

Sztuczna inteligencja i uczenie maszynowe w gerontologii klinicznej

Artificial intelligence and machine learning in clinical gerontology

Adam Bednorz

Szpital Geriatryczny im. Jana Pawła II w Katowicach

Instytut Psychologii, Akademia Humanitas, Sosnowiec

Streszczenie

Artykuł koncentruje się na zastosowaniu sztucznej inteligencji i uczenia maszynowego w gerontologii klinicznej w kontekście starzenia się społeczeństw i związanych z tym wyzwań. Przedstawiono przegląd piśmiennictwa dotyczącego ich wykorzystania w opiece zdrowotnej osób starszych oraz omówiono zarówno pozytywne aspekty, jak i zagrożenia związane z tymi technologiami. Historia rozwoju SI w medycynie sięga lat 40. i 50. XX wieku, gdy naukowcy dostrzegli jej potencjał w procesie diagnozowania. Współczesne techniki uczenia maszynowego, takie jak deep learning, umożliwiają wykrywanie i klasyfikację chorób oraz wspomaganie procesu diagnostycznego i podejmowania decyzji. Przedstawiono również wykorzystanie sztucznej inteligencji i uczenia maszynowego w dziedzinie geriatryki, gdzie te technologie pomagają w diagnozowaniu otępienia oraz identyfikowaniu innych zespołów geriatrycznych. Mimo licznych korzyści, istnieją również wątpliwości i zagrożenia związane z wykorzystaniem sztucznej inteligencji i uczenia maszynowego w gerontologii klinicznej, takie jak ochrona danych osobowych, odpowiedzialność za decyzje podejmowane przez systemy komputerowe oraz utrata aspektu ludzkiego w opiece zdrowotnej. Wnioski z przeglądu piśmiennictwa sugerują, że sztuczna inteligencja oraz uczenie maszynowe mają duży potencjał w poprawie opieki zdrowotnej osób starszych, jednak wymagają dalszych badań i oceny skuteczności w porównaniu z tradycyjnymi metodami statystycznymi. Przy odpowiednim rozwoju i wdrożeniu, technologie te mogą przyczynić się do lepszej diagnostyki, prognozowania i opieki nad starzejącym się społeczeństwem. (Gerontol Pol 2024; 32; 125-132) doi: 10.53139/GP.20243210

Słowa kluczowe: sztuczna inteligencja, uczenie maszynowe, gerontologia kliniczna, starzenie się społeczeństw, opieka zdrowotna osób starszych

Abstract

The article focuses on the application of artificial intelligence and machine learning in clinical gerontology in the context of aging and related challenges. A review is presented of the literature on their use in the health care of the elderly and discusses both the positive aspects and risks associated with these technologies. The history of AI development in medicine dates back to the 1940s and 1950s, when researchers recognized its potential in the diagnosis process. Modern machine learning techniques, such as deep learning, make it possible to detect and classify diseases and support the diagnostic and decision-making process. Also presented is the use of artificial intelligence and machine learning in the field of geriatrics, where these technologies help diagnose dementia and identifying other geriatric syndromes. Despite the numerous benefits, there are also concerns and risks associated with the use of artificial intelligence and machine learning in clinical gerontology, such as protection of personal data, liability for decisions made by computer systems and the loss of the human aspect in health care. Conclusions from the literature review suggest that artificial intelligence and machine learning have great potential in improving health care for the elderly, but require further research and evaluate their effectiveness compared to traditional statistical methods. With appropriate development and implementation, these technologies can contribute to better diagnosis, prognosis and care for the aging population. (Gerontol Pol 2024; 32; 125-132) doi: 10.53139/GP.20243210

Keywords: artificial intelligence, machine learning, clinical gerontology, aging, elderly health care

Wstęp

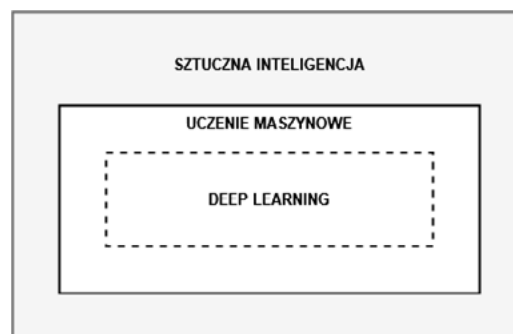
Starzenie się społeczeństw wiąże się z wielochorobowością pacjentów, a równocześnie zauważalnym niedoborem wykwalifikowanych pracowników oraz zmieniającymi się oczekiwaniami i wymaganiami osób starszych w zakresie odpowiedniej opieki zdrowotnej [1]. Sztuczna inteligencja oraz uczenie maszynowe to technologie, od których oczekuje się wsparcia w rozwiązaniu problemów, przed którymi stoi służba zdrowia. Jednocześnie część badaczy wskazuje na wątpliwości oraz zagrożenia, jakie są z nimi związane. Celem artykułu jest przegląd piśmiennictwa na temat zastosowania sztucznej inteligencji oraz uczenia maszynowego w gerontologii klinicznej.

Przeszłość i kontekst historyczny

Sztuczna inteligencja to dziedzina informatyki, która zajmuje się tworzeniem systemów komputerowych zdolnych do podejmowania decyzji i wykonywania zadań. W latach 40. i 50. XX wieku komputery i koncepcja sztucznej inteligencji (ang. *artificial intelligence* – AI) rozwijały się prawie równocześnie. Medycyna szybko dostrzegła jej potencjalną wartość [2,3]. W 1959 roku Keeve Brodman i współpracownicy twierdzili, że dokonywanie poprawnych diagnostycznych interpretacji objawów może być procesem logicznym i z tego względu może być przeprowadzane przez maszynę [4]. Jedenaście lat później, William B. Schwartz pisał, że nauka o komputerach prawdopodobnie wywrze swój główny wpływ poprzez rozszerzenie (a w niektórych przypadkach znaczne zastąpienie) funkcji intelektualnych lekarza [5]; przewidywał, że do roku 2000 komputery będą miały zupełnie nową rolę w medycynie, działając jako potężne rozszerzenie intelektu. Jednak już pod koniec lat 70. dwa główne podejścia do obliczeń w medycynie (systemy oparte na regułach i systemy dopasowujące lub rozpoznawania wzorców) nie odniosły w praktyce takiego sukcesu, jakiego po nich oczekiwano. Systemy oparte na regułach zostały zbudowane na hipotezie, że wiedza ekspercka składa się z wielu niezależnych, specyficznych dla danej sytuacji reguł i że komputery mogą symulować rozumowanie eksperta poprzez łączenie tych reguł w łańcuchy dedukcji. Strategie próbowały więc dopasować charakterystykę kliniczną pacjenta do banku „zapisanych profili”, traktowanych jako „skrypty choroby” (czyli wyniki badań w danej chorobie) [6]. Więcej wysiłku włożono także w zrozumienie samego procesu podejmowania decyzji klinicznych [7].

Teraźniejszość i rozwój data science

Uczenie maszynowe jest dziedziną sztucznej inteligencji, która koncentruje się na opracowywaniu algorytmów, które „uczą się” na podstawie dostępnych danych, aby identyfikować wzorce i podejmować decyzje. Główną ideą uczenia maszynowego jest zdolność komputerów do adaptacji i doskonalenia swojego działania na podstawie analizy danych. Proces ten jest oparty na budowaniu modeli statystycznych i wykorzystywaniu metod takich jak uczenie nadzorowane i nienadzorowane, uczenie głębokie (*deep learning*), czy uczenie ze wzmocnieniem (patrz rycina 1). W uczeniu maszynowym dostarczane są dane wejściowe (zmienna objaśniająca) razem ze spodziewanymi wynikami (zmienna objaśniana). Rola oprogramowania polega na poznaniu zasad, które generują określone rezultaty poszczególnych danych wejściowych (uczenie nadzorowane) [8]. Algorytm uczy się związku między danymi wejściowymi a odpowiadającymi im zmiennymi wyjściowymi (diagnoza kliniczna), natomiast po zakończeniu procesu uczenia się, algorytm może dawać klasyfikację lub predykcję po wprowadzeniu nowych danych wejściowych [8].



Rycina 1. Sztuczna inteligencja oraz uczenie maszynowe. Opracowanie własne

Figure 1. Artificial intelligence and machine learning. Own elaboration

Funkcjonowanie współczesnych systemów AI jest uzależnione od zamieszczonych w nich informacji (danych). Dane będące „nową ropą” (lub złotem) współczesnej gospodarki, prowadzą do zjawiska datafikacji naszego codziennego życia, domów, zdrowia i (starzejących się) organizmów [9-11]. Postęp w dziedzinie nauki o danych nie jest wyłącznie kwestią zwiększenia wydajności, szybkości oraz pamięci masowej. Świat nauki potrzebował czegoś więcej niż tylko danych, potrzebował sposobów na ich identyfikację oraz przetwarzanie. Gdy sieci neuronowe (jeden z algorytmów AI) stały się bardziej zaawansowane pojawiły się większe możliwości w zakresie wykorzystania danych do identyfikacji wcze-

śniej nieopisywanych relacji między zmiennymi. Oprócz systemów ukierunkowanych do zbierania i kodyfikowania danych, nowe formy technologii zaczęły wykorzystywać dane, które są zarówno generowane przez ludzi, jak i przez maszyny [12].

Uczenie maszynowe w geriatricii – szanse

Zastosowanie technologii AI w systemach opieki zdrowotnej stwarza szansę na zmniejszenie śmiertelności i błędów ludzkich, obniżenie kosztów medycznych, a także zmniejszenie zależności od usług społecznych [13,14]. Według ekspertów, AI ma wywrzeć głęboki wpływ na opiekę zdrowotną i badania nad starzeniem się [15]. Szacuje się, że AI w opiece zdrowotnej wygenerowała 6,9 mld USD w 2021 r. oraz ma osiągnąć 67,4 mld USD do 2027 r. i jest jednym z najbardziej lukratywnych i intensywnych inwestycyjnie obszarów wdrażania AI [16].

Algorytmy uczenia maszynowego (ML) są używane do klasyfikacji lub przewidywania, co przekłada się na zastosowania kliniczne związane z diagnozą i prognozą [17]. Z tego względu wykorzystanie ML oraz *deep learning* (bardziej zaawansowana forma ML) może przyczynić się do lepszego wykrywania objawów i klasyfikacji chorób, ma szansę usprawnić proces diagnostyczny i decyzyjny oraz zmniejszyć koszty opieki medycznej [18]. *Deep learning* zostało wykorzystane do klinicznego wspomaganie decyzji w diagnostyce różnych chorób ze względu na to, że skutecznie radzi sobie z niestrukturalnymi i niejednoznacznymi danymi, w tym w retinopatii cukrzycowej, obrzęku plamki żółtej, raku skóry, duszności u starszych pacjentów [19-23]. Programy AI okazały

się przydatne w identyfikacji ognisk chorób zakaźnych mogących mieć wpływ na zdrowie populacji, w łączeniu danych klinicznych, genetycznych oraz laboratoryjnych w celu rozpoznania rzadkich oraz powszechnych schorzeń, które w przeciwnym razie mogłyby zostać przeoczone. Wskazuje się również na użyteczność AI w operacjach biznesowych szpitala [12]. Uczenie maszynowe zostało również wykorzystane do predykcji przyszłego zapotrzebowania na tlen u pacjentów z infekcją Covid-19 przy użyciu danych wejściowych dotyczących parametrów życiowych, danych laboratoryjnych i zdjęć rentgenowskich klatki piersiowej [24]. Systematyczny przegląd wskazuje, że narzędzia ML mogą odegrać istotną rolę w ponownym zdefiniowaniu diagnozy przy użyciu wtórnego źródła danych, ułatwiając w ten sposób wczesną identyfikację choroby, lepsze zrozumienie jej postępu, optymalizację dawek leków/leczenia i odkrycie nowych metod leczenia schorzeń występujących w geriatricii [25].

Diagnozy dotyczące zdrowia psychicznego mają charakter kliniczny w porównaniu z innymi dziedzinami medycyny, gdzie bazuje się na ocenach ilościowych lub badaniach laboratoryjnych. ML wykorzystano w badaniach nad otępieniem, uwzględniając badania neuroobrazowe lub biomarkery [26]. Chociaż obecnie większość badań ogranicza się do diagnozowania otępienia, to pojawiają się analizy związane z identyfikacją innych zespołów geriatrycznych lub wzorców objawów behawioralnych w otępieniu. Podejścia ML wymagają kolejnych badań w diagnozowaniu uzależnień i problemów zdrowia psychicznego u starszych dorosłych [25]. Wyzwaniem diagnostycznym w geriatricii ciągle jest identyfikacja majaczenia. Oprócz zwalidowanych narzędzi oce-

Tabela I. Spektrum sztucznej inteligencji (AI) w medycynie. Opracowanie własne na podstawie piśmiennictwa [12]

Table I. Spectrum of artificial intelligence (AI) in medicine. Own elaboration based on literature [12]

Teraźniejszość				
Służba zdrowia	Wyniki badań klinicznych	Wyszukiwanie informacji medycznych	Analiza obrazów	Kwestie organizacyjne
<ul style="list-style-type: none"> – identyfikacja ognisk choroby poprzez monitorowanie ruchu w Internecie, – śledzenie przypadków, wyników i związków z czynnikami lokalnymi, 	<ul style="list-style-type: none"> – wspomaganie decyzji w projektowaniu badań klinicznych, – identyfikacja pacjentów, – monitorowanie wyników i skutków ubocznych. 	<ul style="list-style-type: none"> – korzystanie z wielu źródeł informacji o pacjencie w celu postawienia diagnozy, – wyszukiwarki internetowe, – wsparcie decyzyjne elektronicznych danych medycznych. 	<ul style="list-style-type: none"> – np. tomografii komputerowej, RTG 	<ul style="list-style-type: none"> – planowanie sal operacyjnych, – fakturowanie i windykacja, – monitorowanie pacjentów.
Przyszłość				
<ul style="list-style-type: none"> – zapewnienie coachingu w czasie rzeczywistym na temat pytań, które należy zadać w wywiadzie medycznym lub objawów fizykalnych, które należy sprawdzić, – słuchanie i pisanie statusów klinicznych w trakcie spotkania, – pełnienie funkcji nauczyciela i asesora w edukacji medycznej, – tworzenie realistycznych „symulatorów” dla prostych i złożonych spotkań z pacjentem 				

niających funkcje poznawcze pacjenta, przydatny może być model, który przy użyciu retrospektywnych danych z EMR (ang. *electronic medical records* – elektroniczne dane medyczne) identyfikuje majączenie (wiek, płeć, wskaźnik współchorobowości Elixhausera, ekspozycja na leki i rozpoznania zostały wykorzystane jako cechy) [27]. W jednym z badań została opracowana skala słów kluczowych do półautomatycznego wykrywania majączenia przy użyciu przetwarzania języka naturalnego notatek klinicznych z elektronicznej dokumentacji medycznej [28]. ML znalazło również zastosowanie w identyfikacji zęczenia się nad osobami starszymi [29]. Podsumowanie możliwości AI prezentuje tabela I.

Techniki ML w porównaniu do tradycyjnych metod statystycznych stwarzają większe możliwości w wykrywaniu złożonych nieliniowych relacji, wysokowymiarowych interakcji między cechami oraz pozwalają na analizę dużych ilości danych. W obszarze geriatry niewiele badań porównywało jednak podejścia ML z dotychczas wykorzystywanymi metodami statystycznymi. W badaniu Park i wsp. stwierdzono, że skuteczność predykcyjna technik ML (las losowy i maszyny wektorów nośnych) była lepsza w porównaniu z regresją logistyczną w przewidywaniu otępienia alzheimerowskiego [30]. W badaniu Forda i wsp. zaobserwowano podobną skuteczność predykcyjną technik ML (random forest i naiwny klasyfikator Bayesa) oraz regresji logistycznej w przewidywaniu otępienia [31]. Ten obszar wymaga jednak kolejnych weryfikacji empirycznych.

Uczenie maszynowe w geriatryi – ograniczenia

Wykorzystanie algorytmów ML w diagnostyce nasywa też wątpliwości. Wynik musi być adekwatny dla wszystkich badanych pacjentów, a nie tylko tych, którzy są podobni do grupy pacjentów (z określonymi cechami i wynikami), na których algorytm był „uczony”. W związku z tym pojawia się pytanie, czy takie algorytmy powinny być stosowane w obszarze zdrowia publicznego (tj. wykorzystanie ograniczonych zasobów) podczas formułowania zaleceń dotyczących diagnostyki lub leczenia (jako wsparcie procesu decyzyjnego). Takie wątpliwości mogą pojawiać się u pracowników służby zdrowia [12].

Obawy dotyczące AI są obecnie większe niż kiedykolwiek wcześniej, co wiąże się z potocznym wyrażeniem „*śmieci na wejściu, śmieci na wyjściu*” [32], które jest używane w odniesieniu do słabych wyników modeli uczenia maszynowego, gdy dane na podstawie których się uczą są niskiej jakości, co wskazuje na znaczenie praktyk gromadzenia, a także eksploracji danych. „*Ob-*

ciążenia na wejściu, obciążenia na wyjściu” to kolejne hasło używane do podkreślenia obaw związanych z faktem, że modele uczenia maszynowego napędzane danymi dokonują wnioskowania poprzez znajdowanie „wzorców” z danych, które analizują (jeśli tendencyjne informacje trafią do algorytmu wynik powieli tę stronniczość) [33]. Źródła stronniczości w systemach AI pozostają wielorakie. Istnieją trzy punkty w procesie uczenia maszynowego, w których może powstać stronniczość: 1) podczas zbierania danych i wstępnego przetwarzania; 2) podczas wyboru i tworzenia modeli; 3) podczas wdrażania wyników [34]. Ostatnie analizy pokazują, że narzędzia używane do konstruowania algorytmów mogą mieć tendencję do wykluczania zainteresowań i wartości osób starszych, co będzie wzmacniać już istniejący ageizm [35]. W najnowszym dokumencie Światowej Organizacji Zdrowia (WHO) zatytułowanym „*Ageism in artificial intelligence for health*” („Ageizm w sztucznej inteligencji dla zdrowia”) zbadano wykorzystanie sztucznej inteligencji w medycynie oraz zdrowiu publicznym w odniesieniu do osób starszych, w tym warunki, w których AI może nasilić lub wprowadzić nowe formy ageizmu [36]. Zaproponowano w nim osiem czynników mających na celu zagwarantowanie, że AI wdrażana w służbie zdrowia jest rozwijana w sposób sprawiedliwy: projektowanie partycypacyjne, różnorodność wiekowa w zespołach zajmujących się nauką o danych, gromadzenie danych uwzględniające wiek, inwestycje w infrastrukturę cyfrową oraz umiejętności cyfrowe osób starszych i ich opiekunów, prawa osób starszych, ramy zarządzania w celu wzmocnienia pozycji osób starszych, zwiększenie liczby badań i solidne procesy etyczne. Wspomniane wytyczne są punktem wyjścia do opracowania etycznego i sprawiedliwego podejścia do budowania AI dla zdrowia. Jednak ich wdrożenie do szerszych debat na temat stronniczości w AI, jak również praktyczna integracja z przepływami pracy twórców AI, będą wymagały wspólnych wysiłków nie tylko całej społeczności badawczej zajmującej się starzeniem się, ale także przedstawicieli innych nauk [1].

Pomijając powyżej rozpatrywane aspekty, w zgromadzonych danych może brakować ważnych informacji (np. dawki konkretnego leku). Dane mogą zostać pominięte ze względu na brak rutynowego zapisu. Niektóre stany chorobowe mogą nie być rutynowo rejestrowane w opiece klinicznej (np. niepełnosprawność fizyczna) lub być rejestrowane, ale w stopniu niewystarczającym (np. otępienie); pominięcie lub niedostateczne zliczenie takich informacji w badaniach może prowadzić do nieprawidłowych konkluzji. Ponadto, rutynowo gromadzone dane mogą zawierać informacje istotne dla celu klinicznego lub administracyjnego, ale nie badaw-

czego [26]. W tym obszarze istnieją również wyzwania związane z charakterem danych, głównie ze względu na dużą liczebność prób, objętość danych uczestników oraz ich niekompletność lub niespójność [37]. Odpowiednia reprezentacja starszej populacji w zbiorach danych wykorzystywanych do szkolenia modeli AI może być zakłócona przez źródła danych, z których korzysta (np. smartfony, aplikacje medyczne, zdrowotne) oraz inne urządzenia IoT (*Internet of Things*), które generują szczegółowe dzienniki czynności związanych ze zdrowiem. Jednym z wyzwań związanych z tymi zbiorami danych jest ich ograniczenie do zdrowych, dobrze sytuowanych i zamożnych starszych dorosłych, którzy mają do nich dostęp oraz wiedzę (czasami odpowiednie wsparcie, aby korzystać z tego typu urządzeń) [11,35]. Klasa, płeć i status ekonomiczny odgrywają decydującą rolę w dystrybucji w dostępie do technologii cyfrowych, a zatem generowane dane mogą być wypaczone, dodatkowo marginalizując osoby już zagrożone wykluczeniem. Stąd pojawia się istotne pytanie: co się dzieje, gdy zbiory danych wdrażane na potrzeby medycznej AI są niereprezentatywne, niekompletne lub niskiej jakości? [1,36].

Stosowanie AI oraz uczenia maszynowego zostało zaakceptowane w interpretacji obrazów medycznych, takich jak zwykle radiogramy, tomografia komputerowa i rezonans magnetyczny, obrazy skóry oraz zdjęcia siatkówki [12,39]. W przypadku tych zastosowań AI i uczenie maszynowe okazały się pomocne w opiece zdrowotnej poprzez oznaczanie aspektów obrazów, które odbiegają od normy. Wiąże się to jednak z powrotem do klasycznego pytania: co jest normą? Pytanie to pokazuje jedną ze słabości wykorzystania AI i uczenia maszynowego w medycynie w takiej formie, w jakiej jest ona dziś w dużej mierze stosowana [12]. Należy zaznaczyć, że dowody na skuteczne wdrożenie ML i *deep learning* w opiekę kliniczną pozostają ciągle niewystarczające, generując wątpliwości natury etycznej dotyczące bezpieczeństwa oraz jakości danych; wskazuje się na niewystarczającą ilość analiz dotyczących wyników leczenia pacjenta i kosztów opieki oraz procedur dotyczących zarządzania danymi [40-42]. Wykorzystanie danych do rozwoju AI dla zdrowia jest złożone, ponieważ zwiększone wykorzystanie i udostępnianie danych zdrowotnych może naruszać prywatność oraz prawo do ochrony danych [1]. Dane zdrowotne to dane wrażliwe, które można pozyskać na wiele sposobów ze standaryzowanych badań klinicznych lub z infrastruktury publicznej służby zdrowia, ale można je również wywnioskować pośrednio np. z przeglądania stron internetowych lub korzystania z aplikacji i urządzeń medycznych służących ochronie zdrowia. Ochrona prywatności danych zdro-

wotnych stanowi problem zarówno dla osób fizycznych i pracowników medycznych, jak twórców systemów AI dla służby zdrowia. Wskazuje się, że niektóre grupy społeczno-demograficzne, takie jak dzieci, osoby starsze, osoby z chorobami przewlekłymi lub niepełnosprawnością, o niższym statusie społeczno-ekonomicznym mogą być bardziej narażone na brak możliwości korzystania z prawa do prywatności i ochrony danych [1].

Właściwa reprezentacja populacji starszych dorosłych w różnych zbiorach danych i podejściach do danych została już wskazana jako jedno z wyzwań dla systemów AI [35,43]. Dane (a także dane, których brakuje), kształtują późniejsze możliwości ich wykorzystania [43]. W raporcie MIT AGELAB stwierdzono, że pomimo stosunkowo optymistycznych perspektyw dotyczących możliwości i przyjęcia systemów AI, eksperci, z którymi przeprowadzono wywiady na temat korzyści płynących z AI dla starzejącej się populacji byli najmniej pewni zdolności AI do zapewnienia bardziej sprawiedliwego dostępu do opieki zdrowotnej [44]. Wskazywali, że każdy system, który zastępuje człowieka algorytmem, ma potencjał podejmowania błędnych decyzji, które mogą zagrażać ludzkiemu zdrowiu [44]. Coraz częściej wskazuje się, że AI w medycynie jest postrzegana zbyt pozytywnie i optymistycznie, co do możliwości tej technologii w zapobieganiu lub leczeniu chorób. W rzeczywistości istnieje tylko kilka certyfikowanych i jeszcze mniej zwalidowanych klinicznie produktów dostępnych w warunkach klinicznych. Większość szumu wokół medycznych zastosowań AI dotyczy przypadków technologii w eksploracyjnych fazach rozwoju (*proof of concept*), które identyfikują potencjalnie wartościowe przypadki użycia, ale które nie zostały jeszcze zweryfikowane w próbach klinicznego wykorzystania [45]. Stąd wielu ekspertów sugeruje ostrożność w szacowaniu rzeczywistych efektów tej technologii na przyszłość opieki zdrowotnej nad starszymi dorosłymi [36].

Podsumowanie – sztuczna inteligencja w przyszłości

Wydaje się, że możliwość dzielenia się danymi i wykorzystania ich do szybkiego generowania wiedzy będzie miała transformujący wpływ na poprawę pracy służby zdrowia również w obszarze geriatric. Jeśli AI i algorytmy uczenia maszynowego mogą być zredukowane do użytecznych klinicznie „aplikacji”, czy będą one w stanie przebrnąć przez góry danych klinicznych, genomicznych, metabolicznych i środowiskowych, aby pomóc w precyzyjnej diagnozie? Czy AI i uczenie maszynowe może stać się osobistym skrybą lekarza, pozwalając zaoszczędzić czas poświęcony na dokumen-

tację na dodatkowy czas spędzony z pacjentem? [12]. AI i uczenie maszynowe mają potencjał, aby uprościć i przyspieszyć badania kliniczne poprzez zarówno bardziej efektywną rekrutację i dopasowanie uczestników badania, jak i bardziej kompleksową analizę danych. Ponadto istnieje możliwość stworzenia syntetycznych grup kontrolnych poprzez dopasowanie danych historycznych do docelowych kryteriów danego badania. Wydaje się możliwe, że sztuczna inteligencja mogłaby generować „syntetycznych pacjentów” w celu symulacji wyników diagnostycznych lub terapeutycznych. Sztuczna inteligencja i uczenie maszynowe mogą również być wykorzystywane do lepszego przewidywania i zrozumienia możliwych zdarzeń niepożądanych [12].

Technologie AI z pewnością wpłyną na to, jak będziemy myśleć o zdrowiu, chorobie i starzeniu się. Otwarte pozostaje pytanie, jak wpleść ludzkie wartości w algorytmy AI i uczenia maszynowego, tak aby uzyskane wyniki odzwierciedlały rzeczywiste problemy, z którymi borykają się pracownicy służby zdrowia? Jakimi kwestiami muszą zająć się organy regulacyjne, w jaki sposób klasyczne podejścia do wnioskowania statystycznego należy zmodyfikować, w przypadku interwencji które opierają się na AI i uczeniu maszynowym? To tylko kilka problemów, przed którymi stoimy. Inny dylemat to, czy aplikacje mogą zachęcać do zadawania kluczowych pytań które mogą pomóc w diagnozie różnicowej? Czy można przechrzyć algorytmy AI i uczenia maszynowego? W wielu obszarach dokonał się postęp,

ale czy jest on wystarczająco dobry? Chociaż innowacje techniczne i technologiczne wywołują daleko idące konsekwencje tego, jak postrzegamy starzenie się, to rzadko skupiają się na specyficznych relacjach między technologią a władzą lub na związku między technologią a ageizmem. Odpowiednie i intersekcjonalne podejście etyczne jest potrzebne w projektowaniu oraz rozwoju AI, a także w tworzeniu polityki, aby systemy algorytmiczne nie wykluczały i nie marginalizowały grup starszych dorosłych poprzez zaniedbywanie społecznych determinantów zdrowia. Obecnie podejmowane są międzynarodowe wysiłki w zakresie regulacji AI, opracowywane są wytyczne oraz zalecenia polityczne dotyczące aspektów sprawiedliwości, odpowiedzialności, przejrzystości w celu spełnienia kryteriów wiarygodności systemów AI. Wyniki i wdrożenie tych regulacji, szczególnie w sektorze opieki zdrowotnej, będą stanowiły dodatkowe wyzwania, które dopiero przed nami [1]. W związku z różnorodnością modeli uczenia maszynowego i ich zastosowaniem w dziedzinie zdrowia, konieczne jest ich dokładniejsze empiryczne zbadanie. Ten krótki przegląd nie wyczerpuje tematu i może służyć jedynie jako wskazówka w kierunku przyszłych badań lub krytycznego myślenia na temat wykorzystania systemów AI w służbie zdrowia i sposobu, w jaki może to wpływać na osoby starsze.

Konflikt interesów / Conflict of interest
Brak / None

Piśmiennictwo / References

1. Stypińska J, Franke A. AI revolution in healthcare and medicine and the (re-)emergence of inequalities and disadvantages for ageing population. *Front Sociol.* 2023 Jan 23;7:1038854.
2. Turing AM. Computing machinery and intelligence. *Mind* 1950;59:433-60.
3. Yu K-H, Beam AL, Kohane IS. Artificial intelligence in healthcare. *Nat Biomed Eng* 2018;2:719-31.
4. Brodman K, Van Woerkom AJ, Erdmann AJ Jr, Goldstein LS. Interpretation of symptoms with a data-processing machine. *AMA Arch Intern Med* 1959;103:776-82.
4. Schwartz WB. Medicine and the computer — the promise and problems of change. *N Engl J Med* 1970;283:1257-64.
5. Bowen JL. Educational strategies to promote clinical diagnostic reasoning. *N Engl J Med* 2006;355:2217-25.
6. Pauker SG, Gorry GA, Kassirer JP, Schwartz WB. Towards the simulation of clinical cognition: taking a present illness by computer. *Am J Med* 1976;60:981-96.
7. Muller AC, Guido. *Machine learning, Python i data science.* Wydawnictwo Helion, Gliwice 2021.
8. Haug CJ, Drazen JM. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. *N Engl J Med.* 2023;388(13):1201-8. doi:10.1056/nejmra2302038.
9. Sadowski J. *Too Smart: How Digital Capitalism is Extracting Data, Controlling Our Lives, and Taking Over the World.* MA: MIT Press. Cambridge 2020.
10. Ruckenstein M., Schüll ND. The datafication of health. *Ann. Rev. Anthropol* 2017; 46, 261-78.

11. Katz S, Marshall BL. Tracked and fit: FitBits, brain games, and the quantified aging body. *J Aging Stud.* 2018 Jun;45:63-68.
12. Haug CJ, Drazen JM. Artificial Intelligence and Machine Learning in Clinical Medicine, 2023. *N Engl J Med.* 2023;388(13):1201-1208.
13. Davenport T, Kalakota R. The potential for artificial intelligence in healthcare. *Future Healthc J.* 2019 Jun;6(2):94-98.
14. Mukaetova-Ladinska EB, Harwood T, Maltby J. Artificial Intelligence in the healthcare of older people. *Arch. Psychiatr. Mental Health* 2020; 4, 007–013.
15. Zhavoronkov A, Mamoshina P, Vanhaelen Q, et al. Artificial intelligence for aging and longevity research: Recent advances and perspectives. *Ageing Res Rev.* 2019 Jan;49:49-66.
16. Markets and Markets. Artificial Intelligence in Healthcare Market. Available online at: https://www.marketsandmarkets.com/Market-Reports/artificial-intelligence-healthcare-market-54679303.html?gclid=Cj0KCQjw39uYBhCLARIsAD_SzMTCiGIsmwIi-Nr2af8teraiLzhODU8qzYGQp05-9ktbwuGGkXpO58aAit_EALw_wcB (accessed 2021; October 10, 2022).
17. Noorbakhsh-Sabet N, Zand R, Zhang Y, et al. Artificial Intelligence Transforms the Future of Health Care. *Am J Med.* 2019 Jul;132(7):795-801.
18. Kumar Y, Koul A, Singla R, et al. Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. *J Ambient Intell Humaniz Comput.* 2022 Jan 13:1-28.
19. Srinivasu PN, Ahmed S, Alhumam A, et al. An AW-HARIS based automated segmentation of human liver using CT images. *Computers, Materials and Continua* 2021 69:3303-19.
20. Voets M, Møllersen K, Bongo LA. Reproduction study using public data of: Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *PLoS One* 2019 14:e0217541.
21. Gulshan V, Peng L, Coram M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *J Am Med Assoc* 2016 316:2402.
22. Esteva A, Kuprel B, Novoa RA, et al. Corrigendum: Dermatologist-level classification of skin cancer with deep neural networks. *Nature.* 2017 Jun 28;546(7660):686.
23. Liong-Rung L, Hung-Wen C, Ming-Yuan H, et al. Using Artificial Intelligence to Establish Chest X-Ray Image Recognition Model to Assist Crucial Diagnosis in Elder Patients With Dyspnea. *Front Med (Lausanne).* 2022 Jun 3;9:893208.
24. Dayan I, Roth HR, Zhong A, et al. Federated learning for predicting clinical outcomes in patients with COVID-19. *Nat Med.* 2021 Oct;27(10):1735-43.
25. Chowdhury M, Cervantes EG, Chan WY, et al. Use of Machine Learning and Artificial Intelligence Methods in Geriatric Mental Health Research Involving Electronic Health Record or Administrative Claims Data: A Systematic Review. *Front Psychiatry.* 2021 Sep 20;12:738466.
26. Todd OM, Burton JK, Dodds RM, et al. New Horizons in the use of routine data for ageing research. *Age Ageing.* 2020 Aug 24;49(5):716-22.
27. Kim JH, Hua M, Whittington RA, et al. A machine learning approach to identifying delirium from electronic health records. *JAMIA Open.* 2022 May 24;5(2):ooac042.
28. Chen L, Li N, Zheng Y, et al. A novel semiautomatic Chinese keywords instrument screening delirium based on electronic medical records. *BMC Geriatr.* 2022 Oct 4;22(1):779.
29. Rosen T, Zhang Y, Bao Y, et al. Can artificial intelligence help identify elder abuse and neglect? *J Elder Abuse Negl.* 2020 Jan-Feb;32(1):97-103.
30. Park JH, Cho HE, Kim JH, et al. Machine learning prediction of incidence of Alzheimer's disease using large-scale administrative health data. *NPJ Digit Med.* 2020 Mar 26;3:46.
31. Ford E, Sheppard J, Oliver S, et al. Automated detection of patients with dementia whose symptoms have been identified in primary care but have no formal diagnosis: a retrospective case-control study using electronic primary care records. *BMJ Open.* 2021 Jan 22;11(1):e039248.
32. Mittelstadt BD, Allo P, Taddeo M, et al. The ethics of algorithms: mapping the debate. *Big Data Soc.* 2016;3,1-21.
33. Wu H, Wang M, Sylolypavan A, et al. "Quantifying health inequalities induced by data and AI models," in 31st International Joint Conference on Artificial Intelligence (Vienna: IJCA;), 2022; 5192-8.

34. de Alford G, Hayden SK, et al. Reducing age bias in machine learning: An algorithmic approach. *SMU Data Sci Rev* 2020; 3, 1-20.
35. Rosales A., Fernández-Ardčvol M. Structural ageism in big data approaches. *Nordicom Rev* 2019; 40, 51–64.
36. WHO. Ageism in AI for Health: WHO Policy Brief. Geneva 2022.
37. Latif J, Xiao C, Tu S, et al. Implementation and use of disease diagnosis systems for electronic medical records based on machine learning: a complete review. *IEEE Access*. 2020; 8:150489-513.
38. Chu CH, Nyrup R, Leslie K, et al. Digital Ageism: Challenges and Opportunities in Artificial Intelligence for Older Adults. *Gerontologist*. 2022 Aug 12;62(7):947-55.
39. Lee P, Bubeck S, Petro J. Benefits, Limits, and Risks of GPT-4 as an AI Chatbot for Medicine. *N Engl J Med*. 2023 Mar 30;388(13):1233-9.
40. Car J, Sheikh A, Wicks P, Williams MS. Beyond the hype of big data and artificial intelligence: Building foundations for knowledge and wisdom. *BMC Med*. 2019;17:143.doi: 10.1186/s12916-019-1382-x.
41. Wang S, Bolling K, Mao W, et al. Technology to Support Aging in Place: Older Adults' Perspectives. *Healthcare (Basel)*.2019;7.
42. Wangmo T, Lipps M, Kressig RW, et al. Ethical concerns with the use of intelligent assistive technology: findings from a qualitative study with professional stakeholders. *BMC Med Ethics*. 2019;20:98.
43. Sourbati M., Behrendt F. Smart Mobility, Age and Data Justice. *New Media and Society* February 2020;23(6):10.1177/1461444820902682.
44. MIT AGELAB. AI and Longevity. MA Cambridge 2021.
45. Madai VI, Higgins DC. Artificial intelligence in healthcare: Lost in translation? *ArXiv* 2021;1-19.