

Kinga Belowska-Bień¹, Bartosz Bień²

Wykorzystanie technik sztucznej inteligencji i uczenia maszynowego we wspomaganii diagnostyki i leczenia chorób neurologicznych

Application of artificial intelligence and machine learning techniques in supporting the diagnosis and treatment of neurological diseases

¹ Katedra i Zakład Farmakologii, Uniwersytet Medyczny we Wrocławiu, Wrocław, Polska² SPIN Software, Wrocław, Polska

Adres do korespondencji: Dr n. med. Kinga Belowska-Bień, Katedra i Zakład Farmakologii, Uniwersytet Medyczny we Wrocławiu, ul. J. Mikulicza-Radeckiego 2, 50-345 Wrocław, e-mail: kinga.belowska-bien@umed.wroc.pl

Streszczenie

W pierwszych dwóch dekadach XXI wieku dokonał się ogromny postęp w zakresie sztucznej inteligencji i uczenia maszynowego, a techniki te trafiły do codziennego użytku – w smartfonach, wyszukiwarkach internetowych, cyfrowych asystentach klienta, systemach sterowania ruchem, a także urządzeniach biomedycznych. Celem pracy jest przedstawienie możliwości wykorzystania technik sztucznej inteligencji i uczenia maszynowego we wspomaganii diagnostyki i leczenia chorób neurologicznych wraz z omówieniem wybranych zastosowań na podstawie aktualnej literatury światowej. W artykule zaprezentowano współczesne definicje sztucznej inteligencji i uczenia maszynowego. Następnie dokonano przeglądu najważniejszych technik inteligentnego przetwarzania danych: metod przeszukiwania, logiki matematycznej, metod probabilistycznych, klasyfikatorów oraz sztucznych sieci neuronowych, w tym sieci głębokich i konwolucyjnych. Określono obszary zastosowania omawianych technik w medycynie, takie jak diagnostyka schorzeń, wspomaganie leczenia, monitorowanie stanu zdrowia i predykcja jego zmian. Przedstawiono rolę sztucznej inteligencji i uczenia maszynowego w neurologii wraz z przykładami zastosowań diagnostycznych opartych na danych anatomicznych, morfologicznych i dotyczących łączności funkcjonalnej mózgu. Zaprezentowano też przykładowe zastosowania technik inteligentnych we wspomaganii leczenia (także operacyjnego) chorób układu nerwowego. Omówiono rolę urządzeń inteligentnego otoczenia monitorujących stan zdrowia pacjentów z przewlekłymi chorobami neurologicznymi, opisano wybrane projekty wykorzystujące techniki inteligentne do wspomaganii wczesnej detekcji symptomów chorób neurodegeneracyjnych. W podsumowaniu ukazano potencjał omówionych technik, jak również związane z nimi trudności i zagrożenia. Wskazano na potencjalną synergię systemów inteligentnych z działaniami personelu medycznego, poprawiającą bezpieczeństwo i jakość życia pacjentów z ostrymi i przewlekłymi chorobami neurologicznymi.

Słowa kluczowe: sztuczna inteligencja, uczenie maszynowe, neurologia, inteligentne otoczenie kliniczne

Abstract

The first two decades of the 21st century have seen great advances in artificial intelligence and machine learning. The techniques have found their way into everyday life, for example in smartphones, search engines, digital customer assistants, motion control systems, and biomedical devices. The aims of this paper are to outline the possibilities for using artificial intelligence and machine learning techniques in supporting the diagnosis and treatment of neurological diseases, and to discuss selected applications of these techniques based on the most recent published reports. First, contemporary definitions of artificial intelligence and machine learning are presented. This is followed by a review of the most important techniques for intelligent data processing: search methods, mathematical logic, probabilistic methods, classifiers, and artificial neural networks (including deep and convolutional networks). Areas of application of these techniques in medicine are identified, including disease diagnosis and support of treatment as well as monitoring and prediction of changes in health status. The role of artificial intelligence and machine learning in neuroscience is presented, together with examples of diagnostic applications based on anatomical, morphological and functional brain connectivity data. Sample applications of intelligent techniques in supporting the treatment (including surgical management) of nervous system diseases are also described. Ambient smart devices monitoring the health status of patients with chronic neurological conditions are discussed, and selected projects based on smart techniques to support early detection of symptoms of neurodegenerative disorders are described. The conclusions highlight the potential of the techniques, as well as the challenges and risks associated with them. A possible synergy between intelligent systems and actions taken by medical staff is outlined as a way to improve the safety and quality of life of patients with acute and chronic neurological diseases.

Keywords: artificial intelligence, machine learning, neurology, ambient clinical intelligence

SZTUCZNA INTELIGENCJA I UCZENIE MASZYNOWE

Definicja sztucznej inteligencji

Interpretacje pojęcia sztucznej inteligencji (*artificial intelligence*, AI) różnią się w zależności od kontekstu. Za najbardziej uogólnioną definicję można uznać „możliwość wykonywania przez maszyny czynności, które zwykle wymagają ludzkiej inteligencji” (Allen, 2020), takich jak rozpoznawanie wzorców, percepcja wzrokowa, podejmowanie decyzji na podstawie przesłanek czy posługiwanie się językiem naturalnym.

Dążenie do stworzenia maszyn wykazujących ludzkie cechy intelektualne towarzyszy człowiekowi od tysiącleci (Nilsson, 2010). W *Iliadzie* mowa jest o poruszających się, rozumnych i mówiących posągach w służbie Hefajstosa, Leonardo da Vinci stworzył zaawansowane schematy mechanicznego rycerza, a z epoki wiktoriańskiej pochodzi wiele historii o „automatonach” wspierających swoich konstruktorów. Starania kontynuowane są po dziś dzień, przy czym nieocenionym pomocnikiem człowieka częściej niż czelkoksztaltny robot bywa obecnie aplikacja uruchomiona na niewielkim urządzeniu mobilnym. Praktyczny cel pozostaje jednak bez zmian – jest nim wsparcie człowieka w sytuacjach wymagających interpretacji faktów, wnioskowania na podstawie przesłanek czy doświadczenia eksperckiego.

Z myślą o realizacji powyższych celów stworzono pierwsze komputerowe systemy AI, wykorzystujące reguły logiki klasycznej opracowywane przez ludzkich ekspertów. Należały do nich pierwsze systemy wspierające lekarzy w latach 70. XX wieku – CASNET czy MYCIN (Kaul *et al.*, 2020) – a także słynny elektroniczny mistrz szachowy Deep Blue. Systemy takie cechuje determinizm, uniemożliwiający odstępstwo od wyznaczonych ścieżek rozumowania. W przypadku systemów podejmujących krytyczne decyzje jest on zaletą, natomiast gdy sytuacja wymaga nieco bardziej ludzkiego, otwartego spojrzenia na rozwiązywany problem, staje się wadą.

Uczenie maszynowe

Klasyczne systemy regułowe nie mogły modyfikować swojego działania w miarę pojawiania się nowych danych i obserwacji. Współczesna popularyzacja dużych zbiorów danych (*Big Data*) doprowadziła do powstania nowej grupy systemów AI, zwanej systemami uczącymi się. Nie wymagają one ręcznego określania reguł – analizują duże zbiory danych, poszukując wzorców i tworząc na ich podstawie model określonego wycinka rzeczywistości. Opisany proces to uczenie maszynowe (*machine learning*, ML).

Uczenie maszynowe umożliwia automatyczną modyfikację zachowania systemu, gdy w dostępnych danych pojawią się nieistniejące wcześniej wzorce. Po przeanalizowaniu nowych danych system może zacząć udzielać nowej odpowiedzi na zapytanie, które wcześniej dawało inny rezultat. W rezultacie znacząco zwiększa się elastyczność systemu, jednak „tok

rozumowania” jest trudniejszy do prześledzenia niż w przypadku systemów regułowych. Rośnie również prawdopodobieństwo pojawienia się nieoczywistych rezultatów, co w zależności od zastosowania systemu może być wadą lub zaletą. System uczy się na podstawie wzorców przedstawianych mu w postaci zbioru danych uczących. Część wzorców nie jest wykorzystywana bezpośrednio w procesie uczenia, ponieważ służą one weryfikacji stopnia wyuczenia systemu – jest to zbiór danych testowych. Podczas procesu uczenia następuje ekstrakcja wiedzy, która następnie może być przechowywana pod różnymi postaciami, takimi jak predykaty i reguły logiczne, wyrażenia algebraiczne i modele generatywne w postaci drzewiastej, taksonomie, schematy i ontologie semantyczne, grafy automatów czy dane probabilistyczne (van Harmelen *et al.*, 2008). Zbiór wymienionych struktur nazywa się bazą wiedzy.

System może się uczyć pod nadzorem człowieka lub samodzielnie. Często wyróżnia się cztery tryby uczenia (Allen, 2020):

1. uczenie nadzorowane (*supervised learning*) – bazuje na cechach obiektów zidentyfikowanych i oznaczonych przez człowieka; algorytmy uczenia nadzorowanego są niezwykle wydajne, ale ręczne etykietowanie danych bywa czasochłonne i kosztowne;
2. uczenie nienadzorowane (*unsupervised learning*) – pozwala na pracę z danymi bez etykietowania (istotne cechy są określane automatycznie w ramach pracy algorytmów), zazwyczaj jest jednak mniej precyzyjne i wydajne niż uczenie nadzorowane;
3. uczenie częściowo nadzorowane (*semi-supervised learning*) – korzysta zarówno z danych etykietowanych, jak i nieetykietowanych, łącząc w sobie zalety i wady dwóch pierwszych podejść;
4. uczenie ze wzmocnieniem (*reinforcement learning*) – używa danych nieetykietowanych, bazując na informacji zwrotnej otrzymywanej ze środowiska podczas kolejnych podejść do rozwiązania problemu metodą prób i błędów; mechanizm wzmocnienia (nagrody) jest tu analogiczny do występującego w świecie zwierzęcym, dzięki czemu algorytm może odnotować, że wykonał krok w kierunku suboptymalnego rozwiązania.

W każdym z trybów uczenia bardzo istotna jest rola człowieka, który udostępnia zbiór danych uczących, wybiera algorytm uczenia i ustala jego parametry, a także rozwiązuje problemy. Należy zauważyć, że wraz ze złożonością modelu rośnie ilość danych wymagana do wyuczenia systemu inteligentnego. Wyboru techniki uczenia powinno się dokonywać z uwzględnieniem charakteru i złożoności modelowanego zagadnienia.

Praktyczne zastosowanie AI

Współczesna AI nie osiąga poziomu inteligencji ludzkiej, może jednak być niezwykle przydatnym narzędziem wspierającym pracę człowieka i automatyzującym żmudne zadania – mówi się wówczas o wąskiej AI (*narrow AI*).

Niektórym odpowiednio wytrenowanym systemom udaje się w określonych zadaniach uzyskiwać skuteczność wyższą od ludzkiej. W największym stopniu dotyczy to analizy regresyjnej, klasyfikacji wzorców (włącznie z rozpoznawaniem obrazu) i klasteryzacji danych.

W dziedzinach medycyny szczególne sukcesy AI odnosi w zakresie analizy obrazu. Przykładem może być system DLAD (*deep learning-based automatic detection*), służący do wykrywania nieprawidłowego wzrostu komórek na radiogramach, który przewyższył wydajnością 17 na 18 lekarzy (Nam *et al.*, 2019). Grupa Google AI Healthcare stworzyła system LYNA (LYmph Node Assistant), wykrywający przerzutowe guzy raka piersi w barwionych preparatach z biopsji węzłów chłonnych. Algorytm ma 99-procentową skuteczność w klasyfikacji próbek (człowiek – 96-procentową), a średni czas przeglądania slajdów został skrócony dwukrotnie (Liu *et al.*, 2019b).

PODSTAWOWE TECHNIKI AI

Wąska AI jest zbiorem różnorodnych technik, stosowanych oddzielnie lub wspólnie w celu rozwiązania określonego problemu: klasyfikacji, planowania, prognozowania czy sterowania (Russell i Norvig, 2010). Każda z technik wykorzystuje określony aparat matematyczny, aby w mniej lub bardziej wierny sposób naśladować procesy przetwarzania informacji zachodzące w układach biologicznych. Możliwe jest także połączenie dwóch albo więcej technik w jednym systemie hybrydowym.

Metody przeszukiwania

Pierwszą grupą technik są metody przeszukiwania (*search methods*), które operują na przestrzeni rozwiązań danego problemu, zdefiniowanej w formie grafu możliwych stanów i przejść między nimi. Celem jest znalezienie sekwencji przejść o jak najniższym koszcie (zazwyczaj czasowym), prowadzącej od stanu początkowego do stanu spełniającego warunki rozwiązania problemu. Algorytmy nie muszą znać lokalizacji rozwiązania w grafie, wymagają jednak zdefiniowania funkcji celu, która określa, czy dany stan spełnia warunki rozwiązania problemu.

Można to porównać do poszukiwania w górach najszybszej drogi do miejsca, skąd rozciąga się widok na całe pasmo górskie. Niewykluczone, że poszukiwanie na ślepo zakończy się sukcesem, ale większą skuteczność uzyska się, biorąc pod uwagę wiedzę dziedzinową; droga na skróty może wcale nie być najszybsza, a widok z najwyższego szczytu bywa przesłonięty chmurami. Opisany proces nazywa się przeszukiwaniem heurystycznym.

Pierwowzorem wielu algorytmów przeszukiwania są zjawiska zaobserwowane w przyrodzie. Przykładem może tu być algorytm mrówkowy (*ant colony optimisation*), polegający na pozostawianiu cyfrowego śladu feromonowego, który wzmacnia określone ścieżki poszukiwania w obrębie grafu. Jeżeli przestrzeń rozwiązań problemu może być opisana

funkcją matematyczną, celem metody przeszukiwania jest znalezienie ekstremum tej funkcji. Przy skomplikowanej, wielowymiarowej lub nieliniowej funkcji z wieloma ekstremami lokalnymi wymaga to zastosowania zaawansowanych algorytmów optymalizacji matematycznej. Mogą one być czasochłonne obliczeniowo i nie dają gwarancji uzyskania optymalnego rozwiązania we wszystkich przypadkach. Innym podejściem do przeszukiwania zbioru rozwiązań są techniki ewolucyjne, inspirowane zasadami doboru naturalnego. W algorytmie genetycznym parametry rozwiązania są kodowane w formie swoistego binarnego genotypu, a poszczególne „osobniki” poddawane są procesom ewolucyjnym – krzyżowaniu, mutacji i selekcji – w poszukiwaniu rezultatu najbardziej zbliżonego do optimum określonego przez funkcję celu. W programowaniu genetycznym genotyp nie jest ciągiem binarnym, lecz zbiorem drzew wyrażań tworzących program komputerowy o określonej gramatyce.

Logika matematyczna

Techniki z drugiej grupy – oparte na logice matematycznej, działające na symbolach – były podstawą większości wczesnych zastosowań AI w postaci regułowych systemów wspomagania decyzji, takich jak wspomniany system MYCIN.

Wiedzę dla systemów regułowych określają eksperci dziedzinowi przy użyciu reguł logicznych. Najczęściej są to wyrażenia logiki pierwszego rzędu z predykatami i kwantyfikatorami. Działanie systemu polega na przeprowadzeniu automatycznego wnioskowania przy użyciu tych wyrażań, pozwalającego na przekształcenie wejściowej przesłanki w konkluzję. Przesłanką może być przykładowo grupa współwystępujących objawów chorobowych, a konkluzją – sugerowana diagnoza.

Metodą uczenia maszynowego jest w przypadku systemów regułowych indukcyjne programowanie logiczne, bazujące na wyrażeniach logicznych i pozwalające na identyfikację relacji między poszczególnymi aspektami problemu.

Ważną techniką z omawianej grupy jest logika rozmyta, która umożliwia modelowanie niebinarnego świata. W logice rozmytej wyrażenie nie zawsze jest w pełni prawdziwe lub fałszywe – może się cechować określonym stopniem prawdziwości.

Metody probabilistyczne

Trzecia grupa technik to metody probabilistyczne, stosowane do wnioskowania na podstawie niepełnych lub niepewnych danych.

Najbardziej znaną techniką jest tu sieć bayesowska, reprezentująca wiedzę w postaci acyklicznego grafu skierowanego. Wierzchołki grafu reprezentują zmienną losową (np. objaw czy diagnozę), a krawędzie – związki przyczynowe między nimi. Określona zmienna losowa w sieci jest warunkowo niezależna od zmiennych, które nie są z nią połączone w grafie. Wnioskowanie polega na obliczeniu rozkładu prawdopodobieństwa zmiennych ujętych w zapytaniu na podstawie danych sieci.

Dla zagadnień, w których istotny jest czynnik czasu, często stosuje się model stochastyczny Markowa. Zakłada on,

że przyszyły stan badanego układu zależy jedynie od stanu aktualnego, a nie od wcześniejszych stanów. Podejście to pozwala na obliczenie prawdopodobieństwa dla złożonych zagadnień, w których przypadku precyzyjne metody obliczeniowe byłyby zbyt czasochłonne.

Innymi technikami z tej grupy są estymacja liniowo-kwadratowa (filtr Kalmana) czy sekwencyjna metoda Monte Carlo, polegająca na szacowaniu modelu przy użyciu symulacji.

Klasyfikatory

Grupa czwarta to klasyfikatory, które bazują na dopasowaniu do wzorca. Jest to grupa obecnie najczęściej stosowana w dziedzinach medycznych – ze względu na często występującą konieczność klasyfikacji, czyli przypisania badanego elementu do konkretnej klasy. Przykładem może być diagnostyka różnicowa choroby Alzheimera i łagodnych zaburzeń poznawczych (*mild cognitive impairment*, MCI) prowadzona na podstawie danych obrazowych.

Jedną z najprostszych, a równocześnie bardzo efektywnych metod jest klasyfikacja oparta na drzewach decyzyjnych. Drzewo decyzyjne reprezentuje funkcję przekształcającą wektor cech wejściowych (dyskretnych lub ciągłych) na pojedynczą wartość „decyzji”. Węzłami drzewa są poszczególne cechy, gałęziami – wartości cech, a liśćmi – decyzje. Drzewo decyzyjne można zatem traktować jako hierarchiczną reprezentację zbioru reguł logicznych. Zalecaną metodą budowania spójnych drzew decyzyjnych jest heurystyka oparta na względnej entropii informacji (*information gain*). Proces klasyfikacji polega na wykorzystaniu drzewa jako modelu predykcyjnego. Jeśli znamy wartości cech, uzyskujemy dyskretną wartość decyzji – oznaczającą klasę, do której przypisany zostaje dany zestaw cech.

Rozszerzeniem metody drzew decyzyjnych jest losowy las decyzyjny (*random forest*), składający się z wielu drzew decyzyjnych tworzonych na etapie uczenia systemu. Ostateczna decyzja, czyli określenie klasy, jest dominantą rozwiązania ze wszystkich drzew. Rozwiązanie to pozwala uniknąć problemu nadmiernego dopasowania do danych uczących, występującego w drzewach decyzyjnych. Z uwagi na agregację rezultatów wnioskowania interpretacja działania metody lasów losowych jest bardziej złożona niż w przypadku drzew decyzyjnych.

Często stosowaną metodą klasyfikacji jest algorytm k najbliższych sąsiadów (*k nearest neighbours*), wyszukujący w przestrzeni bazy wiedzy k najbliższych sklasyfikowanych obserwacji, a następnie określający klasy badanego wzorca. Do wyliczenia dystansu między wzorcami służy często odległość Minkowskiego.

Ważną rodziną metod klasyfikacji są algorytmy związane z operacjami na funkcji jądra, które można traktować jako matematyczną miarę podobieństwa. Funkcję jądra wykorzystuje się jako uzupełnienie wielu probabilistycznych metod klasyfikacji, takich jak naiwne klasyfikatory Bayesa (*naive Bayes classifiers*) czy mieszaniny Gaussa (*Gaussian mixture models*). W dziedzinach medycznych dużą popularnością cieszy się technika maszyny wektorów nośnych (*support*

vector machine, SVM). Polega ona na takim doborze liczby i charakteru cech klasyfikowanych elementów, aby możliwy był ich podział na rozłączne zbiory przy użyciu hiperpłaszczyzny w przestrzeni określonej przez te cechy. Celem jest znalezienie podziału, w którym zbiory reprezentujące poszczególne klasy będą rozdzielone z jak największym marginesem. W przypadku zbiorów trudno separowalnych wykonuje się operację zwaną trikami jądrowymi (*kernel trick*), zwiększając wymiarowość przestrzeni cech tak, aby uzyskać separowalność liniową. Popularność techniki SVM wynika z faktu, że jako metoda dyskryminatywna jest ona precyzyjniejsza od pozostałych technik z omawianej rodziny.

Techniki klasyfikacji można stosować również jako metody regresyjne. Rezultatem nie będzie wtedy dyskretny identyfikator określający klasę, ale liczba rzeczywista – oczekiwana wartość konkretnej zmiennej.

Sztuczne sieci neuronowe

Problemy klasyfikacji i regresji często rozwiązuje się także przy użyciu sztucznych sieci neuronowych (*artificial neural networks*, ANN), których działanie jest inspirowane naturalnymi mechanizmami występującymi w układzie nerwowym. Z matematycznego punktu widzenia sieci neuronowe można traktować jako uniwersalne aproksymatory funkcji. Ich kluczowe cechy to zdolność uogólniania wiedzy i umiejętność kompensacji częściowego braku lub zakłócenia danych wejściowych. Podstawowym elementem budowy ANN jest matematyczny model neuronu o licznych wejściach i jednym wyjściu. Sieć składa się z wielu takich elementów, między którymi – podobnie jak w układzie nerwowym – istnieją ważone połączenia służące do przekazywania wzmocnionego lub osłabionego sygnału do kolejnych neuronów. Dodatkowym filtrem jest funkcja aktywacji, która przekształca ważoną sumę wejść w wartość wyjściową neuronu.

Wyróżniamy ANN jednokierunkowe (*feed-forward*) i rekurencyjne (*recurrent*). Sieć jednokierunkowa jest acyklicznym grafem skierowanym i nie ma wewnętrznego stanu – wartości wyjściowe zależą jedynie od aktualnych wartości wejściowych. Neurony i połączenia neuronów są tu najczęściej ułożone w warstwy. Sieć rekurencyjna zawiera połączenia zwrotne, może zatem tworzyć układ dynamiczny – stabilny, oscylujący, a nawet chaotyczny. Odpowiedź sieci rekurencyjnej może zależeć od historii sygnałów wejściowych, ma ona więc pewien rodzaj pamięci krótkotrwałej. Działanie sieci rekurencyjnej jest bardziej zbliżone do procesów zachodzących w biologicznym układzie nerwowym i trudniejsze do interpretacji. Sieć jest za to zdolna do realizacji trudniejszych zadań, takich jak przetwarzanie języka naturalnego – co okazuje się przydatne również w medycynie. Im więcej warstw neuronów w sieci, tym bardziej złożone przekształcenia może ona aproksymować; rośnie też trudność wyuczenia sieci. Sieci z wieloma ukrytymi (wewnętrznymi) warstwami neuronów nazywane są sieciami głębokimi (*deep neural networks*, DNN). Każda z warstw przekształca sygnał wejściowy w bardziej abstrakcyjną, wysokopoziomową formę

informacji. Sieci głębokie umożliwiają ekstrakcję cech i dokonanie klasyfikacji w ramach pojedynczego algorytmu. Odmianą DNN o szerokim zastosowaniu w medycynie są konwolucyjne sieci neuronowe (*convolutional neural networks*, CNN), wyspecjalizowane m.in. w przetwarzaniu obrazu i wideo. Układ połączeń neuronów jest tutaj wzorowany na strukturze kory wzrokowej zwierząt. Sieci konwolucyjne, w odróżnieniu od sieci ograniczonych do operacji algebraicznych na macierzach, wykorzystują filtrowanie sygnału przy użyciu działania nazywanego splotem całkowym. Rezultatem operacji filtrowania jest mapa cech (*feature map*) zidentyfikowanych w danych obrazowych. Różne rozmiary filtra pozwalają na identyfikację cech o różnej wielkości i szczegółowości. Podczas analizy filtr jest przesuwany, dzięki czemu CNN są mało wrażliwe na przesunięcia cech we wzorcach, będące immanentną cechą danych obrazowych.

ZASTOSOWANIA TECHNIK SZTUCZNEJ INTELIGENCJI I UCZENIA MASZYNOWEGO W MEDYCYNIE

Już na początkowych etapach rozwoju technik AI i ML przewidywano, że znajdą one szerokie zastosowanie w medycynie. Procesy biologiczne często są zjawiskami o znacznej złożoności matematycznej z elementami losowości. Za pomocą obliczeń trudno jest określić związek między wynikami badań a prawdopodobieństwem danej diagnozy lub między leczeniem a zmianą stanu pacjenta. Dzięki rozwojowi cyfrowych technologii diagnostycznych, takich jak obrazowanie medyczne i różnego rodzaju detektory noszone przez pacjenta (aktygrafy, urządzenia do ciągłego monitorowania aktywności elektrycznej serca metodą Holtera), stale rośnie ilość dostępnych informacji.

Techniki inteligentne dobrze radzą sobie z dużą ilością danych trudnych do interpretacji i obarczonych niepewnością. Sztuczna inteligencja i uczenie maszynowe stają się więc narzędziami coraz szerzej wykorzystywanymi w diagnostyce oraz wspomaganiu leczenia, monitorowania i predykcji zmian stanu zdrowia (Briganti i Le Moine, 2020).

Techniki AI i ML są ponadto używane do opracowywania personalizowanej terapii, przykładowo na podstawie genotypu (Schork, 2019), a nawet do wstępnej segregacji (triażu) pacjentów pod względem zapotrzebowania na intensywną opiekę medyczną (Kang *et al.*, 2020).

Dostępne są również aplikacje klienckie pozwalające na uzyskanie – na podstawie przedstawionych wyników badań – porady w pełni generowanej przez algorytmy AI (cyfrowa konsultacja).

Zastosowanie w diagnostyce

Podstawowym zastosowaniem AI i ML w medycynie jest wspomaganie procesu diagnostycznego. Początkowo używano prostych systemów regułowych wnioskujących na podstawie objawów wybieranych przez diagnostę: INTERNIST-I czy QMR. Wśród ich wad wymieniano niewielką elastyczność (co ograniczało swobodę lekarza) i trudności ze skompletowaniem

bazy wiedzy. Obecnie dostępne systemy wspomagające wstępną diagnostykę różnicową są znacznie bardziej rozwinięte i uzupełnione m.in. o identyfikację wizualną (McKinney, 2020). Jednocześnie opracowuje się systemy hybrydowe, łączące dane wejściowe różnego rodzaju: genetyczne, środowiskowe, a także z wywiadu, badań biochemicznych, obrazowych itp. Są to narzędzia medycyny precyzyjnej, mającej na celu pełną personalizację leczenia (Ahmed *et al.*, 2020).

Jednym z najdynamiczniej rozwijających się obszarów zastosowania AI w diagnostyce jest interpretacja danych wizualnych. Głównym źródłem informacji są tu obecnie wyniki badań histopatologicznych lub obrazowania medycznego: tomografii komputerowej (*computed tomography*, CT), pozytonowej tomografii emisyjnej (*positron emission tomography*, PET) i rezonansu magnetycznego (*magnetic resonance imaging*, MRI). Współczesne badanie obrazowe generuje gigabajty danych obrazowych, uzyskiwanych za pomocą rozmaitych filtrów i technik w celu zaprezentowania informacji w różnych ujęciach (Werner *et al.*, 2015). Przeanalizowanie takiej ilości danych przez człowieka jest trudne i czasochłonne, stąd dążenie do przynajmniej częściowej automatyzacji. Za szczególnie przydatne w analizie danych obrazowych uznano DNN (Lee *et al.*, 2017). Przekształcanie przez nie sygnału w kolejne informacje coraz wyższego poziomu pozwala na przejście od pikseli lub wokseli do krzywych, następnie do kształtów, a ostatecznie do metadanych cechy wyodrębnionej z obrazu, np. guza nowotworowego. Największą popularność zyskały konwolucyjne DNN, charakteryzujące się zmniejszoną wrażliwością na przesunięcie przestrzenne cech w obrębie wzorca, co jest typowe dla obrazowania medycznego.

Gdy liczba przykładów uczących jest relatywnie niewielka względem liczby cech wyodrębnianych z danych, dobrze sprawdza się technika klasyfikacyjna maszyny wektorów nośnych (Son *et al.*, 2010).

Metaanaliza rozwiązań, w których zastosowano metody uczenia głębokiego do wykrywania chorób na podstawie danych obrazowych, wykazała, że wiele algorytmów dorównuje dokładnością pracownikom służby zdrowia (Liu *et al.*, 2019a). Autorzy stwierdzają, że metody AI mają ogromny potencjał, ale tylko w nielicznych projektach dokonano zewnętrznej walidacji lub porównania skuteczności algorytmu i człowieka na jednej próbie. Przyjęcie nowych standardów raportowania i stworzenie wiarygodnej bazy danych uczących to konieczne kroki na drodze do powszechnej akceptacji stosowania technik AI w omawianej dziedzinie.

Wspomaganie leczenia przy użyciu technik AI

Kolejnym rozwijającym się zastosowaniem technik inteligentnych w medycynie jest wspomaganie leczenia, również leczenia operacyjnego.

Szeroka analiza danych ułatwia personalizację leczenia farmakologicznego, która jest ważnym celem medycyny precyzyjnej. Możliwości generalizacji zapewniane przez

techniki ML wspomagają z kolei tworzenie ogólnych standardów terapii.

W leczeniu operacyjnym AI wspomaga podejmowanie decyzji odnośnie do kwalifikacji do zabiegu, a także lokalizowanie chorych lub uszkodzonych tkanek. W okresie pooperacyjnym pomaga śledzić przebieg powrotu do zdrowia i oceniać ryzyko ewentualnego nawrotu choroby.

Techniki inteligentne służące do monitorowania stanu zdrowia pacjenta

Wiele technik inteligentnych znajduje zastosowanie w monitorowaniu stanu zdrowia, w szczególności w wykrywaniu sytuacji zagrażających życiu. Algorytmy w czasie rzeczywistym analizują dane pomiarowe zbierane przez urządzenia noszone (*wearables*), do których należą czujniki bezprzewodowo zintegrowane ze smartfonem lub smartwatchem, przyklejane do ciała biosensory, a nawet tkaniny stale rejestrujące wybrane parametry fizjologiczne. Zespół urządzeń wyposażonych w techniki AI/ML nazywa się inteligentnym otoczeniem (*ambient intelligence*) (Acampora *et al.*, 2013). W razie wykrycia nieprawidłowości inteligentne otoczenie alarmuje pacjenta oraz – jeśli urządzenie zapewnia komunikację z internetem – lekarza albo jednostkę opieki zdrowotnej. Urządzenia już dostępne na rynku służą do wykrywania migotania przedsionków (Halcox *et al.*, 2017) czy napadów padaczkowych (Regalia *et al.*, 2019). Postęp technik uczenia głębokiego i systemów hybrydowych umożliwia powstawanie coraz skuteczniejszych urządzeń monitorujących, a nawet prognozujących zagrożenie.

Urządzenia dla diabetyków stają się osobistymi systemami wspomaganie decyzji – nie tylko stale monitorują pacjenta, ale również doradzają korekty dozowania leku w zależności od bieżącego poziomu glukozy, dostarczonych dawek leku, spożytych posiłków i aktywności fizycznej. ANN okazały się skuteczniejsze niż standardowa formuła wyliczeniowa dla bolusów insulinowych (Vettoretti *et al.*, 2020).

Prognozowanie zmian stanu zdrowia

Kolejnym zastosowaniem omawianych technik jest prognozowanie zmian stanu zdrowia (włącznie z przeżywalnością) w celu optymalizacji planu opieki zdrowotnej. Głównymi narzędziami AI/ML są tutaj techniki klasyfikacji i regresji. Elektroniczna dokumentacja medyczna dostarczyła danych do prognozowania ryzyka ostrego zespołu wieńcowego przy użyciu techniki maszyny wektorów nośnych (Huang *et al.*, 2017). Technika losowych lasów decyzyjnych zastosowana do danych klinicznych i socjoekonomicznych pozwoliła w badaniu Tele-HF na uzyskanie dokładniejszej prognozy powtórnej hospitalizacji z powodu niewydolności serca niż metody statystyki klasycznej (Mortazavi *et al.*, 2016). Jednokierunkowej sieci neuronowej trenowanej za pomocą algorytmów genetycznych użyto do prognozowania spadku współczynnika filtracji kłębuszkowej u pacjentów z zespołem policystycznych nerek (Niel *et al.*, 2018).

ZASTOSOWANIE TECHNIK AI I ML W NEUROLOGII

W neurologii, podobnie jak w całej medycynie, wykorzystanie technik inteligentnych zostało najbardziej rozwinięte w obszarze diagnostyki. Coraz częściej są one również elementem wsparcia w procesie leczenia farmakologicznego i operacyjnego. Ponadto mogą służyć do śledzenia funkcji neurologicznych organizmu w chorobach przewlekłych, zarówno w zakresie wykrywania nieprawidłowości, jak i monitorowania odpowiedzi na leczenie (Modi, 2017).

AI w diagnostyce chorób neurologicznych

Narzędzia współczesnej AI najlepiej nadają się do wsparcia metod diagnostycznych, w których badanie pacjenta dostarcza dużej ilości danych, tak jak w przypadku obrazowania MRI, PET i CT. Według Segato i wsp. (2020) współczesne zastosowania diagnostyczne technik AI można podzielić według rodzaju analizowanych danych.

Pierwszą grupą są dane dotyczące struktury anatomicznej mózgu, pozyskiwane głównie za pomocą obrazowania MRI, rzadziej PET i CT. Analiza z użyciem AI w dużej mierze koncentruje się na chorobie Alzheimera (diagnoza, klasyfikacja, różnicowanie względem łagodnych zaburzeń poznawczych lub demencji) oraz nowotworach układu nerwowego (detekcja i klasyfikacja rodzaju guza, predykcja prawdopodobieństwa mutacji). Innymi schorzeniami, w których do analizy danych anatomicznych zastosowano techniki inteligentne, są stwardnienie rozsiane (diagnoza i klasyfikacja), schizofrenia, urazy mózgu i dysfunkcje tętnic mózgowych, a także depresja, choroba dwubiegunowa i mutyzm mózdkowy. Podstawowymi technikami są tutaj konwolucyjne sieci neuronowe i klasyfikatory oparte na maszynach wektorów nośnych; dość często korzysta się też z techniki losowych lasów decyzyjnych. Należy zaznaczyć, że powyższe metody wciąż traktowane są jako eksperymentalne i nie należą do podstawowego instrumentarium diagnostycznego.

Druga grupa danych to informacje morfologiczne. Tu zastosowania technik inteligentnych skupiają się na nowotworach mózgu, w szczególności na segmentacji i ocenie wolumetrycznej. Większość danych pochodzi z MRI i jest analizowana przy użyciu maszyn wektorów nośnych i sieci neuronowych – zarówno konwolucyjnych, jak i w pełni połączonych. Metody uczenia głębokiego umożliwiają przetworzenie obrazu i klasyfikację określonego przypadku przez jeden algorytm. Stosowane są również techniki losowych lasów decyzyjnych, ukryte modele Markowa oraz klasteryzacja przy użyciu algorytmu centroidów i klasyfikatora rozmytego FCM (*fuzzy c-means*).

Przykładowymi cechami z MRI wykorzystywanymi w analizie mogą być wzmocnione kontrastem obrazy T1 i T2, FLAIR (*fluid-attenuated inversion recovery*), PD (*proton density*), ADC (*apparent diffusion coefficient*), rCBF (*relative cerebral blood flow*), rCBV (*relative cerebral blood volume*).

czy MTT (*mean transit time*). Właśnie takiego zestawu parametrów użyto do automatycznego odróżniania nekrozy radiacyjnej od ognisk nawracającego glejaka wielopostaciowego (Hu *et al.*, 2011).

Do trzeciej grupy analizowanych danych należą informacje dotyczące łączności funkcjonalnej (*functional connectivity*). One także pochodzą z urządzeń obrazowania medycznego, są jednak wstępnie przetworzone metodami statystycznymi w celu ekstrakcji informacji ustrukturyzowanej. Modele *functional connectivity* można budować przez ekstrakcję uśrednionych szeregów czasowych z danych fMRI wokseli w poszczególnych obszarach mózgu, a następnie poddanie ich falkowej analizie korelacyjnej (*wavelet correlation analysis*) (Saba *et al.*, 2019). Wynikiem jest struktura topologiczna nazywana minimalnym drzewem rozpinającym (*minimum spanning tree*, MST). Struktury danych oparte na grafach mogą być przetwarzane różnorodnymi technikami AI, np. w diagnostyce różnicowej choroby Alzheimera i procesu neurozwyrodnieniowego zlokalizowanego w płatach czołowych i skroniowych mózgu (otępienie czołowo-skroniowe, *frontotemporal lobar degeneration*, FTL) (de Haan *et al.*, 2009). W podobny sposób można budować i wykorzystywać modele łączności anatomicznej (*anatomical connectivity*) i efektywnej (*effective connectivity*) (Lang *et al.*, 2012). Zakres możliwości analizy opartej na danych dotyczących łączności funkcjonalnej jest znacznie szerszy – obejmuje diagnozę różnicową choroby Alzheimera, demencji i łagodnych zaburzeń poznawczych, diagnozę i klasyfikację zaburzeń ze spektrum autyzmu, diagnozę stwardnienia rozsianego, schizofrenii, choroby Parkinsona, padaczki, zespołu Tourette'a, depresji czy choroby dwubiegunowej. Dodatkowo metody inteligentne pozwalają na wykorzystanie tych danych do określania dojrzałości mózgu, klasyfikacji stanu uwagi i fazy snu, identyfikacji słyszenia absolutnego, predykcji utraty słuchu, klasyfikacji płci, diagnozowania nałogu nikotynowego i alkoholowego i wielu innych celów. Techniki AI stosowane do trzeciej grupy danych są bardziej zróżnicowane niż w pierwszych dwóch grupach (Segato *et al.*, 2020). W dużej mierze są to ponownie maszyny wektorów stanów i konwolucyjne sieci neuronowe, znaczący wkład mają jednak także regresja liniowa, metoda losowych lasów decyzyjnych, liniowa analiza dyskryminacyjna, algorytm k najbliższych sąsiadów, adaptywne wzmacnianie (*AdaBoost*) i metody grupowania.

AI we wspomaganiu leczenia chorób neurologicznych

Leczenie operacyjne w neurologii obejmuje m.in. głęboką stymulację mózgu (*deep brain stimulation*, DBS) w chorobie Parkinsona i padaczkach oraz zabiegi neurochirurgiczne związane z chorobą nowotworową lub uszkodzeniem mózgu z powodu udaru czy urazu mechanicznego.

Według Segato i wsp. (2020) w leczeniu operacyjnym chorób układu nerwowego techniki AI stosuje się do wsparcia następujących czynności:

- kwalifikacja do zabiegu;
- śródoperacyjna segmentacja struktur mózgu;
- wybór i lokalizowanie struktur anatomicznych do zabiegu na podstawie obrazowania (dotyczy to ognisk padaczkorodnych u pacjentów z padaczką czy zakresu operacji w guzach mózgu);
- określenie stref stymulacji mózgu w chorobie Parkinsona;
- określenie trajektorii dla narzędzi chirurgicznych w celu minimalizacji inwazyjności;
- wsparcie śródoperacyjne;
- ocena pooperacyjna obejmująca predykcję czasu i stopnia powrotu do zdrowia – m.in. na podstawie kwantyfikacji nieprawidłowości ruchowych (Lieber *et al.*, 2015).

Technikami najczęściej wykorzystywanymi w powyższych celach są sieci neuronowe, ukryte modele Markowa i maszyna wektorów nośnych, a w mniejszym zakresie – losowe lasy decyzyjne, klastrowy algorytm centroidów i algorytmy genetyczne.

Celem wsparcia leczenia farmakologicznego w chorobach neurologicznych jest dobór odpowiedniego leku lub kombinacji leków dla konkretnego chorego wraz z optymalnym dawkowaniem. Procesy te, będące elementami medycyny precyzyjnej, wymagają skorelowania danych genetycznych i proteomicznych pacjenta z chemiczną charakterystyką potencjalnych leków (Romm i Tsigelny, 2020). Techniki inteligentne, takie jak konwolucyjne sieci neuronowe oparte na zależnościach (*dependency-based convolutional neural networks*), w połączeniu z metrykami podobieństwa leków umożliwiają również przewidywanie niepożądanych interakcji (Rohani i Eslahchi, 2019). Uczenie maszynowe pozwala ponadto na wykorzystanie danych farmakokinetycznych i farmakodynamicznych leku w połączeniu z charakterystyką stanu pacjenta w celu indywidualizacji i optymalizacji schematu leczenia.

Monitorowanie funkcji neurologicznych

W neurologii działanie urządzeń inteligentnego otoczenia koncentruje się na zbieraniu i analizowaniu w czasie rzeczywistym sygnałów elektrycznych związanych ze stanem neurologicznym pacjenta. W zależności od rodzaju urządzenia wynik analizy może prowadzić do uruchomienia alarmu albo nawet rozpoczęcia terapii, np. poprzez stymulację.

Najczęściej analizowanym rodzajem danych są dane elektroencefalograficzne (EEG), zbierane przez czujniki na skórze głowy lub wewnątrzczaszkowe. Do interpretacji sygnału EEG służą różnorodne metody AI – wśród często wybieranych rozwiązań są maszyna wektorów nośnych i DNN. Zaawansowane systemy dokonują oczyszczenia danych i ekstrakcji cech, takich jak gęstość widmowa sygnału czy łączność funkcjonalna, bazując na relacji czasowej aktywności poszczególnych regionów mózgu (Cao, 2020). Niekiedy analizie podlegają też dane elektromiograficzne, monitorowane u pacjentów cierpiących na neuropatie i miopatie. Po ekstrakcji cech przy użyciu analizy autoregresyjnej do interpretacji może zostać wykorzystany system hybrydowy

łączy sieć neuronową z elementami logiki rozmytej (Koçer, 2010).

Do uczenia maszynowego w systemach analizujących sygnały elektryczne służą dane zbierane z urządzeń monitorujących pacjentów na oddziałach intensywnej opieki neurologicznej. Urządzenia zachowują znaczną ilość danych temporalnych dla takich parametrów, jak wentylacja, parametry hemodynamiczne, ciśnienie śródczaszkowe, temperatura ciała, ilość przyjmowanych płynów, sygnały elektromiograficzne (EMG) i EEG (Modi, 2017). Potencjał wykorzystania powyższych danych w systemach uczenia maszynowego pozostaje przedmiotem badań. Jedną z możliwości jest budowa systemu, który w sposób przynajmniej częściowo autonomiczny sterowałby stanowiskiem intensywnej opieki medycznej.

Urządzenia inteligentne stale noszone przez pacjenta mogą w znaczącym stopniu wyeliminować źródła opóźnień w leczeniu ostrego udaru mózgu, co jest kluczowe dla skuteczności terapii. Chory z udarem często nie jest świadomy sytuacji lub znajduje się w stanie, który uniemożliwia wezwanie pomocy. Urządzenie po zidentyfikowaniu udaru może automatycznie powiadomić ratownictwo medyczne. W połączeniu ze zautomatyzowaną interpretacją badań obrazowych w szpitalu techniki inteligentne zwiększają szanse na uratowanie życia i zdrowia. Urządzenia mobilne wyposażone w systemy interpretujące dane z czujników pomagają też w neurorehabilitacji poudarowej (Modi, 2017).

Również pacjenci cierpiący na napady padaczkowe mogą odnieść korzyści z noszenia urządzeń inteligentnych. Niezależnie od reagowania w sytuacjach krytycznych, system może na co dzień przypominać o terminach przyjmowania odpowiednich dawek leku – a pominięcie nawet jednej dawki skutkuje niekiedy napadem przełomowym (Acampora *et al.*, 2013). Oprócz ciągłej analizy EEG systemy monitorowania pacjentów z padaczką zawierają akcelerometrię wykonane w technologii układów mikromechanicznych, pozwalające na rejestrację objawów ruchowych, które są kluczowe dla interpretacji charakteru niektórych napadów. Systemy z reagującą stymulacją korową potrafią nie tylko wykryć lateralizację i lokalizację napadu, ale także podjąć próbę powstrzymania jego rozprzestrzeniania się (Morrell, 2011). Przy użyciu sieci neuronowych i algorytmów genetycznych (Rapaport *et al.*, 2019) stworzono prototyp urządzenia umożliwiającego predykcję ataku padaczkowego nawet z godzinnym wyprzedzeniem (BGU, 2020).

Urządzenia noszone stosowane w połączeniu z urządzeniami mobilnymi wykazały skuteczność w ilościowej i jakościowej ocenie chodu, postawy i drżenia u pacjentów ze stwardnieniem rozsianym, chorobą Parkinsona i chorobą Huntingtona (Dorsey *et al.*, 2017).

Techniki AI służą ponadto do monitorowania przebiegu i zaburzeń snu – sieci neuronowe i metody klasteryzacji pozwalają na analizę danych polisomnograficznych i EEG. Ma to na celu diagnozowanie narkolepsji, monitorowanie i poprawę bezpieczeństwa chorego z obturacyjnym bezdechem sennym czy ocenę ryzyka chorób neurodegeneracyjnych na

podstawie idiopatycznych zaburzeń fazy REM (Goldstein *et al.*, 2020).

Inteligentne otoczenie może być pomocne w poprawie jakości życia pacjentów z zaburzeniami neurodegeneracyjnymi. Intensywne badania nad działaniem uczenia maszynowego prowadzono zwłaszcza w kontekście różnicowania zaburzeń motorycznych w chorobie Parkinsona. U osób z wszczepionym głębokim stymulatorem mózgu możliwe jest dostosowanie parametrów stymulacji przez urządzenie monitorujące i analizujące informacje otrzymane z czujników ruchu ciała. Na co dzień urządzenia mogą też monitorować zmiany stanu poznawczego i asystować w czynnościach, z których wykonaniem chory ma trudności (Modi, 2017).

WYBRANE PROJEKTY I NARZĘDZIA

Na Newcastle University trwa obecnie (2021) projekt Octahedron (Optical Coherence Tomography Automated Heuristics for Early Diagnosis via Retina in Ophthalmology and Neurology), którego celem jest jak najwcześniejsze wykrycie początkowych objawów chorób neurodegeneracyjnych na podstawie obrazowania siatkówki. Tworzony system wykorzystuje niezwykle szczegółowe dane obrazowe pozyskane techniką OCT (*optical coherence tomography*) (Lauer-mann *et al.*, 2021), uwidaczniające poszczególne warstwy komórek nerwowych. Obrazy są następnie analizowane metodami ML. Dane uczące to setki tysięcy skanów siatkówkowych wysokiej rozdzielczości. Efekty uczenia maszynowego w analizie danych OCT, do której użyto konwolucyjnych sieci neuronowych, zaprezentowali również Schmidt-Erfurth i wsp. (2018).

Celem innego międzynarodowego przedsięwzięcia – z udziałem naukowców z National University of Singapore, University College London i Massachusetts General Hospital – jest prognozowanie rozwoju choroby Alzheimera za pomocą rekurencyjnych sieci neuronowych (Nguyen *et al.*, 2020). Zastosowanie tej techniki umożliwiło kompensację niepełnych informacji wejściowych, typowych dla badania podłużnego, z którego pochodziły dane 1677 uczestników zawarte w bazie ADNI (Alzheimer's Disease Neuroimaging Initiative). Projekt był odpowiedzią na wyzwanie TADPOLE (The Alzheimer's Disease Prediction of Longitudinal Evolution) (Marinescu *et al.*, 2018), które jest interesującym przykładem zastosowania gamifikacji do rozwiązania problemu naukowego – poszczególne zespoły rywalizują ze sobą w dążeniu do osiągnięcia najwyższej skuteczności analizy.

Interesujące wykorzystanie analizy języka naturalnego do wczesnego screeningu choroby Alzheimera zaproponował zespół szwajcarsko-niemiecki (Fritsch *et al.*, 2019) w ramach projektu TAPAS (Training Network on Automatic Processing of Pathological Speech). Celem było stworzenie narzędzia do mierzenia poziomu utraty funkcji poznawczych na podstawie analizy deficytów semantycznych w mowie spontanicznej. Sięgnięto tu po technikę modeli językowych sieci neuronowych (*neural network language models*, NNLM) z warstwą długotrwałej pamięci

krótkoterminowej (*long short-term memory*, LSTM), która okazała się skuteczna jako narzędzie preselekcji pacjentów do dalszego badania.

PODSUMOWANIE

Dynamiczny rozwój zastosowań AI i ML w neurologii oraz całej medycynie trwa i przyspiesza, o czym świadczy liczba prac i projektów z ostatnich lat. W przyszłości techniki inteligentne będą integralną częścią medycyny, już dziś określaną jako inteligentne otoczenie kliniczne (*ambient clinical intelligence*, ACI) (Briganti i Le Moine, 2020). Jest to koncepcja znacznie usprawniająca nowoczesną opiekę zdrowotną. ACI pozwala na zlecenie żmudnych i czasochłonnych zadań systemom elektronicznym, a równocześnie ułatwia indywidualne traktowanie każdego pacjenta. Prezentowane tu techniki umożliwiają automatyzację wielu czynności organizacyjnych i diagnostycznych – od zebrania i usystematyzowania wywiadu, przez przeprowadzenie wybranych badań, aż po interpretację wyników. Niewątpliwymi zaletami AI są dostępność przez całą dobę, zmniejszenie częstotliwości występowania błędów ludzkich oraz szybsze przetwarzanie danych i podejmowanie decyzji, które niekiedy okazują się bardziej racjonalne od decyzji człowieka. Z zastosowaniem omawianych technik wiąże się jednak wiele trudności. Heurystyczny charakter licznych rozwiązań AI sprawia, że możliwe jest uzyskanie nieprzewidywanych rezultatów, zwłaszcza w razie niewłaściwego zdefiniowania ograniczeń dziedzinowych. Uczenie maszynowe opiera się na obserwacji przykładów, które w części przypadków mogą nie pokrywać całej przestrzeni możliwych zdarzeń, szczególnie w stale ewoluującym środowisku. Wciąż zmieniają się charakterystyka demograficzna społeczeństwa i styl życia, pojawiają się też nowe jednostki chorobowe (np. zespół postcovidowy). Wszystko to sprawia, że systemy AI wymagają stałego treningu i aktualizacji baz wiedzy – podobnie jak u ludzi pożądana jest nauka przez całe życie. Dzisiejsze systemy AI nie radzą sobie dobrze z interpretacją danych przedstawionych za pomocą języka naturalnego, takich jak notatki tekstowe. Należy więc nieustannie dbać o odpowiednie ustrukturyzowanie, kompletność i obiektywizm danych używanych do uczenia maszynowego.

Większość rozwiązań prezentowanych w niniejszej pracy znajduje się na stosunkowo wczesnym etapie rozwoju. Zgoda organów regulacyjnych na szerokie zastosowanie kliniczne metod AI wymaga pełnej walidacji innowacyjnych narzędzi względem sprawdzonych metod tradycyjnych. Systemy inteligentne używane w medycynie powinny już na etapie projektowania być przygotowywane tak, by sprostać formalnym wymaganiom i ograniczeniom prawnym w odniesieniu do interpretowalności, jakości danych i bezpieczeństwa (Varghese, 2020).

Sztuczna inteligencja nie zastąpi lekarzy ani diagnostów. Wręcz przeciwnie: stanie się ich największym sojusznikiem. Obecnie często porównuje się efektywność lekarzy z efektywnością systemów inteligentnych (Liu *et al.*, 2019a).

Właściwszym podejściem wydaje się systematyczne porównanie lekarzy wyposażonych w narzędzia AI z lekarzami, którzy pracują bez takiego wsparcia. Dopiero wtedy uzyska się pełen obraz sytuacji, a sztuczna inteligencja zostanie szerzej zaakceptowana jako narzędzie zwiększające produktywność pracowników ochrony zdrowia (Varghese, 2020). Mocną stroną AI jest rozległa wiedza uzyskana z danych – ma ona jednak relatywnie płytki charakter. Z kolei ważną cechą ludzkiego eksperta jest głęboka intuicja diagnostyczna i terapeutyczna. Połączenie tych dwóch światów cechuje się ogromnym potencjałem, dlatego nowoczesne szkolenie lekarzy powinno obejmować zagadnienia AI, a systemy inteligentne powinny być konstruowane tak, żeby dawać rezultaty zrozumiałe i pomocne dla człowieka.

Uczenie maszynowe ma umiejętność wskazywania wzorców i prawidłowości, ale nie przewiduje myślenia kreatywnego ani intencjonalnego wychodzenia poza schematy. Tymczasem zdarza się, że poszczególni pacjenci opisują podobne lub identyczne okoliczności w zupełnie różny sposób. Wtedy także niezbędny jest udział lekarza.

Współczesne systemy komputerowe nie są wyposażone w empatię, dlatego tak duże znaczenie mają obecność człowieka i kultywowanie w środowisku klinicznym umiejętności miękkich. Niektórzy pacjenci mogą mieć negatywne nastawienie do automatycznych rekomendacji.

Inną istotną kwestią jest rozważenie etycznych implikacji ciągłego monitoringu, w szczególności podłączonego do sieci (Briganti i Le Moine, 2020).

Pomimo wielu ograniczeń systemy sztucznej inteligencji i uczenia maszynowego oraz ich zastosowanie w neurologii mają niezwykle liczne zalety. Cyfryzacja opieki zdrowotnej pozytywnie wpływa na jakość świadczeń, a zarazem obniża koszty (Buntin *et al.*, 2011). Najważniejszym zyskiem jest jednak poprawa bezpieczeństwa i jakości życia osób z ostrymi i przewlekłymi chorobami neurologicznymi (Modi, 2017).

Konflikt interesów

Autorzy nie zgłaszają żadnych finansowych ani osobistych powiązań z innymi osobami lub organizacjami, które mogłyby negatywnie wpłynąć na treść publikacji oraz rościć sobie prawo do tej publikacji.

Piśmiennictwo

- Acampora G, Cook DJ, Rashidi P *et al.*: A survey on ambient intelligence in health care. *Proc IEEE Inst Electr Electron Eng* 2013; 101: 2470–2494.
- Ahmed Z, Mohamed K, Zeeshan S *et al.*: Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. *Database (Oxford)* 2020; 2020: baaa010.
- Allen G: Understanding AI Technology. Joint Artificial Intelligence Center (JAIC), US Department of Defense, 2020.
- BGU: Ben-Gurion University of the Negev, Neuroscience at BGU: BGU researchers develop wearable device for predicting epileptic seizures. 2020. Available from: https://in.bgu.ac.il/en/neuro/pages/news/neurohelp_epilepsy.aspx [cited: 7 June 2021].

- Briganti G, Le Moine O: Artificial intelligence in medicine: today and tomorrow. *Front Med (Lausanne)* 2020; 7: 27.
- Buntin MB, Burke MF, Hoaglin MC et al.: The benefits of health information technology: a review of the recent literature shows predominantly positive results. *Health Aff (Millwood)* 2011; 30: 464–471.
- Cao Z: A review of artificial intelligence for EEG-based brain-computer interfaces and applications. *Brain Science Advances* 2020; 6: 162–170.
- Dorsey ER, Papapetropoulos S, Xiong M et al.: The first frontier: digital biomarkers for neurodegenerative disorders. *Digit Biomark* 2017; 1: 6–13.
- Fritsch J, Wankerl S, Nöth E: Automatic diagnosis of Alzheimer's disease using neural network language models. ICASSP 2019 – 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2019: 5841–5845.
- Goldstein CA, Berry RB, Kent DT et al.: Artificial intelligence in sleep medicine: an American Academy of Sleep Medicine position statement. *J Clin Sleep Med* 2020; 16: 605–607.
- de Haan W, Pijnenburg YA, Strijers RL et al.: Functional neural network analysis in frontotemporal dementia and Alzheimer's disease using EEG and graph theory. *BMC Neurosci* 2009; 10: 101.
- Halcox JJP, Wareham K, Cardew A et al.: Assessment of remote heart rhythm sampling using the AliveCor heart monitor to screen for atrial fibrillation: the REHEARSE-AF study. *Circulation* 2017; 136: 1784–1794.
- van Harmelen F, Lifschitz V, Porter B (eds.): *Handbook of Knowledge Representation*. Elsevier, Amsterdam 2008.
- Hu X, Wong KK, Young GS et al.: Support vector machine multiparametric MRI identification of pseudoprogression from tumor recurrence in patients with resected glioblastoma. *J Magn Reson Imaging* 2011; 33: 296–305.
- Huang Z, Chan TM, Dong W: MACE prediction of acute coronary syndrome via boosted resampling classification using electronic medical records. *J Biomed Inform* 2017; 66: 161–170.
- Kang DY, Cho KJ, Kwon O et al.: Artificial intelligence algorithm to predict the need for critical care in prehospital emergency medical services. *Scand J Trauma Resusc Emerg Med* 2020; 28: 17.
- Kaul V, Enslin S, Gross SA: History of artificial intelligence in medicine. *Gastrointest Endosc* 2020; 92: 807–812.
- Koçer S: Classification of EMG signals using neuro-fuzzy system and diagnosis of neuromuscular diseases. *J Med Syst* 2010; 34: 321–329.
- Lang EW, Tomé AM, Keck IR et al.: Brain connectivity analysis: a short survey. *Comput Intell Neurosci* 2012; 2012: 412512.
- Laueremann JL, Sochurek JAM, Plöttner P et al.: Applicability of optical coherence tomography angiography (OCTA) imaging in Parkinson's disease. *Sci Rep* 2021; 11: 5520.
- Lee JG, Jun S, Cho YW et al.: Deep learning in medical imaging: general overview. *Korean J Radiol* 2017; 18: 570–584.
- Lieber B, Taylor BES, Appelboom G et al.: Motion sensors to assess and monitor medical and surgical management of Parkinson disease. *World Neurosurg* 2015; 84: 561–566.
- Liu X, Faes L, Kale AU et al.: A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. *Lancet Digit Health* 2019a; 1: e271–e297.
- Liu Y, Kohlberger T, Norouzi M et al.: Artificial intelligence-based breast cancer nodal metastasis detection: insights into the black box for pathologists. *Arch Pathol Lab Med* 2019b; 143: 859–868.
- Marinescu RV, Oxtoby NP, Young AL et al.; EuroPOND Consortium (for the Alzheimer's Disease Neuroimaging Initiative): TADPOLE challenge: prediction of longitudinal evolution in Alzheimer's disease. 2018; ArXiv: 1805.03909 Q-Bio Stat.
- McKinney A: *VisualDx Mobile App*. J Electron Resour Med Libr 2020; 17: 16–30.
- Modi S: Artificial intelligence and neurology. *J Biomed Syst Emerg Technol* 2017; 4: 112.
- Morrell MJ; RNS System in Epilepsy Study Group: Responsive cortical stimulation for the treatment of medically intractable partial epilepsy. *Neurology* 2011; 77: 1295–1304.
- Mortazavi BJ, Downing NS, Buchholz EM et al.: Analysis of machine learning techniques for heart failure readmissions. *Circ Cardiovasc Qual Outcomes* 2016; 9: 629–640.
- Nam JG, Park S, Hwang EJ et al.: Development and validation of deep learning-based automatic detection algorithm for malignant pulmonary nodules on chest radiographs. *Radiology* 2019; 290: 218–228.
- Nguyen M, He T, An L et al.: Predicting Alzheimer's disease progression using deep recurrent neural networks. *Neuroimage* 2020; 222: 117203.
- Niel O, Boussard C, Bastard P: Artificial intelligence can predict GFR decline during the course of ADPKD. *Am J Kidney Dis* 2018; 71: 911–912.
- Nilsson NJ: *The Quest for Artificial Intelligence: A History of Ideas and Achievements*. Cambridge University Press, New York 2010.
- Rapaport E, Shriki O, Puzis R: EEGNAS: neural architecture search for electroencephalography data analysis and decoding. *International Workshop on Human Brain and Artificial Intelligence*; 2019: 3–20.
- Regalia G, Onorati F, Lai M et al.: Multimodal wrist-worn devices for seizure detection and advancing research: focus on the Empatica wristbands. *Epilepsy Res* 2019; 153: 79–82.
- Rohani N, Eslahchi C: Drug-drug interaction predicting by neural network using integrated similarity. *Sci Rep* 2019; 9: 13645.
- Romm EL, Tsigelny IF: Artificial intelligence in drug treatment. *Annu Rev Pharmacol Toxicol* 2020; 60: 353–369.
- Russell S, Norvig P: *Artificial Intelligence: A Modern Approach*. 3rd ed., Prentice Hall, Upper Saddle River, NJ 2010: 1151.
- Saba V, Premi E, Cristillo V et al.: Brain connectivity and information-flow breakdown revealed by a minimum spanning tree-based analysis of MRI data in behavioral variant frontotemporal dementia. *Front Neurosci* 2019; 13: 211.
- Schmidt-Erfurth U, Sadeghipour A, Gerendas BS et al.: Artificial intelligence in retina. *Prog Retin Eye Res* 2018; 67: 1–29.
- Schork NJ: Artificial intelligence and personalized medicine. *Cancer Treat Res* 2019; 178: 265–283.
- Segato A, Marzullo A, Calimeri F et al.: Artificial intelligence for brain diseases: a systematic review. *APL Bioeng* 2020; 4: 041503.
- Son YJ, Kim HG, Kim EH et al.: Application of support vector machine for prediction of medication adherence in heart failure patients. *Healthc Inform Res* 2010; 16: 253–259.
- Varghese J: Artificial intelligence in medicine: chances and challenges for wide clinical adoption. *Visc Med* 2020; 36: 443–449.
- Vettoretti M, Cappon G, Facchinetti A et al.: Advanced diabetes management using artificial intelligence and continuous glucose monitoring sensors. *Sensors (Basel)* 2020; 20: 3870.
- Werner P, Barthel H, Drzezga A et al.: Current status and future role of brain PET/MRI in clinical and research settings. *Eur J Nucl Med Mol Imaging* 2015; 42: 512–526.