te tematy, w tym nt. ram etycznych dla sztucznej inteligencji, które same zostały wykorzystane do stworzenia rozważań regulacyjnych dla sztucznej inteligencji z amerykańską FDA oraz rozważania dotyczące zwrotu kosztów dla amerykańskiego CMS i innych płatników, i wszystkie one zostały pomyślnie zastosowane, co doprowadziło do zatwierdzenia przez organy regulacyjne i zwrotu kosztów autonomicznej sztucznej inteligencji w USA (1, 2, 3).

Z ram etycznych można wywnioskować, co następuje: Technologia sztucznej inteligencji wymaga również walidacji w ramach wstępnie zarejestrowanego, recenzowanego badania klinicznego prowadzonego w zamierzonych warunkach klinicznych, którego wyniki spełniają lub przekraczają wszystkie zaplanowane punkty końcowe. Na przykład, IDx-DR przekroczył wszystkie zaplanowane punkty końcowe z 87-procentową czułością, 91-procentową swoistością, z prawidłowym wynikiem diagnostycznym dla 96 procent badanych i dowiedziono, że nie ma uprzedzeń rasowych ani etnicznych. Wyniki te doprowadziły do uzyskania zgody FDA i pomogły zbudować zaufanie wszystkich interesariuszy z branży, ułatwiając przyjęcie autonomicznej sztucznej inteligencji do standardów opieki nad cukrzycą, refundację za pomocą kodu CPT 92229 w USA i powszechne przyjęcie systemu. Ostatecznym celem rozwoju sztucznej inteligencji jest poprawa wyników leczenia pacjentów poprzez zwiększenie dostępu, obniżenie kosztów i poprawę jakości opieki dostępnej dla osób, które jej najbardziej potrzebują.

Bibliografia


1. MD Abramoff et al., "Foundational Considerations for Artificial Intelligence Using Ophthalmic Images," *Ophthalmology*, 129, e14 (2021). PMID: 34478784.
2. MD Abramoff et al., "Diagnosing Diabetic Retinopathy with Artificial Intelligence: What Information Should Be Included to Ensure Ethical Informed Consent?" *Front Med (Lausanne)*, 8 (2021). PMID: 34901083.
3. DS Char et al., "Identifying Ethical Considerations for Machine Learning Healthcare Applications," *The American Journal of Bioethics*, 20, 7 (2020).
4. MD Abramoff et al., "Lessons Learned About Autonomous Ai: Finding a Safe, Efficacious, and Ethical Path through the Development Process," *Am J Ophthalmol*, 214, 314 (2020).
5. MD Abramoff et al., "A Reimbursement Framework for Artificial Intelligence in Healthcare," *NPJ Digit Med*, 5 (2022). PMID: 35681002.

Jakie są główne wyzwania związane z dalszym rozwojem sztucznej inteligencji w najbliższej przyszłości?

Linda Zangwill

Opracowanie algorytmów sztucznej inteligencji do wykrywania jaskry jest teraz stosunkowo proste, jeśli dysponuje się odpowiednimi zestawami danych i zasobami obliczeniowymi. Jednym z głównych wyzwań we wdrażaniu sztucznej inteligencji w warunkach klinicznych jest zapewnienie, że algorytm jest możliwy do uogólnienia na populacje docelowe i nie będzie stronniczy ze względu na ograniczenia zestawu treningowego. Ocena możliwości uogólnienia wyników wymaga szeroko zakrojonych testów algorytmu AI na zewnętrznych zbiorach danych z różnych populacji. Kolejnym wyzwaniem jest ustalenie, jak zintegrować system AI i wyniki z praktyką kliniczną. Gdzie i jak należy umieścić wyniki algorytmu AI w elektronicznej karcie zdrowia lub systemie PACS, z którego korzysta klinicysta w rutynowym postępowaniu z pacjentami z jaskrą? Jakiego rodzaju informacje podsumowujące i/lub wizualizację wyników AI należy podać? Niezbędne jest określenie, w jaki sposób wyniki sztucznej inteligencji mogą być dostarczane w sposób łatwy i szybki w użyciu, aby zapewnić wartość dodaną i nie

spowalniać sprawnego przepływu pracy klinicznej. Można opracować najlepszy algorytm sztucznej inteligencji, ale jeśli lekarze nie chcą lub nie mogą z niego korzystać, nie poprawi to opieki zdrowotnej. Inne wyzwania związane z rozwojem i wdrażaniem sztucznej inteligencji obejmują jak najlepiej otworzyć tzw. czarną skrzynkę, aby dostarczyć informacji o tym, jakiego algorytmu użył do podjęcia decyzji, a także kwestie medyczne, prawne, etyczne i dotyczące prywatności.



Źródło: <https://www.canva.com/>

Michael F. Chiang

Przedstawię kilka wyzwań: po pierwsze, tracimy wiele możliwości wykorzystania danych obrazu okulistycznego do opracowywania systemów sztucznej inteligencji, ponieważ dane te są zamknięte w zastrzeżonych standardach i niedostępne dla badaczy i lekarzy. Po drugie, musimy poprawić kulturę udostępniania danych, standardy reprezentacji danych i metody ustalania podstawowej prawdy, aby w pełni wykorzystać możliwości budowania dużych

zbiorów danych gotowych do sztucznej inteligencji do odkrywania wiedzy. Po trzecie, systemy sztucznej inteligencji najlepiej radzą sobie z pojedynczymi pytaniami (np. „Czy w tym obrazie siatkówki dziecka poddawanego badaniu ROP występują cechy określone jako „objaw plus”?”), podczas gdy scenariusze w warunkach rzeczywistych wymagają równoległego odpowiadania na wiele pytań. Po czwarte, systemy sztucznej inteligencji są zazwyczaj szkolone i walidowane w dość wąskich populacjach i określonych urządzeniach do obrazowania, podczas gdy rzeczywiste aplikacje będą musiały zostać poddane rygorystycznej walidacji, aby zapewnić, że działają w szerokich populacjach i urządzeniach bez uprzedzeń.

Damien Gatinel

Ograniczenia rozwoju AI dotyczą głównie gromadzenia danych, ponieważ wspólnym punktem każdego projektu jest wykorzystanie dużej ilości danych wysokiej jakości. Często zdarza się, że nawet po skompilowaniu dużego zestawu danych koniecznych jest drastyczne zmniejszenie jego rozmiaru. Możemy również przewidzieć pewne problemy etyczne, o ile czasami nie wiemy, za pomocą jakiego mechanizmu (mechanizmów) uzyskuje się określone wyniki w zakresie klasyfikacji lub przewidywania.

Paisan Ruamviboonsuk

Myślę, że możemy wykorzystać zalety multimodalnych obrazów w okulistyce do opracowania modeli AI, które są bardziej skuteczne w badaniach przesiewowych lub wykrywaniu chorób lub wykrywaniu postępu choroby. Obecnie istnieje niezliczona ilość modeli sztucznej inteligencji dla różnego rodzaju zadań; jednak główne wyzwania dla mnie polegają na tym, jak przydatne są te modele w zmniejszaniu ryzyka ślepoty; jak przydatne są do wdrożenia w świecie rzeczywistym. Wiele modeli sztucznej inteligencji działa dobrze w walidacji wewnętrznej, ale nie sprawdza się we wdrażaniu w warunkach rzeczywistych. Inne wyzwania opierałyby się na „przewidywaniu” wyników leczenia i progresji choroby. Modele dla tych zadań mają teraz dokładność około 70 procent, czekamy na lepsze prognozy w przyszłości.

Michael D. Abramoff

Teoretyczne wyzwania, które widzę: w opiece zdrowotnej dane treningowe zawsze będą skąpe, więc jak możemy zbudować sztuczną inteligencję, która wykorzystuje ograniczone ilości danych treningowych i jak korzystamy z serwerów proxy w warunkach głębokiego uczenia? W jakich warunkach sztuczną inteligencję można zmienić „w pewnym stopniu” bez konieczności pełnej (i często kosztownej) walidacji? Musimy być w stanie dowiedzieć się, w jaki sposób rozszerzamy refundację sztucznej inteligencji, która spełnia niektóre, ale nie wszystkie, powyższe kryteria oraz jak radzimy sobie z utratą informacji, która wiąże się z wielokrotnym badaniem istniejących zestawów danych, takich jak drogi zestaw danych walidacyjnych. Przewiduję, że praktyczne wyzwania obejmują między innymi: potrzebę lepszej edukacji i przyjęcia wysoce zwalidowanych systemów sztucznej inteligencji, które są zintegrowane z systemami organizacji pracy medycznej i podlegają zrównoważonej refundacji. Sztuczna inteligencja w opiece zdrowotnej musi koncentrować się na rozwiązaniach, które przynoszą największe korzyści pacjentom. W jaki sposób regulujemy lokalne AI, które są bezpieczne i skuteczne w niektórych subpopulacjach, ale nie w innych? Chociaż mogą istnieć technologie sztucznej inteligencji, które brzmią ekscytująco, jeśli nie wpływają pozytywnie na wyniki pacjentów, nie przyniosą one żadnych realnych korzyści opiece zdrowotnej i mogą spowolnić wdrażanie rozwiązań mających pozytywny wpływ. Oczywiście wszystko to zależy od posiadania dostępu do odpowiednio zróżnicowanych i wiarygodnych zbiorów danych, na podstawie których można szkolić nowe systemy AI.


Co musisz wiedzieć o AutoML...

Tomasz Krzywicki, Informatyk, Uniwersytet Warmińsko-Mazurski, Olsztyn, Polska

Co to jest AutoML i jak można z niego korzystać?

AutoML to rodzaj oprogramowania lub usług w chmurach obliczeniowych, które mają na celu automatyczne wytwarzanie modeli predykcyjnych rozwiązujących pewne problemy na

podstawie przekazanego zbioru danych. W celu skorzystania z narzędzi AutoML wystarczy jedynie dostęp do komputera wraz zainstalowanym odpowiednim oprogramowaniem lub dostęp do chmury obliczeniowej oferującej usługi AutoML. Należy również pamiętać o posiadaniu prawidłowo oznaczonego zbioru danych pod kątem rozwiązania zadanego problemu. Użycie tych narzędzi sprowadza się jedynie do wskazania danych oraz uruchomienia procesu poszukiwania optymalnych architektur modeli, który może być długotrwały. Po wykazaniu się odrobiną cierpliwości wytworzony model jest gotowy do wykorzystania w dowolnej formie, np. wdrożenia w innej usłudze serwerowej lub na dowolnym urządzeniu oraz analizy metryk predykcji przygotowanych za pomocą narzędzi AutoML.



mgr. inż. Tomasz Krzywicki

Jakie są dostępne typy Auto ML i czym się różnią?

Najbardziej oczywistym podziałem narzędzi AutoML jest środowisko, w którym wykonywane są obliczenia. W przypadku oprogramowania instalowanego na komputerach lokalnych,

obliczenia wykonywane są na nich samych. Analogicznie jest w przypadku usług w chmurach obliczeniowych. Warto zwrócić uwagę na to, że narzędzia AutoML uruchamiane na lokalnych komputerach mogą wymagać mocnych zasobów sprzętowych w postaci procesora graficznego oraz sensownej ilości pamięci operacyjnej - najlepiej minimum 16 GB. Ten najbardziej oczywisty podział związany jest również z kosztami tych narzędzi. Oprogramowanie AutoML instalowane na lokalnych komputerach w większości przypadków jest bezpłatne, natomiast usługi AutoML w chmurach obliczeniowych są obciążone kosztami.

Jaki jest koszt tych narzędzi ML?

Koszty usług AutoML zależą od czynników takich jak lokalizacja serwerowni, w której dokonywane są obliczenia, rodzaj i złożoność rozwiązywanego problemu, docelowe miejsce wdrożenia modelu oraz skala wykorzystanych zasobów obliczeniowych wraz czasem poświęconym na wytworzenie modelu. Przy planowaniu kosztów należy wziąć po uwagę również przestrzeń serwerową do przechowywania zbiorów danych. Niektóre z usług nie umożliwiają pobrania wytworzonych modeli na dysk komputera, a jedynie wdrożenie ich w innych usługach serwerowych co wiąże się z dodatkowymi kosztami. Przykładowo koszt jednej godziny pracy usługi AutoML uruchomionej w Ohio kosztuje 1\$ za jeden węzeł, czyli serwer. Chmury obliczeniowe często oferują jednak bezpłatny okres testowy, który w zupełności wystarcza na przetestowanie możliwości usług AutoML.

Jakie są główne wyzwania związane z dalszym rozwojem sztucznej inteligencji w najbliższej przyszłości?

Obecnie najpopularniejszą metodą tworzenia inteligentnych narzędzi jest uczenie maszynowe, czyli heurystyka polegająca na dopasowaniu funkcji matematycznych, lub grupy funkcji do pewnego zbioru danych celem uzyskania optymalnego rozwiązania w postaci predykcji bliskich oznaczeniom w zbiorze danych. W związku z tym sztuczna inteligencja na obecnym etapie posiada zdolność uczenia się pewnych wzorców, ale nie potrafi myśleć i wymaga

ciągłego monitorowania. Niektórzy badacze uważają, że sztuczna inteligencja wkrótce zbliży się do kresu rozwoju możliwości. Najwięksi gracze w świecie technologii jednak prowadzą już badania nad całkowicie nową formą tej dziedziny czerpiąc silne inspiracje z ludzkiego mózgu i z mojego punktu widzenia to jest największe wyzwanie na bliską i bardziej odległą przyszłość.

Powyższym materiałem stanowi streszczenie wystąpień najważniejszych prelegentów międzynarodowej konferencji „Sztuczna inteligencja w Okulistyce 2022” (eng. „AI in Ophthalmology 2022”), która odbyła się online w dniu 3 czerwca 2022 r. z inicjatywy Fundacji Wspierania Rozwoju Okulistyki „Okulistyka 21”. W trakcie konferencji podzielonej na 5 sesji eksperci z Europy, Azji i Ameryki zaprezentowali najnowsze osiągnięcia naukowe w zakresie wykorzystania sztucznej inteligencji w okulistyce i optometrii. Wydarzenie okazało się dużym sukcesem, o czym świadczyć może zainteresowanie uczestników, ponieważ na konferencję zarejestrowało się ponad 650 osób, z 19 krajów Europy, Azji, obu Ameryk oraz Afryki Południowej.

Konferencja została zrealizowana w ramach projektu Sztuczna inteligencja w okulistyce - konferencja naukowa współfinansowanego ze środków Ministerstwa Edukacji i Nauki.

Ponieważ współpraca i sieciowanie osób zainteresowanych przyszłymi zastosowaniami sztucznej inteligencji w okulistyce jest niezwykle ważne, postanowiłem rozpocząć tworzenie Międzynarodowego Towarzystwa Sztucznej Inteligencji w Okulistyce (International AI in Ophthalmology Society (IAIOph)). Zapraszamy wszystkich do dołączenia bezpośrednio na iaisoc.com lub poprzez e-mail: ae.grzybowski@gmail.com Wszystkie wykłady z 2022 AI in Ophthalmology Meeting są dostępne na aiinophthalmology.com.