


SEBASTIAN PATRZYK
ANNA WOŹNIACKA

SZTUCZNA INTELIGENCJA W MEDYCYNIE




SEBASTIAN PATRZYK* 
ANNA WOŹNIACKA 

SZTUCZNA INTELIGENCJA W MEDYCYNIE

ARTIFICIAL INTELLIGENCE IN MEDICINE

Klinika Dermatologii i Wenerologii USK im. WAM w Łodzi, Uniwersytet Medyczny w Łodzi
sebastian.patrzyk@umed.lodz.pl, anna.wozniacka@umed.lodz.pl

* sebastian.patrzyk@umed.lodz.pl
sebastian.patrzyk@wp.pl



Seria monografii naukowych dotyczących zagadnień z zakresu dyscyplin nauk farmaceutycznych, nauk medycznych i nauk o zdrowiu.

Wydawnictwo recenzowane i punktowane na zasadach zgodnych z Rozporządzeniem MNiSW z dnia 22 lutego 2019 r. w sprawie ewaluacji jakości działalności naukowej (Dz.U. 2019 poz. 392 z późn. zm.).

RADA NAUKOWA

dr hab. Monika A. Olszewska, prof. uczelni – Redaktor naczelna
prof. dr hab. Monika Łukomska-Szymańska – Zastępca redaktor naczelnej
prof. dr hab. Iwona Cygankiewicz
dr hab. Małgorzata Pikala, prof. uczelni

REDAKTOR PROWADZĄCA

dr hab. Małgorzata Pikala

REDAKCJA JĘZYKOWA I KOREKTA

Magdalena Kokosińska, Anna Sikorska

REDAKCJA ABSTRAKTU ANGIELSKIEGO

Katarzyna Kraska

OPRACOWANIE GRAFICZNE

Tomasz Przybył

SZTUCZNA INTELIGENCJA W MEDYCYNIE

Łódź 2022

WYDAWNICTWO UNIwersYTETU MEDYCZNEGO W ŁODZI

<http://wydawnictwo.umed.pl/>

[e-mail: editorial@reports.umed.pl](mailto:editorial@reports.umed.pl)

Unikatowy identyfikator Wydawnictwa: 60000

(Komunikat Ministra Edukacji i Nauki z dnia 22 lipca 2021 r. w sprawie wykazu wydawnictw publikujących recenzowane monografie naukowe)

ISBN 978-83-67198-09-7

WYDANIE PIERWSZE



© 2022. Pewne prawa zastrzeżone na rzecz autorów. Opublikowane na licencji Creative Commons Uznanie Autorstwa (CC BY) (<https://creativecommons.org/licenses/by/4.0/legalcode.pl>).

Licencjobiorca: Wydawnictwo Uniwersytetu Medycznego w Łodzi. Zezwala się na wykorzystanie treści monografii zgodnie z licencją – pod warunkiem zachowania niniejszej informacji licencyjnej oraz wskazania autorów jako właścicieli praw do tekstu.

Spis treści

1. Wprowadzenie	8
2. Historia rozwoju sztucznej inteligencji	8
3. Medyczne bazy danych	11
4. Sztuczna inteligencja w medycynie specjalistycznej	14
4.1. Radiologia i radioterapia	14
4.2. Patomorfologia.....	16
4.3. Gastroenterologia.....	18
4.4. Dermatologia	19
4.5. Okulistyka	20
4.6. Kardiologia.....	20
5. Sztuczna inteligencja a pandemia COVID-19 – przykłady zastosowań	21
6. Sztuczna inteligencja w podstawowej opiece zdrowotnej.....	23
7. Dyskusja.....	24
Bibliografia.....	26

Streszczenie: Mianem sztucznej inteligencji określa się modele informatyczne, których działanie jest wzorowane na ludzkiej inteligencji. Należą do nich programy działające w oparciu o sztuczne sieci neuronowe, które zdolne są do samodzielnego uczenia się i poprawiania swoich wyników w rozwiązywaniu różnego rodzaju zadań, do których zostały zaprogramowane. Algorytmy sztucznej inteligencji potrafią między innymi rozpoznawać obrazy, mowę, analizować tekst pisany, co daje szerokie możliwości ich zastosowania w różnych dziedzinach nauki, wśród których wiodącą stała się medycyna. Modele matematyczne sztucznej inteligencji są rozwijane w oparciu o duże ilości danych, których w świecie medycyny bardzo szybko przybywa, a ich efektywna eksploracja i analiza przez człowieka nie jest możliwa. Programy oparte na sztucznej inteligencji mogą osiągać bardzo dobre rezultaty w wielu dziedzinach, a próby implementacji AI podejmowane są w niemal każdej gałęzi medycyny. Na całym świecie obserwuje się kolejne obiecujące wyniki prac nad nowymi jej zastosowaniami, przeznaczonymi zarówno dla specjalistów, jak i pacjentów. Obecnie rola AI w medycynie staje się coraz większa, jednak zawsze nadrzędną funkcję w korzystaniu z niej pełni człowiek.

Słowa kluczowe: sztuczna inteligencja, sieci neuronowe, deep learning, machine learning, chatbot, big data

Abstract: Artificial intelligence is defined as IT models whose operation is based on human intelligence. These include programs based on artificial neural networks, which can learn independently and improve their results in solving various types of tasks for which they have been programmed. Artificial intelligence algorithms can, among other things, recognize images, speech, analyze written text, which gives a wide range of applications in various fields of science, among which medicine has become the leading one. Artificial intelligence mathematical models are developed based on large amounts of data, which is rapidly increasing in medicine. However, their effective exploration and analysis by humans are not possible. Artificial intelligence-based programs can achieve excellent results in many areas, and attempts to implement AI are made in almost every branch of medicine. In addition, there are other promising work results on new applications dedicated to both specialists and patients all over the world. Currently, the role of AI in medicine is becoming more and more critical, but human being always plays an essential role in its use.

Keywords: artificial intelligence, neural networks, deep learning, machine learning, chatbot, big data

Wykaz skrótów

- AI** – sztuczna inteligencja (pl. SI, ang. *artificial intelligence*)
- AUC** – ang. *area under the curve*
- BIT** – technologie interwencji behawioralnej (ang. *behavioral intervention technologies*)
- BiLSTM** – Bidirectional LSTM
- CAGR** – skumulowany roczny wskaźnik wzrostu (ang. *compound annual growth rate*)
- CADe** – wykrywanie wspomagane komputerowo (ang. *computer aided detection*)
- CADx** – diagnoza wspomagana komputerowo (ang. *computer asisted diagnosing*)
- CNN** – konwolucyjne sieci neuronowe (ang. *convolutional neural networks*)
- CNV** – neowaskularyzacja naczyńówki (ang. *choroidal neovascularization*)
- DIA** – cyfrowa analiza obrazu (ang. *digital image analysis*)
- DL** – uczenie głębokie (ang. *deep learning*)
- EBM** – medycyna oparta na dowodach (ang. *evidence based medicine*)
- FDA** – Agencja Żywności i Leków (ang. *Food and Drug Administration*)
- FLAIR** – ang. *fluid-attenuated inversion recovery*
- GRUs** – gated recurrent units
- HPV** – wirus brodawczaka ludzkiego (ang. *human papilloma virus*)
- LSTM** – long short-term memory
- ML** – uczenie maszynowe (ang. *machine learning*)
- NLP** – przetwarzanie języka naturalnego (ang. *natural language processing*)
- OCT** – optyczna koherentna tomografia (ang. *optical coherence tomography*)
- PET/CT** – pozytronowa tomografia emisyjna połączona z tomografem komputerowym (ang. *positrone emission tomography/computer tomography*)
- RECIST** – kryteria oceny odpowiedzi w guzach litych (ang. *response evaluation criteria in solid tumours*)
- RNN** – rekurencyjna sieć neuronowa (ang. *recurrent neural network*)
- ROC** – krzywa oceny jakości klasyfikatora (ang. *receiver operating characteristic*)
- TNM** – klasyfikacja stopnia zaawansowania nowotworów: guz, węzeł chłonny, przerzut (ang. *tumour, node, metastasis*)
- VAE** – ang. *variational autoencoder*
- WSI** – cyfrowe obrazy całych preparatów mikroskopowych (ang. *whole slide imaging*)

1. Wprowadzenie

Współcześnie zmiany gospodarcze i społeczne spowodowane szybkim rozwojem biotechnologii i sztucznej inteligencji (ang. *artificial intelligence*, AI) są przyrównywane do rewolucji, jaką wywołało w XIX wieku wprowadzenie elektryczności. Rozwój technologiczny, w którym maszyny wykonują zadania, którymi jeszcze niedawno mógł zajmować się tylko człowiek, nie jest już przyszłością – stał się teraźniejszością.

Sztuczna inteligencja, z którą są związane techniki uczenia maszynowego, posiada zdolność samodzielnego uczenia się. Programy bazujące na AI uczą się samodzielnie rozwiązywać problemy i podejmować decyzje na podstawie dużej ilości informacji, które są zbyt obszerne i zbyt trudne do przetworzenia dla tradycyjnych systemów niewykorzystujących technologii AI. Sztuczna inteligencja jest obdarzona zdolnością do przechwytywania, przechowywania, zarządzania i analizowania olbrzymich ilości często pozornie niepowiązanych ze sobą danych. Programy oparte o AI wykonują wiele czynności, aby realizować zadania, do których zostały zaprogramowane, a przetwarzanie danych jest wykonalne dzięki dużym możliwościom operacyjnym komputerów. Systemy te mogą w pewnym stopniu autonomicznie się ulepszać, poprawiać swoje rezultaty. Sztuczna inteligencja szybko zajęła szczególne miejsce nie tylko w życiu codziennym człowieka, ale również w medycynie.

2. Historia rozwoju sztucznej inteligencji

Skonstruowanie komputera w latach 40. XX wieku bezsprzecznie zainicjowało nowy rozdział w historii ludzkości i znacznie przyczyniło się do postępu cywilizacyjnego. Jednocześnie odkrycie to, w miarę dalszego rozwoju ery komputerów, coraz częściej prowokowało do pytania o granicę możliwości maszyn oraz o to, czy są one zdolne rozwinąć inteligencję zbliżoną do ludzkiej.

Idea twórców przypominających swoim zachowaniem i myśleniem człowieka tkwiła w ludzkiej wyobraźni od zarania dziejów i była obecna w formie starożytnych mitów i średniowiecznych legend, a także w literaturze (np. Homunculus w dramacie *Faust* J.W. Goethego).

Stopniowy rozwój techniki zmieniał wyobrażenie ludzi na temat alternatywnych form inteligencji i sprawił, że wkrótce coraz częściej przybierały one formę maszyn, takich jak np. roboty.

Chociaż za autora słowa „robot” uważa się czeskiego pisarza Karela Čapka, autora sztuki *R. U. R.* („Rossumovi Univerzální Roboti”) z 1920 roku, to we wspomnianym utworze termin ten odnosił się raczej do sztucznych biologicznych twórców, które mogą być mylone z ludźmi. Słowo „robot” w pełni swego współczesnego znaczenia jako rodzaj maszyny pojawiło się w kulturze za sprawą serii opowiadań science fiction pt. *Roboty* autorstwa Isaaka Asimova, z których pierwsze pt. *Runaround* zostało opublikowane w 1942 roku. Nowe trendy w literaturze zbiegły się w czasie z działaniami angielskiego matematyka Alana Turinga, który opracował elektromechaniczne urządzenie uważane za protoplastę współczesnych komputerów – maszynę o nazwie *The Bombe*. Była ona zdolna do odszyfrowywania kodu niemieckiej maszyny szyfrującej Enigma podczas II wojny światowej. Do jej powstania przyczyniły się wcześniejsze dokonania polskich matematyków: Mariana Rejewskiego, Jerzego Różyckiego i Henryka Żygalskiego, którzy opracowali pierwsze urządzenie służące rozszyfrowywaniu Enigmy, nazwane przez nich bombą kryptologiczną. Umiejętności *The Bombe*, urządzenia znacznie bardziej zaawansowanego od swego polskiego poprzednika i przewyższającego umiejętności nawet najzdolniejszych ówczesnych matematyków, skłoniły jej twórcę do refleksji nad inteligencją maszyn. Turing uczestniczył także w innych projektach, między innymi w tworzeniu bardziej zaawansowanej maszyny do kryptoanalizy – *Colossus*. W 1950 roku opublikował artykuł pt. *Computing Machinery and Intelligence*, w którym opisał, jak stworzyć inteligentną maszynę oraz w jaki sposób testować jej inteligencję. Podstawą testu była ocena dialogu, jaki prowadzi maszyna z rozmówcą. W założeniu obie strony posługują się językiem naturalnym. Kryterium zdania testu przez maszynę według Turinga było „oszukanie” co najmniej 30% osób oceniających 5-minutową rozmowę, to jest przekonanie ludzi, że ich rozmówcą jest drugi człowiek (Turing, 1950).

Test ten w różnych modyfikacjach ma zastosowanie także w czasach współczesnych. Turing zakładał, że przy ciągłym postępie technicznym około 2000 roku pojawią się urządzenia zdolne

przejsć test pozytywnie. Obecnie wiemy już, że test po raz pierwszy przeszedł pomyślnie w 2014 roku algorytm o imieniu Eugene Goostman udający nastolatka pochodzącego z Odessy (Masche i Le, 2018).

Pojęcie „sztuczna inteligencja” zostało oficjalnie zaakceptowane w 1956 roku, kiedy Marvin Minsky i John McCarthy, dwaj amerykańscy informatycy, byli gospodarzami konferencji dotyczącej sztucznej inteligencji (Dartmouth Summer Research Project on Artificial Intelligence, DSRPAI) w Dartmouth College New Hampshire (McCarthy, Minsky i Rochester, 2006).

Warsztaty, które wyznaczały początek AI i zostały sfinansowane przez Rockefeller Foundation, zjednoczyły tych, którzy później zostali uznani za ojców założycieli AI. Uczestnikami spotkania byli także Nathaniel Rochester, który zaprojektował później IBM 701 – pierwszy komercyjny komputer naukowy, oraz matematyk Claude Shannon, jeden z twórców teorii informacji. Ambicją DSRPAI było zjednoczenie badaczy z różnych dziedzin, tak by stworzyć nowy obszar badawczy mający na celu budowę maszyn zdolnych do symulacji ludzkiej inteligencji (Haenlein i Kaplan, 2019; McCarthy, Minsky i Rochester, 2006). W ciągu kolejnych dwóch dekad obserwowano znaczny postęp w badaniach nad sztuczną inteligencją. Przykładem może być opracowany między 1964 a 1966 r. przez Josepha Weizenbauma program ELIZA – jeden z pierwszych programów komputerowych symulujących rozmowę maszyny z człowiekiem, który pomimo swej prostoty mógłby pozytywnie przejść test Turinga (Swain i Cara, 2019).

Innym sukcesem w badaniach nad AI okazał się program General Problem Solver, stworzony w 1957 roku przez Herberta A. Simona, Cliffa Shawa i Allena Newella, który rozwiązywał określone proste problemy, takie jak na przykład układanka „Wieże Hanoi” (General Problem Solver, 2021).

W 1970 roku Marvin Minsky w wywiadzie dla „Life Magazine” stwierdził, że w ciągu kolejnych 3 do 8 lat powstanie system dorównujący inteligencją człowiekowi (Forbus, Kuipers i Lieberman, 2016). Takie słowa mogły rozbudzić wielkie nadzieje wobec rozwijającej się błyskawicznie technologii. Późniejszy okres był jednak mniej obfity w sukcesy, a przynajmniej nie na skalę, jakiej się wcześniej spodziewano. W tym czasie toczyły się otwarte dyskusje nad sensem kolejnych dotacji rządowych na rzecz nowych projektów związanych z AI. Rząd brytyjski, a w ślad za nim również amerykański, ograniczył fundusze przekazywane uniwersytetom na kolejne badania, co poskutkowało kilkuletnim okresem zastoju.

Jednym z powodów początkowego braku postępu w dziedzinie AI był sposób, w jaki wczesne systemy, takie jak ELIZA i General Problem Solver, próbowały odtworzyć ludzką inteligencję. W istocie były one systemami eksperckimi (ang. *expert systems*), to znaczy zbiorami reguł, które zakładają, że ludzka inteligencja może zostać sformalizowana i zrekonstruowana na zasadzie serii stwierdzeń „jeśli..., to...”. Systemy eksperckie mogą bardzo dobrze radzić sobie w obszarach, które nadają się do takiej formalizacji. Na przykład program do grania w szachy Deep Blue firmy IBM, który w 1997 roku był w stanie pokonać mistrza świata Garriego Kasparowa, był systemem właśnie tego typu (IBM, 2021a).

Systemy eksperckie słabo natomiast radzą sobie w obszarach, które nie nadają się do takiej formalizacji. Przykładowo, bardzo trudno jest wyszkolić system ekspercki w rozpoznawaniu twarzy, a nawet w rozróżnianiu innych obrazów, na przykład sylwetki człowieka od kształtu hydrantu. W przypadku takich zadań konieczne jest, aby system był w stanie poprawnie interpretować dane zewnętrzne, uczyć się na podstawie takich danych i wykorzystywać te zdobycze do osiągnięcia określonych celów i zadań dzięki elastycznej adaptacji – cechom definiującym AI. Systemy eksperckie, które nie posiadają tych cech, z technologicznego punktu widzenia nie są we współczesnym rozumowaniu prawdziwą sztuczną inteligencją (Haenlein i Kaplan, 2019).

Zagadnienie statystycznych metod osiągnięcia prawdziwej sztucznej inteligencji zostało poruszone już w latach 40. XX wieku, kiedy kanadyjski psycholog Donald Hebb opracował teorię uczenia się, znaną jako postulat Hebba, będącą próbą wyjaśnienia plastyczności synaptycznej i adaptacji neuronów mózgowych podczas procesu uczenia się. Teoria ta była podstawą poglądu naukowego, który dowodził, że ślady pamięciowe (engramy) w ludzkim mózgu, analizowane z poziomu całościowego, są sieciami neuronowymi. Doniesienia te skłoniły naukowców do badań nad sztucznymi sieciami neuronowymi, opartymi na sygnale elektrycznym. Postęp prac był jednak ograniczony brakiem wystarczającej mocy obliczeniowej przez ówczesne komputery, przez co tworzone sztuczne sieci

neuronowe były dość uproszczone. Przykładem takiej sieci jest ADALINE (Adaptive Linear Neuron lub późniejsze Adaptive Linear Element). Jest to wczesna jednowarstwowa sztuczna sieć neuronowa i nazwa fizycznego urządzenia, które zaimplementowało tę sieć (Anderson i Rosenfeld, 2000) oraz jej późniejsza, trójwarstwowa wersja – MADALINE (Many ADALINE), która przez wiele lat znajdowała zastosowanie na przykład przy usuwaniu efektu echa podczas rozmów telefonicznych. Zaczęto ją także wykorzystywać w medycynie podczas anulowania zapisu bicia serca matki w elektrokardiografii płodowej. Modyfikacja ta ułatwiała odczyt tętna płodu (Widrow i Winter, 1988).

Z czasem zaczęły pojawiać się komputery o coraz większej mocy obliczeniowej, a to z kolei umożliwiało coraz szybszy rozwój sztucznych sieci neuronowych oraz innych technologii uczenia maszynowego (ang. *machine learning*, ML) i głębokiego (ang. *deep learning*, DL).

Technika uczenia maszynowego, będąca podrodzajem AI, jest związana z analizą danych i programowaniem eksploracji danych (ang. *data mining*). Wykorzystuje ona algorytmy matematyczne do wykrywania wzorców w zbiorach danych – analizuje je i na tej podstawie pozwala na przewidzenie rezultatu lub podjęcie decyzji. Uczenie głębokie to obszar uczenia maszynowego oparty na wspomnianych wcześniej sztucznych sieciach neuronowych.

Zasadniczą różnicą między *deep learning* i *machine learning* jest to, że uczenie głębokie może działać w sposób kompleksowy bez tzw. etapów modelowania cech (ang. *feature modeling steps*), które są zwykle uciążliwe. W DL odpowiednie modele cech mogą również „być nauczone” na podstawie dostarczonych danych (Chang i in., 2019). W konsekwencji (w pewnym uproszczeniu) oznacza to, że dane, na których opierają się mechanizmy uczenia głębokiego, nie muszą być odpowiednio ustrukturyzowane, a system może przetwarzać je niezależnie od ich postaci.

Tabela 1. Wybrane pojęcia związane z zagadnieniem sztucznej inteligencji.

Sztuczna inteligencja	Zdolność maszyn takich jak komputery do naśladowania ludzkiej inteligencji
Uczenie maszynowe (ang. <i>machine learning</i>)	Algorytmy i modele statystyczne, które są zaprogramowane do uczenia się na podstawie danych, a tym samym są zdolne do rozpoznawania i wnioskowania występujących w nich wzorców (El Naqa i Murphy, 2015).
Nauka nadzorowana (ang. <i>supervised learning</i>)	Dotyczy zadań uczenia maszynowego, w których celem jest zidentyfikowanie funkcji, która najlepiej łączy zestaw danych wejściowych (takich jak np. obraz) z ich odpowiednimi danymi wyjściowymi (etykieta). Jest to oparte na uczeniu się lub treningu na wcześniej przygotowanych parach. Jego przeciwieństwem jest uczenie się bez nadzoru (ang. <i>unsupervised learning</i>), w którym nowe wzorce, takie jak grupy lub „klastry”, są identyfikowane w danych bez wpływu wcześniejszej wiedzy lub etykiet (IBM, 2021b).
Sieć neuronowa (ang. <i>neural network</i>)	Forma nadzorowanego uczenia maszynowego inspirowana biologią, w której dane przechodzą przez szereg połączonych ze sobą neuronów, które są indywidualnie ważone w celu przewidywania. Podczas uczenia się dane przechodzą przez sieć w sposób iteracyjny, a wagi są stale dostosowywane, aby zoptymalizować zdolność dopasowania etykiety do danych (Wang, 2003).

Tabela 1. Wybrane pojęcia związane z zagadnieniem sztucznej inteligencji (cd.)

Uczenie głębokie (ang. <i>deep learning</i>)	Odnosi się do sieci neuronowej z wieloma warstwami „neuronów”, które mają regulowane wagi (funkcje matematyczne). Technologia wykorzystywana szeroko w rozpoznawaniu mowy oraz obrazów, a także mechanizmach decyzyjnych i analizie danych (Zhang W.J. i in., 2018).
Konwolucyjna sieć neuronowa (ang. <i>convolutional neural network, CNN</i>)	Rodzaj sieci neuronowej złożonej z kilku warstw. Nazwa pochodzi od matematycznej operacji liniowej między macierzami zwanej konwolucją (inaczej splotem). Tego typu sieci potrafią filtrować części danych i wyodrębnić istotne cechy. Mogą być wykorzystywane na przykład w klasyfikacji wzorów (obrazów), między innymi w medycynie (Albawi, Mohammed i Al-Zawi, 2017).
Nadmierne dopasowanie (ang. <i>overfitting</i>)	Częsty problem w uczeniu maszynowym, który polega na tym, że model ma wysoką dokładność podczas testowania na danych z tego samego źródła co dane szkoleniowe, ale jego wydajność nie przekłada się na nowe źródła danych (Dietterich, 1995).
Uczenie multimodalne (ang. <i>multi-modal learning</i>)	Modele głębokiego uczenia korzystające z różnego rodzaju danych jednocześnie, takich jak tekst, obrazy, elektroniczne dane medyczne (Shorten, Khoshgoftaar i Furht, 2021).

W ciągu ostatnich dwóch dekad pojawiło się wiele systemów wykorzystujących sztuczną inteligencję, a razem z nimi – kolejne sukcesy. AI pokonała człowieka w popularnym amerykańskim teleturnieju „Jopardy!” w 2011 roku (Chandrasekar, 2014) i w wielu grach planszowych, takich jak Go w 2015 roku (Silver, 2017). Współczesne programy AI dobrze rozumieją ludzką mowę i chociaż pozytywne przejście testu Turinga nadal bywa przedmiotem kontrowersji, to z powodzeniem mogą zaplanować podróż, zamówić posiłek czy sprawdzić pogodę. Obecność AI w życiu codziennym staje się faktem, jest ona z nami przez cały dzień w naszych smartfonach, telewizorach czy samochodach. Algorytmy AI od wielu lat filtrują spam w naszych skrzynkach pocztowych, dobierają reklamy i proponują takie treści, które mogą nas zaintrygować. AI przybrała postać wszechstronnego i wszechobecnego asystenta ułatwiającego codzienne funkcjonowanie, lecz jest również obecna w wielu innych, różnorodnych dziedzinach, spośród których jedną z wiodących stała się medycyna.

Pierwsze realne pomysły wykorzystania AI w medycynie do rozwiązywania problemów i podejmowania decyzji klinicznych pojawiły się w Stanach Zjednoczonych już w latach 70. XX wieku i były omawiane między innymi podczas serii warsztatów w Rutgers w 1975 roku (Kulikowski, 2019). Efekty wymiany poglądów i pomysłów między badaczami zajmującymi się medycyną kliniczną i AI zostały następnie streszczone w książce *Artificial Intelligence in Medicine* pod redakcją Petera Szolovitsa (Szolovits, 1982; Kulikowski, 2019). Pierwsza europejska konferencja poświęcona wyłącznie sztucznej inteligencji w medycynie (Artificial Intelligence in Medicine, AIME) odbyła się w Pawii (Włochy) w 1985 roku i od tego momentu odbywa się corocznie w różnych europejskich miastach. Wybrane prace prezentowane podczas konferencji są publikowane w założonym w 1998 czasopiśmie „Artificial Intelligence in Medicine” (Peek i in., 2015).

3. Medyczne bazy danych

Należy zaznaczyć, że dużą rolę dla dalszego rozwoju AI odegrała możliwość przechowywania ogromnych zasobów danych w formie cyfrowej, określanych mianem big data, których analiza przez człowieka bez pomocy maszyny jest niemożliwa. W dobie Internetu różnorodne zasoby wiedzy medycznej z całego świata są gromadzone w bazach, takich jak na przykład PubMed, stworzony przez US National Library of Medicine i zawierający ponad 30 milionów publikacji i streszczeń z innych medycznych baz danych oraz czasopism.

Jednym z wielu przykładów rzetelnego gromadzenia i systematyzowania danych jest też The Cancer Genome Atlas, który powstał w 2006 roku jako inicjatywa amerykańskiego National Cancer Institute i National Human Genome Research Institute. Jest to interdyscyplinarny program

skupiający specjalistów z różnych dziedzin, którego efektem było utworzenie publicznie dostępnej bazy zawierającej 2,5 petabajta danych dotyczących genetyki, epigenetyki, transkrypcji i proteomiki nowotworów, wśród których znajdują się liczne cyfrowe obrazy histopatologiczne odpowiadające poszczególnym mutacjom (National Cancer Institute, 2020).

W wielu dziedzinach medycyny już od lat konsekwentnie są tworzone bazy ustrukturyzowanych danych, jak np. obrazy siatkówki w okulistyce, całodobowe zapisy EKG w kardiologii, tomogramy w radiologii itp. To właśnie eksploracja takich danych (ang. *data mining*), ich wydobywanie i zaawansowana analiza umożliwiają maszynom uczenie się.

Liczba danych medycznych stale wzrasta. Według prognoz International Data Corporation (IDC) z 2018 roku sponsorowanych przez Seagate Technology objętość dużych zbiorów danych w sektorze opieki zdrowotnej wzrośnie szybciej niż w innych sektorach w ciągu najbliższych kilku lat. Liczba tych danych będzie rosła szybciej niż w sektorze produkcji, usług finansowych lub mediach i do 2025 roku informacje te istotnie wpłyną na wzrost wskaźnika określonego jako skumulowany roczny wskaźnik wzrostu (ang. *compound annual growth rate, CAGR*), który szacowany jest na 36%. Dla porównania prognozuje się, że dane w przemyśle wytwórczym osiągną CAGR na poziomie 30%, dane dotyczące usług finansowych będą rosły w tempie 26% rocznie, a dane w przemyśle medialnym i rozrywkowym wzrosną o 25% na rok (Kent, 2018). W 2010 roku szacowano, że co 26 sekund w świecie pojawia się nowa publikacja medyczna (Garba i in., 2010). W samej bazie Medline w 2017 roku odnotowano ponad 760 tysięcy nowych cytowań (National Library of Medicine, 2021a). W roku 2020 było to już ponad 898 tysięcy cytowań. Dla porównania w 2000 roku było to około 485 tysięcy cytowań. Są to treści z ponad 5200 czasopism z całego świata pisane w około 40 językach (National Library of Medicine, 2021a).

Poza specjalistycznymi artykułami naukowymi do danych medycznych zaliczane są raporty histopatologiczne, wyniki badań laboratoryjnych, zdjęcia radiologiczne, nagrania wideo i głosowe. Ponadto danymi medycznymi są również dane z urządzeń takich jak smartwatche, aplikacje na smartfony, urządzenia pomiarowe monitorujące na przykład przebyty dystans w ciągu dnia, spalone kalorie, rytm serca, ciśnienie tętnicze, saturację, poziom glikemii oraz dane z aplikacji prozdrowotnych na urządzeniach mobilnych. Wiele z nich jest obecnie traconych lub nie w pełni wykorzystywanych, choć zwraca się coraz większą uwagę na drzemiący w nich potencjał. Oszacowano, że człowiek w ciągu swojego życia generuje aż 1100 terabajtów danych określanych jako „egzogenne”, to jest dotyczących jego edukacji, kariery zawodowej, stanu cywilnego, statusu społecznego, zdrowia psychicznego, ubezpieczenia społecznego i świadczeń opieki społecznej, domowych systemów monitorowania i wielu innych. Oprócz tego 6 terabajtów wygenerowanych w ciągu ludzkiego życia to dane genetyczne, a 0,4 terabajta to dane takie jak elektroniczna dokumentacja medyczna, w tym wyniki wszystkich badań wykonanych podczas życia pacjenta (dane kliniczne) (Ahmed i in., 2017).

Tak duży przyrost potencjalnie przydatnych danych wiąże się z koniecznością odpowiedniego zarządzania nimi. Z technologicznego punktu widzenia powszechna dostępność dużych zbiorów tekstów i czasopism biomedycznych sprawiła, że konieczne stało się opracowanie lepszych algorytmów przetwarzania języka naturalnego (ang. *natural language processing, NLP*) do automatycznego klasyfikowania i interpretacji dużej liczby danych i wiedzy zawartych w Internecie (Kulikowski, 2019). NLP jest działem nauki z pogranicza lingwistyki, informatyki i sztucznej inteligencji. Dzięki rozwojowi NLP komputery stają się zdolne „zrozumieć” zawartość dokumentów, również znaczenia kontekstowe. Technologia ta może następnie dokładnie wyodrębnić potrzebne informacje i spostrzeżenia zawarte w dokumentach, a także kategoryzować i organizować same dokumenty.

Pomimo szybkiego rozwoju AI musimy być świadomi jej licznych ograniczeń. Obecnie uczenie maszynowe to nadal proces ograniczony do wybranych, dość wąskich dziedzin i zależny od przeznaczenia danego programu. Zrozumienie przez systemy informatyczne kompletnych tekstów, w przeciwieństwie do „eksploracji tekstu” na przykład w celu znajdowania i wyszukiwania artykułów według słów lub fragmentów tekstu (takich jak słowa kluczowe lub nazwane tematy), poczyniło istotne postępy, jednak pozostaje otwartym problemem dla nauki, ponieważ nasza ludzka percepcja, funkcje poznawcze, lingwistyczne i mentalne modele tego, co stanowi ludzkie rozumienie, są nadal znacznie szersze od możliwości AI (Kulikowski, 2019).

Praca lekarzy specjalistów jest w dużej mierze rutynowa – dotyczy grup pacjentów z konkretnymi chorobami, opiera się na wypracowanych schematach diagnostycznych i terapeutycznych. Problemem stają się pacjenci, których objawy lub reakcja na leczenie odbiegają od spodziewanego scenariusza. Lekarz prowadzący terapię niejednokrotnie przerywa ją, porzuca ciężące na nim inne zadania i rozpoczyna poszukiwania – przegląda podręczniki, samodzielnie analizuje zasoby w Internecie, sięga po konsultacje specjalistów z innych wąskich dziedzin. Jest to proces bardzo czasochłonny i nie zawsze efektywny. Po wpisaniu danego zagadnienia w wyszukiwarkę Google lub bazę PubMed można uzyskać ogromną liczbę rekordów, z których tylko niewielka część odnosi się do istoty zgłębianego problemu, a ich przegląd zajmuje bardzo dużo czasu. W efekcie istnieje duża przepaść między naukowcami generującymi wiedzę a ludźmi, którzy mają te osiągnięcia zastosować w praktyce. Potrzebny jest zatem system, który umożliwiłby łatwiejsze korzystanie z ogromnych zasobów wiedzy obecnych w Internecie. Naprzeciw tym oczekiwaniom wychodzą narzędzia takie jak Watson Health, wykorzystujący sztuczną inteligencję do eksploracji danych. Jest to szeroki, interdyscyplinarny projekt, w ramach którego powstaje między innymi oprogramowanie zdolne do czytania literatury medycznej i identyfikacji problemów, które są semantycznie powiązane z dowolnymi medycznymi zagadnieniami. AI może określać miarę klinicznego podobieństwa między pacjentami. Umożliwia to np. innym badaczom tworzenie dynamicznych kohort pacjentów, w których poszczególne osoby mogą być w różnym czasie włączane lub wyłączane z danej grupy. W kohortach statycznych raz włączona jednostka pozostaje tam na stałe. Program ułatwia również zrozumienie, która ścieżka opieki działa lepiej dla danej grupy pacjentów.

Ważnym obszarem, w którym rozwija się rozwiązania bazujące na sztucznej inteligencji, są badania kliniczne. W 2020 roku na świecie zarejestrowanych było ponad 346 000 badań (National Library of Medicine, 2021b) Dla przykładu, w Stanach Zjednoczonych zaledwie około 3% dorosłych pacjentów onkologicznych uczestniczy w badaniach klinicznych (English i in., 2010). Rekrutacja i włączanie odpowiednich pacjentów jest trudnym zadaniem między innymi ze względu na skomplikowane protokoły, liczące niekiedy ponad 100 stron. Program Watson For Clinical Matching jest zdolny do analizowania nieustrukturyzowanych danych, takich jak kryteria kwalifikacji do próby klinicznej – na ich podstawie przygotowuje listę wyselekcjonowanych badań wraz z dowodami klinicznymi, które trafiają do lekarza. Ułatwia to włączanie nowych pacjentów do odpowiednich badań klinicznych (IBM, 2021c).

Wykorzystanie sztucznej inteligencji do analizy danych medycznych umożliwia podejmowanie indywidualnych decyzji terapeutycznych oraz upowszechnianie wśród lekarzy najlepszych praktyk w oparciu o medycynę opartą na dowodach (ang. *evidence based medicine*, EBM) (IBM, 2021d).

Nauki omiczne to dyscypliny zmierzające do wyjaśnienia biologiczno-chemicznych zasad funkcjonowania organizmu przy użyciu nowoczesnych metod chemicznych (np. metod spektroskopowych i spektrometrycznych) i metod biologii molekularnej (np. PCR – reakcja łańcuchowa polimerazy). Funkcjonalną jednostką informacji i charakterystyki biochemicznej badanej substancji jest np. proteom – wszystkie proteiny w badanej próbce (Jurowski, 2021). Technologie „omiczne” są relatywnie nową dziedziną badań, takich jak genomika, proteomika lub metabolomika. W badaniach tych analizuje się duże ilości danych, ponieważ w ten sposób można oceniać całe genomy, proteomy lub metabolomy. Z tego względu głównym elementem badań „omicznych” jest technologia informacyjna (Technologie „omiczne”, 2021).

PANDA-view to łatwe w użyciu i wielofunkcyjne narzędzie do analizy statystycznej i wizualizacji danych omicznych, zwłaszcza ilościowych danych proteomiki. Może obsługiwać zarówno oznakowane, jak i wolne od etykiet dane ilościowe. Oprócz powszechnie stosowanych metod wizualizacji danych PANDA-view implementuje wielopoziomową reprezentację wyników kwantyfikacji PANDA, która jest pomocna dla użytkowników końcowych w szczegółowym zbadaniu i ręcznej walidacji danych (Chang i in., 2018).

Pomyślność badań dotyczących poznania etiopatogenezy różnych chorób i opracowania strategii terapeutycznych wymaga znacznych zasobów finansowych niezbędnych do wyszukiwania, gromadzenia i interpretacji danych. Jest to proces nie tylko pracochłonny, ale również długotrwały. PandaOmics jest niezwykle wartościowym oprogramowaniem pomocnym w identyfikacji celu. Jest ono zdolne do interpretacji danych typu OMICS w powiązaniu ze wszystkimi danymi generowanymi

przez społeczność naukową. Wyrafinowane algorytmy sztucznej inteligencji sugerują realne hipotezy dotyczące punktów uchwytu nowych leków, co znacznie skraca czas potrzebny do osiągnięcia celu.

PandaOmics potrafi wykonywać skomplikowane zadania potrzebne do zrozumienia dużej liczby pozornie niepowiązanych ze sobą danych, np. genetycznych. Przykładem takich działań jest tzw. analiza szlaków biologicznych. Oprogramowanie przekształca listę na pierwszy rzut oka niepołączonych ze sobą genów w spójną historię opartą na rozregulowanych procesach molekularnych. Metoda działania tych narzędzi polega na gromadzeniu i wykorzystywaniu wiedzy obejmującej funkcjonowanie biomolekularne oraz testy statystyczne i inne algorytmy (García-Campos, Espinal-Enríquez i Hernández-Lemus, 2015). PandaOmics wykorzystuje zastrzeżoną metodę analizy szlaków o nazwie iPanda do wnioskowania o aktywacji lub hamowaniu szlaku. Wyniki opublikowane w „Nature Communications” w 2016 roku wykazały, że algorytm jest zdolny do tworzenia spójnych zestawów biologicznie istotnych biomarkerów uzyskanych na wielu zestawach danych transkryptomicznych (Insilico, 2021; Ozerov i in., 2016).

Insilico Medicine dostarcza również oprogramowanie o nazwie Chemistry42, którego zadaniem jest odkrywanie nowych molekuł, oraz InClinico – program umożliwiający przewidywanie wyników badań klinicznych. Chemistry42 to zautomatyzowana platforma uczenia maszynowego do projektowania leków, która w ciągu tygodnia może znaleźć nowe cząsteczki. Dla przykładu opisywano, że system ten umożliwił szybką identyfikację silnych inhibitorów kinazy DDR1. Cztery związki były aktywne w testach biochemicznych, a dwa zostały zwalidowane w testach komórkowych. Jeden z głównych kandydatów do dalszych badań został przetestowany na zwierzętach i wykazał korzystną farmakokinetykę u myszy (Zhavoronkov i in., 2019).

Do chwili obecnej odkrycie nowego leku wiąże się z bardzo wysokim kosztem i jest procesem długotrwałym. W ostatnich latach całościowy średni koszt wprowadzenia nowego leku na rynek wzrósł do około 2,5 miliarda dolarów, a szacowany czas do wejścia preparatu na rynek to 10–15 lat. Dlatego, oprócz tworzenia nowych molekuł, zrodził się pomysł wykorzystania sztucznej inteligencji do odkrywania nowych zastosowań dla istniejących już cząsteczek (ang. *drug repurposing*). W 2016 roku amerykańska firma Atomwise przy użyciu własnej technologii AI spośród już istniejących substancji wytypowała w ten sposób dwie cząsteczki aktywne wobec wirusa Ebola (Atomwise, 2015).

4. Sztuczna inteligencja w medycynie specjalistycznej

4.1. Radiologia i radioterapia

Jednym z kluczowych obszarów do wykorzystania sztucznej inteligencji jest analiza obrazu. Radiologia to bez wątpienia dziedzina medycyny, w której diagnoza opiera się w większości właśnie na tym procesie. Liczba zarejestrowanych do opisu obrazów zwiększa się z roku na rok, co z kolei wymusza zwiększenie efektywności pracy specjalistów. Według szacunków co roku jeden na czterech Amerykanów poddawany jest badaniu metodą tomografii komputerowej, zaś jeden na dziesięciu ma wykonywane badanie przy użyciu rezonansu magnetycznego (OECD, 2018a). Pomocą przy opracowywaniu tak dużej liczby badań mogą okazać się maszyny przeszkolone w oparciu o tysiące plików graficznych takich jak radiogramy, zdolne do wykrywania konkretnych zmian często z zaskakującą precyzją, niekiedy przekraczającą umiejętności człowieka.

Opracowywanie zautomatyzowanych rozwiązań opartych na głębokim uczeniu rozpoczyna się od rozwiązania najczęstszych problemów klinicznych, w których to dostępne są dane wystarczające, by rozwijać skomplikowane algorytmy. Problemy te mogą dotyczyć bardzo złożonych przypadków, w których potrzebna jest wiedza specjalistyczna. Wskazuje się tu przede wszystkim na odczyt tomografii komputerowej płuc, mammografii i obrazów z wirtualnej kolonoskopii (Hosny i in., 2018).

Radiolodzy w swej pracy polegają na zdobytej wiedzy oraz doświadczeniu i stale odwołują się do obrazów prawidłowych, co umożliwia im rozpoznawanie wzorów nietypowych dla stanu fizjologicznego, mogących sugerować patologię, na przykład zmianę nowotworową. Kryteria, na których opierają się specjaliści, mieszczą się w nieco subiektywnym wzorcu decyzyjnym, od którego zależy rozpoznanie często bardzo subtelných lub nieoczywistych zmian obrazowych. W miarę rozwoju

komputerów i wzrostu zależności od nich zaczęto stosować zautomatyzowane metody zwane wykrywaniem wspomaganym komputerowo (ang. *computer aided detection*, CADe). Algorytmy widzenia komputerowego na podstawie wprowadzonych kryteriów mogą wyróżniać widoczne na obrazie obiekty. Precyzja wielu systemów CADe pozostaje wątpliwa, a wysiłki podejmowane w celu ograniczenia fałszywych oznaczeń nie dawały satysfakcjonujących rezultatów. Odnajdywane i opisywane przez CADe struktury często wymagały weryfikacji i oceny radiologa, co wpływało na obniżenie ich wydajności.

W ostatnich latach podjęto próby wykorzystania uczenia głębokiego w systemach wykrywania wspomaganego komputerowo do takich zadań jak odnajdywanie guzków w płucach w tomografii komputerowej i raka stercza w obrazowaniu multiparametrycznym, zwłaszcza MRI. Choć jest to przedmiotem dalszych badań, to już obecnie CADe oparte na sieciach neuronowych przewyższają skutecznością tradycyjne systemy tego typu w wykrywaniu zmian w mammogramach, a nawet mogą dorównywać skutecznością człowiekowi (Kooi i in., 2017).

Ponadto systemy oparte na głębokim uczeniu mogą znaleźć zastosowanie w monitorowaniu wzrostu zmian nowotworowych. Obecnie, celem ułatwienia zadania lekarzom, stosuje się jednolite kryteria, takie jak RECIST (ang. *response evaluation criteria in solid tumours*), stworzone przez WHO do oceny litych guzów. Metoda ta, kosztem pewnych uproszczeń, pozwala na zmniejszenie nakładu pracy lekarza i ilości danych, z którymi musi się on mierzyć przy korzystaniu z tego rodzaju kryteriów. Wadą takiego rozwiązania jest wynikające ze wspomnianych uproszczeń oparcie się na nie zawsze prawdziwych założeniach (jak na przykład założenie izotropowego, tj. stałego we wszystkich kierunkach, wzrostu guza). Podczas gdy niektóre cechy zmian są bezpośrednio identyfikowalne przez ludzi (takie jak umiarkowanie duże różnice w wielkości obiektu, kształcie i kawitacji), inne – obejmujące subtelne zmiany tekstury i niejednorodności w obiekcie – już nie. Mogą one również wpływać na ocenę rozwoju guza. Architektury głębokiego uczenia, takie jak rekurencyjne sieci neuronowe, bardzo dobrze nadają się do szczegółowej analizy danych w formie sekwencji czasowych i oczekuje się, że znajdą wiele zastosowań w monitorowaniu zmian obrazowych, dzięki czemu uzupełnią pracę człowieka (Hosny i in., 2018). Dane z literatury oraz postęp w tej dziedzinie pozwalają wierzyć, iż wkrótce algorytmy będą bardziej precyzyjne niż ludzie.

Sztuczna inteligencja może pomóc we wczesnej identyfikacji guzków w płucach oraz w ocenie i charakteryzowaniu różnych zmian wykrywanych przypadkowo (na przykład w wątrobie podczas badania CT), wstępnej ich kwalifikacji jako łagodnych lub złośliwych i nadaniu odpowiedniego priorytetu w postępowaniu z pacjentem.

W przypadku zadań związanych z klasyfikacją przerzutów do węzłów chłonnych w PET/CT sztuczna inteligencja charakteryzowała się wyższą czułością, ale niższą swoistością niż radiolodzy. Stanowi to punkt wyjścia do dalszych badań w tym zakresie (Wang i in., 2017).

Najczęściej na świecie wykonywane badanie obrazowe, jakim jest badanie rentgenowskie klatki piersiowej, często służy potwierdzeniu bądź wykluczeniu zmian zapalnych w płucach. Zaprojektowany pod tym kątem program CheXNet, będący 121-warstwową konwolucyjną siecią neuronową, którego model działania opracowano w oparciu o bazę liczącą przeszło 100 000 zdjęć rentgenowskich ChestX-ray14, może w tym zakresie przewyższać skutecznością oceny radiologów (Rajpurkar i in., 2017).

Ostatnie wysiłki badaczy wskazują na elastyczność głębokiego uczenia się w rekonstrukcji obrazu podczas badań MRI, co może pozwolić na skrócenie czasu badania oraz zwiększyć jakość otrzymanego obrazu. To z kolei przełoży się na większą wartość diagnostyczną wykonywanego badania. Obecnie odnotowano na tym polu nowe osiągnięcia, jak na przykład poprawę jakości obrazów uzyskiwanych w sekwencji FLAIR (ang. *fluid-attenuated inversion recovery*) MRI, która jest stosowana powszechnie do obrazowania wybranych struktur mózgu (Hagiwara i in., 2019).

Inne podejmowane próby wykorzystują nowatorskie metody sztucznej inteligencji do korygowania artefaktów, a także do rozwiązywania pewnych problemów, na przykład ograniczonego kąta tomografii komputerowej, polegającego na możliwości odtworzenia tylko części skanowanego miejsca ze względu na niezdolność skanera do wykonywania pełnych obrotów o 180° wokół obiektów (Hammernik i in., 2017).

Znamienne dokonania obserwuje się też w dziedzinie mammografii. Interwałowy rak piersi to termin określający nowotwór wykryty w ciągu 12 miesięcy od mammograficznego badania przesiewowego, w którym wyniki zostały uznane za prawidłowe. W krajach europejskich częstość jego występowania waha się od 8,4 do 21,3 przypadków na 10 000 badań screeningowych (Hofvind i in., 2018). Jest to zatem istotny problem diagnostyczny.

Lång i in. (2021) w swoich badaniach poddali analizie mammogramy screeningowe 429 kobiet, u których zdiagnozowano raka interwałowego. Obrazy zostały przeanalizowane przez system oparty na głębokim uczeniu zdolny do oceny ryzyka występowania raka od 1 do 10. Następnie dwóch doświadczonych radiologów oceniło wspólnie te mammogramy i sklasyfikowało je w 3 grupach: prawdziwie negatywne, minimalne objawy oraz fałszywie negatywne. Ocenili oni także, czy system sztucznej inteligencji prawidłowo zlokalizował nowotwór. AI powiązała z najwyższym ryzykiem raka 143 spośród 429 przypadków, z czego 67% (96/143) zostało sklasyfikowanych (przez radiologów) jako minimalne objawy nowotworu lub wyniki fałszywie negatywne. Natomiast 58% (83/143) zmian nowotworowych zostało przez AI prawidłowo zlokalizowanych, a zatem potencjalnie mogłyby być one wykryte w badaniu przesiewowym, co skutkowałoby zmniejszeniem liczby przypadków nierozpoznanego raka o 19,3%. Potencjalne zmniejszenie liczby przypadków raka interwałowego wiktanego ciężkim przebiegiem (kończącego się zgonem lub chorobą w IV stopniu zaawansowania) przy 10 stopniu ryzyka wyniosło 23% (Lång i in., 2021).

Potencjał sztucznej inteligencji może być wykorzystany także w dziedzinie radioterapii onkologicznej. Planowanie leczenia promieniowaniem można zautomatyzować poprzez segmentację guzów w celu optymalnego doboru dawki promieniowania. Ponadto do oceny rezultatów radioterapii niezbędna jest ocena odpowiedzi na leczenie monitorowana w czasie. AI jest w stanie przeprowadzić tę ocenę i poprawić w ten sposób dokładność i szybkość zadania (Sarkar i Chow, 2020).

4.2. Patomorfologia

Dzięki wprowadzeniu cyfrowego sprzętu do patomorfologii, od mikroskopów po skanery do obrazowania całych slajdów, otworzyła się droga do zautomatyzowanej diagnostyki patologicznej, wspieranej przez sztuczną inteligencję.

Obrazy biopłatów tkankowych, w przeciwieństwie np. do radiologicznych, mogą być znacznie bardziej złożone, co utrudnia ich cyfrową analizę. Bez względu na wielkość biopłatów algorytmy sztucznej inteligencji mogą analizować je z dużą dokładnością.

Cyfrowe obrazy preparatów histopatologicznych oceniane przez algorytmy sztucznej inteligencji są uzyskiwane w większości z preparatów barwionych rutynowo hematoksyliną i eozyną. Proces przygotowania preparatu jest wieloetapowy i związany z przechowywaniem preparatu w formalinie, alkoholu, acetonie. Preparat jest następnie zatapiany w parafinie, podlega skrawaniu, a następnie barwieniu. Każdy etap tego procesu oraz różne urządzenia, a następnie oprogramowanie stosowane w skanerach do obrazowania cyfrowego, mogą wpływać na jakość obrazów cyfrowych, w tym na kolor, jasność, kontrast i skalę. Aby uzyskać najlepsze rezultaty, obrazy te muszą być poddane procesowi normalizacji. Dopiero po złożonej cyfrowej obróbce jest możliwe maksymalne wykorzystanie potencjału sztucznych sieci neuronowych w ich analizie.

Jednym z przykładów zastosowania konwolucyjnych sieci neuronowych w diagnostyce histopatologicznej jest automatyczne oznaczanie podtypu raka płuca. Do tego celu wykorzystano 1635 obrazów tzw. wirtualnej mikroskopii (ang. *whole slide imaging*, WSI), to jest obrazów prezentujących całe szkiełko mikroskopowe, powstałych z połączenia wielu mniejszych obrazów z mikroskopu. Zestaw danych pochodził z The Cancer Genome Atlas (TCGA). Tak opracowany algorytm był w stanie ocenić z dużym prawdopodobieństwem, czy zmiana jest łagodna lub rozpoznać gruczolakoraka albo raka płaskonabłonkowego (Chang i in., 2019). Aby ocenić jakość klasyfikacji, posłużono się krzywą ROC (ang. *receiver operating characteristic*), której kształt zależy między innymi od odsetka wyników prawdziwie dodatnich i fałszywie dodatnich. Wartość pola powierzchni pod krzywą ROC – określana skrótowcem AUC (ang. *area under the curve*) – pozwala na ocenę dokładności automatycznego systemu klasyfikacji (Zweig i Campbell, 1993; Topol, 2019).

Uważa się, że AUC równe 0,5 sugeruje brak dyskryminacji zdolności do diagnozowania pacjentów z daną chorobą podstawie testu. AUC między 0,7 a 0,8 to dokładność dopuszczalna, 0,8 do 0,9 – doskonała, a wartość przekraczająca 0,9 – wybitna (Mandrekar, 2010).

W przypadku omawianego powyżej systemu oceny preparatów histopatologicznych osiągnięto bardzo wysoką wartość AUC równą 0,97. Co więcej, dzięki zastosowaniu metody uczenia się opartej na transferze wielozadaniowym (ang. *multi-task transfer learning*) na obrazach WSI gruczolakoraka płuca można było niezależnie określić mutacje sześciu genów (w tym KRAS, EGFR i STK11). Wykrywanie mutacji łączyło się z wysoką wartością AUC – 0,86 dla genu STK11 i AUC 0,83 dla genu EGFR (Chang i in., 2019).

Technologia *Transfer Learning* umożliwia wykorzystanie wcześniej stworzonego modelu do rozwiązywania nowego problemu. Jest to technika, a ściślej metodologia projektowania w obszarze uczenia maszynowego, często stosowana w trenowaniu sieci neuronowych w obszarach, gdzie liczba danych jest relatywnie niewielka (Tan i in., 2018). Dotyczy to między innymi medycyny, gdyż wiele zjawisk nie jest na tyle rozpowszechnionych w społeczeństwie, żeby ośrodki badawcze mogły dysponować na przykład milionami różnych obrazów przedstawiających jednego rodzaju zmianę chorobową.

Analiza przydatności AI w diagnostyce histopatologicznej wskazuje na ogromną rolę sztucznej inteligencji również w ocenie zaawansowania procesu nowotworowego. Systemy klasyfikacji (ang. *staging*), takie jak TNM (ang. *tumour, node, metastasis*) w onkologii, opierają się na danych zebranych wcześniej. Należą do nich między innymi informacje o stopniu rozwoju i naciekania zmian nowotworowych, zajęciu węzłów chłonnych oraz obecności przerzutów. Zaklasyfikowanie pacjentów do określonych kategorii pozwala na odpowiedni dobór leczenia oraz pomaga w ocenie rokowania i prognozowaniu przeżycia. *Stagingi* – ponieważ opiera się na opisach jakościowych, które często trudno jest zmierzyć ilościowo – przez pewien czas nie był postrzegany jako nadający się do automatyzacji. Zautomatyzowane określanie wielkości guza pierwotnego, okolicznych węzłów chłonnych i odległych przerzutów wymaga kombinacji różnych metod. Okazuje się, że *deep learning*, poprzez zdolność jednoczesnego uczenia się i analizy wielu danych, jest przydatny w rozwiązywaniu również wieloaspektowych problemów z klasyfikacją. Większość działań związanych z głębokim uczeniem w celu wykrywania zajęcia węzłów chłonnych i odległych przerzutów, a finalnie – uzyskania dokładnej oceny zaawansowania choroby przeprowadzono na obrazach histopatologicznych. W przyszłości planowane są również badania oparte na obrazach radiologicznych (Hosny i in., 2018).

Działania zmierzające do rozpoznania raka prostaty stały się jednym z najbardziej aktywnych pól w kontekście wykorzystania *deep learning* z powodu dużej zależności między stopniem złośliwości a morfologią tkanek. W jednym z badań zeskanowano 225 preparatów biopsyjnych stercza (biopsja igłowa), a regiony wykazujące cechy nowotworzenia wykorzystano do opracowania detektora raka. Proces detekcji oparty na CNN był prowadzony na poziomie nakładających się fragmentów obrazu histopatologicznego celem wygenerowania mapy prawdopodobieństwa. Stworzony dzięki niej skumulowany histogram prawdopodobieństwa pozwalał na ocenę stopnia złośliwości nowotworu na podstawie obrazu histopatologicznego. Metoda ta odznaczała się wysoką dokładnością (AUC 0,99).

W innych badaniach wykorzystano techniki uczenia maszynowego do oceny preparatów w skali Gleasona. Opisywana w jednej z prób dokładność oceny wynosiła 0,7, podczas gdy dokładność uzyskana przez 29 patologów była niższa – AUC 0,61. System wyszkolony w oparciu o 5759 obrazów biopsyjnych prostaty odznaczał się wysoką precyzją diagnostyczną, bowiem możliwe było odróżnienie zmiany łagodnej od złośliwej (AUC 0,99), sklasyfikowanie obrazu jako stopień 2 lub wyższy (AUC 0,978) i jako stopień 3 lub wyższy (AUC 0,974). Pod względem oceny w skali Gleasona system ten osiągnął wydajność zbliżoną do rezultatów uzyskanych przez grupę patomorfologów (Bulten i in., 2020).

Innym przykładem zastosowania sztucznej inteligencji w patomorfologii jest diagnostyka raka piersi. Nowotwór ten, z racji dużego rozpowszechnienia w populacji, stanowi wielkie wyzwanie współczesnej onkologii. Proces terapeutyczny jest planowany indywidualnie i wielopoziomowo w zależności od stopnia zaawansowania nowotworu oraz jego genetycznego uwarunkowania.

W przyszłości skomputeryzowana analiza obrazu histopatologicznego guza może usprawnić diagnostykę raka piersi i skrócić czasochłonne analizy, na przykład ocenę biomarkerów. Niektóre z nich mogą być różnicowane w zależności od lekarza wykonującego ocenę, natomiast cyfrowa analiza obrazu (ang. *digital image analysis*, DIA) zwiększa powtarzalność wyników. Ponadto opracowanie komputerowych modeli opartych na AI, służących diagnozowaniu i prognozowaniu wyników, może ułatwić podejmowanie decyzji klinicznych zgodnie z ideą medycyny spersonalizowanej (Robertson i in., 2017).

Wytrenowane na odpowiednich zasobach (obrazy i inne dane z bazy TCGA) konwolucyjne sieci neuronowe z dużą dokładnością potrafią rozróżnić glejaka wielopostaciowego od glejaka nisko zróżnicowanego, włącznie z określeniem poziomu zróżnicowania między stopniem 2 a 3 (Chang i in., 2019).

Multimodalne uczenie głębokie okazało się przydatne również do celów diagnostyki dysplazji szyjki macicy. W jednym z badań połączono wysoce niejednorodne multimodalne dane zebrane podczas wizyt przesiewowych pacjentek poprzez odpowiednie rozszerzenie konwencjonalnej struktury CNN. Algorytm korzystał z danych takich jak obrazy szyjki macicy, jak również wyniki badań cytologicznych i testów w kierunku zakażenia HPV (ang. *human papilloma virus*). Model proponowany przez autorów daje ostateczną diagnozę dysplazji szyjki macicy z czułością 87,83% przy 90-procentowej specyficzności w dużym zbiorze danych i jest znaczącym osiągnięciem w klasyfikacji na poziomie przesiewowej wizyty ambulatoryjnej (Xu, 2016).

Korbar i in. (2017) opisali stworzoną przez siebie metodę automatycznej analizy obrazu do klasyfikacji histopatologicznej polipów jelita grubego. Obejmowała ona pięć powszechnych typów polipów i była przygotowana w oparciu o bazę 458 obrazów całych preparatów mikroskopowych (WSI). Metoda ta osiągała bardzo wysoką dokładność w klasyfikacji polipów jelita grubego na całych obrazach mikroskopowych.

4.3. Gastroenterologia

Innym obszarem, w którym dostrzegany jest potencjał sztucznej inteligencji, jest gastroenterologia, gdzie AI może być wykorzystana m.in. do wykrywania i monitorowania polipów okrężnicy w prewencji rozwoju raka jelita grubego (Le, Salifu i McFarlane, 2021).

W kolonoskopii diagnostyka wspomagana komputerowo (CAD) oparta o algorytmy AI może pomóc endoskopistom w różnicowaniu polipów nowotworowych (gruczolaków) wymagających resekcji od polipów nieneoplastycznych i niewymagających resekcji. CAD działająca w czasie rzeczywistym może osiągnąć poziom wydajności pozwalający na bezpieczne diagnozowanie i pozostawianie mniejszych polipów do dalszej obserwacji (Mori i in., 2018)

Inne projektowane systemy automatycznego wykrywania polipów mają za zadanie ostrzegać endoskopistę o obecności polipa za pomocą cyfrowego markera wizualnego na ekranie lub dźwięku (Alagappan i in., 2018).

Po wykryciu zmiany w przewodzie pokarmowym analiza obliczeniowa na zasadzie wspomnianej wcześniej diagnostyki wspomaganej komputerowo (CAD) mogłaby pomóc przewidzieć obraz histologiczny polipa bez potrzeby biopsji. Dziedzina biopsji optycznej liczy sobie już kilkadziesiąt lat, lecz wykorzystanie mechanizmów głębokiego uczenia i rosnąca złożoność obliczeniowych metod analitycznych doprowadziły do istotnych osiągnięć w tym zakresie. Zdolność diagnozowania małych polipów, takich jak drobne gruczolaki *in situ* za pomocą diagnostyki optycznej, może umożliwić wycięcie gruczolaków bez weryfikacji histopatologicznej, co w efekcie pozwala na ograniczenie kosztów. W samych Stanach Zjednoczonych strategia „wytnij i pomiń” (ang. *resect and discard*) pozwala na zaoszczędzenie rocznie 33 mln dolarów (Alagappan i in., 2018).

Endocytoskopia (EC) to technika ultrawysokiego powiększenia, która generuje obrazy powierzchniowych struktur nabłonkowych w rozdzielczości na poziomie komórkowym. W 2015 roku Mori i in. (2015) opisali opracowany przez siebie system diagnostyki wspomaganej komputerowo, który wykorzystuje technikę segmentacji jądrowej i ekstrakcji cech do przewidywania klasyfikacji patologicznej zmian wykrywanych w jelicie grubym i odbytnicy (tj. zmiany nienowotworowej, gruczolaka bądź raka) i odznacza się w tym zakresie wysoką precyzją.

Sztuczna inteligencja jest też wykorzystywana do rozpoznawania krwawień z przewodu pokarmowego, wykrywania regionów błony śluzowej objętych stanem zapalnym, a nawet do diagnozowania pewnych rodzajów zapaleń przewodu pokarmowego (Alagappan i in., 2018).

4.4. Dermatologia

Powyższe przykłady świadczą o tym, iż w wielu dziedzinach medycyny istotnym zakresem do wykorzystania sztucznej inteligencji staje się diagnostyka nowotworów. Podobnie jest również w dermatologii, gdzie ocena obrazu zmian skórnych jest kluczowa w określaniu ryzyka obecności procesu nowotworowego.

Diagnozowanie raka skóry wymaga wieloletniego szkolenia. Z uwagi na duże różnicowanie rozmiarów, odcieni i tekstur zmiany skórne są często trudne do interpretacji. Zastosowanie algorytmów głębokiego uczenia, dobrze radzących sobie z taką wariancją, pozwala wykrywać cechy znacznie wykraczające poza te rozważane przez specjalistów dermatologii (Hosny i in., 2018).

W jednym z najbardziej doniosłych badań konwolucyjną sieć neuronową przeszkolono przy użyciu zestawu danych złożonego z 129 450 obrazów klinicznych – dermoskopowych i fotografii cyfrowych. Przetestowano jego skuteczność w porównaniu z oceną 21 specjalistów w zakresie dermatologii w oparciu o obrazy kliniczne potwierdzone biopsyjnie. Posłużono się dwoma kluczowymi przypadkami zastosowania binarnej, zero-jedynkowej klasyfikacji: nowotwory wywodzące się z keratynocytów w porównaniu z łagodnymi brodawkami łojotokowymi oraz czerniaki złośliwe w porównaniu z łagodnymi znamionami. Pierwszy przypadek odpowiada identyfikacji najbardziej rozpowszechnionych raków skóry, drugi – identyfikacji zmian najbardziej złośliwych. CNN osiąga wydajność na równi ze wszystkimi testowanymi ekspertami w obu zadaniach i udowadnia, że klasyfikacja raka skóry przeprowadzona przez sztuczną inteligencję może być równie trafna jak diagnoza dermatologów. Urządzenia mobilne wyposażone w inteligentne aplikacje mogą zatem potencjalnie zwiększyć zasięg działalności dermatologów poza kliniką (Esteva i in., 2017).

Można się spodziewać, że aplikacje oparte na CNN są w stanie pomóc lekarzowi ogólnemu w skuteczniejszym analizowaniu zmian skórnych i zapewnić lepszą kontrolę pacjentów.

W innym z badań konwolucyjna sieć neuronowa wyszkolona z wykorzystaniem 12 378 obrazów dermoskopowych (wyłącznie z domeny open source) pod kątem detekcji czerniaka została porównana z trafnością diagnostyczną dermatologów. Do testu użyto 100 obrazów dermoskopowych ocenianych przez 157 dermatologów z 12 szpitali uniwersyteckich w Niemczech. W teście zbadano czułość, swoistość i oceniono jakość klasyfikatora za pomocą krzywej ROC. Średnia czułość i swoistość osiągnięta przez dermatologów na obrazach dermoskopowych wyniosła odpowiednio 74,1% (zakres 40,0–100%) i 60% (zakres 21,3–91,3%). Przy średniej czułości 74,1% CNN wykazywała średnią swoistość 86,5% (zakres 70,8–91,3%). Przy średniej swoistości wynoszącej 60% algorytm osiągnął średnią czułość 87,5% (zakres 80–95%). Wśród dermatologów specjaliści pełniący funkcje kierownicze wykazali najwyższą średnią swoistość 69,2% przy średniej czułości 73,3%. Przy tak samo wysokiej specyficzności 69,2% CNN miała średnią czułość 84,5%. CNN osiągnęła wyniki przewyższające 136 ze 157 dermatologów na różnych poziomach doświadczenia (od młodszego asystenta do kierownika oddziału) (Brinker i in., 2019).

Oprócz klasyfikacji zmian pod kątem rozwoju procesu nowotworowego uczenie głębokie w dermatologii może wspomagać diagnostykę mikologiczną, czego dowodzi praca Gao i in. (2021). Autorzy opracowali zautomatyzowany mikroskop (zdolny do samodzielnego skanowania wcześniej przygotowanych fluorescencyjnych preparatów) i przeszkolili model przetwarzania obrazu oparty na sztucznej sieci neuronowej ResNet-50 (jest to jedna z kilku sztucznych sieci neuronowych chętnie wykorzystywanych między innymi w medycynie). Ogółem zgromadzono 292 preparaty mikologiczne pochodzące ze skóry, paznokci i włosów. System przeszkolony był w klasyfikowaniu obrazów diagnozujących obecność grzybów nitkowatych, drożdży/zarodników oraz obrazów prawidłowych (bez obecności grzyba). Czułość automatycznego mikroskopu do wykrywania grzybów w skórze, paznokciach i włosach wyniosła odpowiednio 99,5%, 95,2% i 60%, a swoistość – odpowiednio 91,4%, 100% i 100% (Gao i in., 2021).

4.5. Okulistyka

Systemy analizy obrazu oparte na sztucznej inteligencji znalazły również zastosowanie w ocenie i klasyfikacji zmian chorobowych w okulistyce, na przykład w obrazach dna oka. Obecnie obserwowane są znaczne postępy w dziedzinie diagnozowania chorób takich jak retinopatia cukrzycowa. Z racji stale wzrastającej liczby pacjentów z cukrzycą kluczowe znaczenie ma wykrywanie zmian na wczesnym etapie. Analiza cyfrowych obrazów przy zastosowaniu AI znacznie usprawnia ten proces.

Abràmoff i in. (2016) wykazali, że technologia głębokiego uczenia wykorzystywana w wykrywaniu retinopatii cukrzycowej (określonej w badaniu jako umiarkowana retinopatia nieproliferacyjna lub cięższa, w tym cukrzycowy obrzęk płamki) osiągnęła AUC 0,98 i czułość równą 96,8% oraz swoistość 87%. Podobnie Gargeya i Leng (2017), którzy operowali zbiorem danych liczącym ponad 75 000 obrazów, dzięki zastosowaniu walidacji krzyżowej uzyskali w swojej pracy obiecujące wyniki – AUC 0,97 oraz 0,94 i 0,95 przy wykorzystaniu dwóch niezależnych zbiorów testowych (Messidor-2 i E-Ophtha). Takie rezultaty zdaniem autorów świadczą o przydatności stworzonego przez nich systemu do przesiewowej oceny obrazu dna oka pod kątem retinopatii cukrzycowej (Gargeya i Leng, 2017).

Gulshan i in. (2016), związani z Google AI Healthcare, odnotowali wysoką skuteczność diagnostyczną innego systemu uczenia głębokiego. Został on wytrenowany w oparciu o ponad 128 000 różnych obrazów siatkówki ocenianych wielokrotnie (od 3 do 5 razy) przez 54 wykwalifikowanych specjalistów okulistyki pod kątem retinopatii cukrzycowej oraz cukrzycowego obrzęku płamki. Baza testowa składała się z około 10 000 obrazów uzyskanych z wcześniej wspomnianej bazy Messidor-2 oraz EyePACKS-1 klasyfikowanych przez 7 okulistów. AUC osiągnięte przez stworzony mechanizm wynosiło 0,991 dla bazy EyePACS-1 i 0,990 dla Messidor-2.

W innym badaniu wykorzystano potencjał sztucznych sieci neuronowych do segmentacji i klasyfikacji obrazów uzyskanych z optycznej tomografii koherencyjnej (ang. *optical coherence tomography*, OCT). Sieć segmentacyjna pozwala na wyodrębnienie 15 różnych cech morfologicznych siatkówki i artefaktów rejestrowanych w trakcie zbierania danych. Dane wyjściowe tej sieci są następnie przekazywane do sieci klasyfikacyjnej, która odpowiada za decyzyjny triage (badanie pilne, umiarkowanie pilne, rutynowe i obserwacja) oraz klasyfikację 10 różnych patologii (neowaskularyzacja naczyńki, ang. *choroidal neovascularization* – CNV, obrzęk płamki bez CNV, druzy, zanik geograficzny, błona nasiatkówkowa, trakcja szklistkowo-siatkówkowa, pełnej grubości otwór w płamce, otwór w płamce o niepełnej grubości, centralna retinopatia surowicza oraz stan „normalny”). Zgodnie z powyższym podejściem wyniki otrzymane w tych zadaniach klasyfikacyjnych określono jako dorównujące wynikom ekspertów. W dłuższej perspektywie system mógłby być używany do selekcji pacjentów poza szpitalem, a nawet gabinetem lekarskim, zwłaszcza że już obecnie z systemów OCT coraz częściej korzystają optometryści (Ting i in., 2018).

Obniżenie ciśnienia wewnątrzgałkowego pozwala na opóźnienie progresji zaćmy, ale optymalizacja metod terapeutycznych do różnych form zaćmy wciąż jest wyzwaniem i nie zawsze przynosi spodziewane efekty. Kazemian i in. (2017) opracowali kliniczne narzędzie służące prognozowaniu przebiegu tej choroby. Wykorzystuje ono dane tonometryczne oraz dotyczące pola widzenia przy różnych wartościach docelowych ciśnienia wewnątrzgałkowego.

Być może zastosowanie uczenia maszynowego czerpiącego dane z całego genomu i biorącego pod uwagę szereg innych zmiennych, takich jak styl życia i choroby towarzyszące, pozwoli w przyszłości stworzyć jeden algorytm przydatny do prognozowania ryzyka, leczenia inwazyjnego lub stopnia upośledzenia widzenia z powodu jaskry (Ting i in., 2018).

4.6. Kardiologia

Kolejną dziedziną, w której z powodzeniem implementowane są technologie z zakresu AI, jest kardiologia. Część osiągnięć jest związana z postęпами dokonywanymi w radiologii. Na przykład klasyfikatory sieci neuronowych mogą ułatwić wykrywanie wzorców zastoinowej niewydolności serca na radiogramach klatki piersiowej (Seah i in., 2019). Mogą być również przydatne do automatycznej klasyfikacji obrazów wewnątrznaczyniowej koherentnej tomografii optycznej tętnic wieńcowych w chorobie Kawasaki, w której system osiąga dokładność prawie 90% (Abdolmanafi i in., 2020).

Poza tym AI jest szeroko wykorzystywana do segmentacji lewej i prawej komory w diagnostyce MRI, a konkretnie – do takich zadań jak lokalizacja wsierdza i pomiaru jego grubości oraz uwidaczniania różnych struktur anatomicznych.

W jednym z badań, mającym na celu klasyfikację obrazów echokardiograficznych (baza danych złożona z 8 000 obrazów), głęboka sieć neuronowa z dużą precyzją diagnozowała kardiomiopatię przerostową (AUC 0,93), amyloidozę serca (AUC 0,87) i nadciśnienie płucne (AUC 0,85) (Zhang i in., 2018).

Od ponad 100 lat standardowe 12-odprowadzeniowe badanie elektrokardiograficzne (EKG) służy do rutynowej oceny stanu układu bódźprzewodzącego i funkcji serca. Postęp technologiczny, jaki dokonał się w ostatnich latach, zrewolucjonizował EKG w dwóch aspektach. Pierwszy dotyczy struktury samego urządzenia rejestrującego czynność mięśnia sercowego z powierzchni skóry. Konstrukcja urządzenia zmieniła się w taki sposób, że rejestrujące sensory mogą być mniejsze, bardziej czułe, bezprzewodowe, mogą stanowić element garderoby pacjenta (ang. *wearable device*), rejestrować i przysyłać sygnały na odległość przez całą dobę. Drugi aspekt dotyczy opracowania algorytmu komputerowego opartego na AI, który jest zdolny do wykrycia subtelnych zmian w zapisie i autonomicznej interpretacji zarejestrowanych danych. Sieci neuronowe, uczone na podstawie analizy wielu tysięcy wzorców (zapisów EKG), są w stanie bardziej precyzyjnie aniżeli oko specjalisty kardiologa wychwycić określone anomalie. Jesteśmy więc świadkami nowej ery elektrokardiologii, nieinwazyjnej metody oceny stanu krążenia (Kashou, May i Noseworthy, 2020).

Obecnie FDA zatwierdziła co najmniej kilka aplikacji dla urządzeń mobilnych służących między innymi wykrywaniu napadów migotania przedsionków.

5. Sztuczna inteligencja a pandemia COVID-19 – przykłady zastosowań

Na początku 2020 roku pojawiło się niespodziewane nowe globalne zagrożenie dla zdrowia w postaci wirusa SARS-CoV-2 wywołującego chorobę COVID-19. Epidemia stała się wielkim wyzwaniem dla systemów ochrony zdrowia, a do walki z nią zaprzęgnięto wszystkie dostępne środki, w tym również sztuczną inteligencję.

Liczba publikacji naukowych dotyczących COVID-19 jest tak duża, że nie może być przestudowana przez żadnego człowieka ani nawet przez pojedynczą grupę ludzi. Znaczna część tych zasobów gromadzona jest w bazie CORD-19 (The COVID-19 Open Research Dataset), która zawiera również publikacje na temat poprzednich jednostek chorobowych wywołanych przez koronawirusy – MERS i SARS. Dokumenty zawarte w CORD-19 pochodzą między innymi z baz PubMed, Światowej Organizacji Zdrowia, a także serwerów zawierających preprinty jeszcze nieopublikowanych prac. Aby móc korzystać w pełni z tak ogromnej liczby danych, powstały systemy takie jak CO-Search, Covidex czy SLEDGE służące do efektywnego wyszukiwania literatury w oparciu o mechanizmy sztucznej inteligencji. Publikacje odpowiadające na zapytanie wprowadzone przez użytkownika są sortowane według trafności (Shorten, Khoshgoftaar i Furht, 2021).

Technologia oparta na zasadach uczenia głębokiego pozwala naukowcom na poznawanie większej liczby szczegółów na temat epidemiologii SARS-CoV-2, które mają kluczowe znaczenie dla zdrowia publicznego. Współcześnie, z uwagi na powszechność transportu lotniczego i dużą migrację ludności, bardzo trudno jest prognozować rozprzestrzenianie się epidemii chorób zakaźnych. Problemem jest również bardzo duża liczba innych zmiennych, takich jak klimat, pogoda, gęstość zaludnienia, organizacja ochrony zdrowia, czynniki kulturowe, wydarzenia masowe, sytuacja polityczna i wiele innych. Znacznie lepiej niż klasyczne modele statystyczne z takimi danymi radzi sobie AI. Uczenie maszynowe i przetwarzanie danych w chmurze mogą być bardzo efektywnie wdrażane w celu śledzenia przebiegu choroby, przewidywania wzrostu fali zakażeń oraz projektowania strategii i zasad zarządzania związanych z rozprzestrzenianiem się choroby.

Kim i in. (2020) w swojej pracy przedstawili algorytm przewidujący, jak bardzo wirus może się rozprzestrzeniać podczas podróży z określonych regionów. Stworzona przez nich sieć neuronowa Hi-COVIDNet rozpoznaje czasową zależność zakażeń COVID-19 w poszczególnych krajach, a także wielopoziomowe interakcje związane z migracją ludzi. W swojej pracy udowodnili praktyczność

i skuteczność Hi-COVIDNet na podstawie analizy przypadków z Korei Południowej. Po przeszkoleniu Hi-COVIDNet z użyciem zbiorów danych zebranych od 22 marca do 5 maja 2020 roku przewidziano liczbę zaimportowanych przypadków COVID-19 w czasie od 6 do 19 maja 2020 roku. Prognozy okazały się być bardzo podobne do trendu obserwowanego w rzeczywistości.

Le, Salifu i McFarlane. (2021) stworzyli model pozwalający na bardzo szczegółowe prognozowanie rozprzestrzeniania się wirusa w Stanach Zjednoczonych na poziomie hrabstwa i stanu. Użyty zestaw danych składa się z potwierdzonych przypadków, ankiet dotyczących objawów, map zasięgu ruchu, mobilności społeczeństw, wizyt lekarskich, ilości testów PCR wykonywanych w danym stanie oraz pogody. Celem eksperymentu było oddzielenie czynników specyficznych dla regionu, takich jak demografia, regulacje prawne i mobilność, od cech choroby COVID-19. Wykorzystane przez autorów metody pozwalają na uzyskanie modeli prognostycznych o bardzo wysokiej rozdzielczości.

Do przewidywania liczby zakażeń wykorzystuje się różne metody głębokiego uczenia, takie jak Recurrent Neural Network (RNN), Long short-term memory (LSTM), Bidirectional LSTM (BiLSTM), Gated recurrent units (GRUs) i Variational AutoEncoder (VAE). Wybór metody zależy od rozszerzonej zdolności modeli głębokiego uczenia do wychwytywania nieliniowości procesów z uwzględnieniem elastyczności w modelowaniu danych zależnych od czasu. Zeroual i in. (2020) porównali te metody ze sobą – wzięto pod uwagę skuteczność prognozowania z siedemnastodniowym wyprzedzeniem na podstawie danych historycznych z okresu 148 dni z Włoch, Hiszpanii, Francji, Chin, USA i Australii. Największą dokładnością wykazał się system VAE, jednak pozostałe modele nie różniły się istotnie. Głębokie uczenie może być bardzo pomocne w prognoście nowych zakażeń nawet w oparciu o relatywnie niewielkie ilości danych, jak to było w powyższym przypadku.

Inne narzędzie badawcze wykorzystujące AI odnotowało korelację pomiędzy wybranymi wynikami badań laboratoryjnych pacjentów, zgłaszanymi objawami (np. mialgia) a ciężkością przebiegu COVID-19. Ponadto zauważono, że pewne cechy uważane za charakterystyczne dla COVID-19, takie jak zmiany w obrazie płuc (np. obraz matowego szkła), gorączka i silna odpowiedź immunologiczna, nie były przydatne w przewidywaniu, u którego pacjenta z początkowo łagodnymi objawami rozwinię się ciężka niewydolność oddechowa. Również wiek i płeć nie były pomocne w przewidywaniu ciężkiego przebiegu choroby, chociaż wcześniejsze badania wykazały, że mężczyźni powyżej 60. roku życia są bardziej narażeni na ryzyko (Jiang i in., 2020).

Shelke i in. (2020) opisali modele głębokiego uczenia samodzielnie klasyfikujące zdjęcia rentgenowskie klatki piersiowej do 4 klas: stan prawidłowy, zapalenie płuc, gruźlica lub COVID-19. Ponadto radiogramy wskazujące na COVID-19 są dalej grupowane na podstawie ciężkości na łagodne, średnie i ciężkie. Model uczenia głębokiego VGG16 zastosowany do klasyfikacji zapalenia płuc, gruźlicy i stanu bez odchylenia od normy charakteryzował się dokładnością 95,9%. Do segregacji „normalnego” zapalenia płuc i zapalenia w przebiegu COVID-19 zastosowano model DenseNet-161 (rodzaj głębokiej sieci neuronowej), który odznaczał się dokładnością na poziomie 98,9%. Natomiast kolejny model – ResNet-18 – działał najlepiej w przypadku klasyfikacji ciężkości choroby i osiągnął dokładność 76%. Zaprezentowane wyniki sugerują możliwość wykonywania masowych badań radiologicznych w celu prognozowania osobniczego przebiegu COVID-19.

Sztuczna inteligencja, oprócz zdolności modelowania schematu rozprzestrzeniania się wirusa oraz oceny ryzyka ciężkości choroby u indywidualnych pacjentów, może znaleźć zastosowanie w poszukiwaniach nowych leków lub szczepionek przeciw COVID-19.

W 2014 roku powstała wspomniana już wcześniej firma Insilico Medicine, mająca być z założenia alternatywą dla testów na zwierzętach w programach badawczo-rozwojowych przemysłu farmaceutycznego. Przy wykorzystaniu sztucznej inteligencji i technik głębokiego uczenia Insilico stara się analizować, w jaki sposób dany związek wpływa na komórki i jakie leki można zastosować do ich leczenia przy uwzględnieniu możliwych działań niepożądanych. Oddział firmy – Pharma.AI – świadczy usługi uczenia maszynowego różnym firmom farmaceutycznym, biotechnologicznym i kosmetycznym (Insilico, 2021).

6. Sztuczna inteligencja w podstawowej opiece zdrowotnej

Powyższe przykłady w większości dotyczyły wybranych zastosowań sztucznej inteligencji w specjalistycznej opiece medycznej. Nowoczesna opieka zdrowotna wskazuje na doniosłą rolę lekarza pierwszego kontaktu. Istotne jest likwidowanie barier i ułatwianie dostępu do usług medycznych wszystkim pacjentom, jak również promowanie zdrowego stylu życia i profilaktyki chorób. W Europie Zachodniej realizacja tych celów odbywa się również przy zastosowaniu i popularyzacji programów komputerowych, które wchodzi w interakcję z użytkownikiem przy użyciu języka naturalnego (ludzkiego) – chatbotów. Użytkownicy komunikują się z tymi narzędziami za pomocą czatu w formie pisemnej lub głosowo, tak jakby rozmawiali z inną osobą. Chatboty, dzięki leżącej u ich podstaw technologii przetwarzania języka naturalnego (NLP), interpretują słowa podane im przez człowieka i udzielają odpowiedzi. Są konsultantami zaprojektowanymi do realizacji różnych celów, również prozdrowotnych.

Chatboty stanowią innowacyjne podejście do wyzwań w dziedzinie teleopieki i profilaktyki. Przy odpowiednim zaprojektowaniu chatboty mogą w przyszłości zwiększyć zaangażowanie i dbałość pacjentów o swoje zdrowie, zwiększyć skuteczność zachowań prozdrowotnych, a w dalszej perspektywie – obniżyć koszty działania systemu opieki zdrowotnej. Jednak zaprojektowanie inteligentnego chatbota, który dobrze reaguje na potrzeby użytkowników, nie jest łatwe. Obecnie sektor chatbotów boryka się jeszcze z wieloma poważnymi ograniczeniami, takimi jak problemy z rozumieniem języka naturalnego, w tym właściwą interpretacją synonimów.

Chatboty – ze względu na rodzaj wiedzy, pod której kątem zostały zaprojektowane – można podzielić na działające w sferze otwartej, gdzie rozmawiają na tematy ogólne, i w sferze zamkniętej – związane ze ścisłym rodzajem wiedzy, na przykład medycznej. Natomiast w oparciu o rodzaj świadczony usługi i wymagany przez to typ interakcji można wyróżnić chatboty interpersonalne i intrapersonalne. Te pierwsze przeznaczone są do komunikacji z innymi podmiotami w określonym celu, jak na przykład rezerwowanie wizyty u lekarza czy zrobienie zdalnych zakupów. Druga grupa to osoby asystenci, obecni między innymi w komunikatorach takich jak WhatsApp, Messenger, Slack, których zadaniem jest rozumienie użytkownika niczym drugi człowiek (Adamopoulou i Moussiades, 2020).

Ta grupa tzw. agentów konwersacyjnych (ang. *conversational agents*) może znaleźć zastosowanie między innymi w psychiatrii i już obecnie podkreślany jest ich korzystny potencjał w psychoedukacji i samorealizacji pacjentów. Ponadto liczne badania przeprowadzone wśród populacji z depresją, zaburzeniami lękowymi, schizofrenią, zaburzeniami afektywnymi dwubiegunowymi i zaburzeniami związanymi z uzależnieniami dowodzą, że ocena satysfakcji z chatbotów jest w tej grupie wysoka. Obserwacje wskazują, że chatboty mogą być skutecznym i przyjemnym narzędziem wspomagającym leczenie psychiatryczne (Vaidyam i in., 2019).

Chatboty to programy spersonalizowane, które gromadzą bardzo dużo danych wrażliwych użytkownika, co musi wiązać się z wysoką dbałością o odpowiednie zabezpieczenie tych informacji. Ekosystem chatbotów rozwija się bardzo szybko, a nowe funkcje są udostępniane codziennie przez liczne platformy.

W obszarach tzw. e-zdrowia istnieje podzbiór technologii zaprojektowanych specjalnie po to, by wspierać zmianę zachowania pacjenta w celu poprawy jego zdrowia. Są to technologie interwencji behawioralnej (ang. *behavioral intervention technologies*, BIT). Wsparcie ze strony człowieka zostało zintegrowane z BIT na różne sposoby (np. poprzez SMS-y, e-maile, rozmowy telefoniczne prowadzone ze specjalistami). Chatboty z powodzeniem mogą uzupełniać działanie człowieka w tej dziedzinie.

Wdrożenie chatbota w zakresie edukacji żywieniowej może poprawić dostęp pacjentów do informacji, ponieważ systemy konwersacyjne są uważane za jedne z najbardziej intuicyjnych, które nie wymagają wysiłku edukacyjnego. Chatbot skutecznie wspierałby również zaangażowanie użytkownika poprzez podpowiedzi i zdrowe rekomendacje w czasie i miejscu, w którym dokonywany jest wybór jedzenia (Fadhil i Gabrielli, 2017).

W przyszłości rozpoznawanie objawów i diagnozowanie przez boty można znacznie poprawić, dodając obsługę większej liczby funkcji medycznych, takich jak lokalizacja, czas trwania i intensywność objawów oraz bardziej szczegółowy opis objawów. Wdrożenie takiego Spersonalizowanego Asystenta Medycznego w dużej mierze opiera się na algorytmach AI (Divya i in., 2018).

7. Dyskusja

O znaczeniu rozwoju technologii bazujących na sztucznej inteligencji i oczekiwanych korzyściach płynących z ich wdrażania mogą świadczyć fundusze przeznaczane na dalszy rozwój tych technologii. Dla przykładu Komisja Europejska w 2018 roku przeznaczyła na wdrażanie AI na różne rynki 4 mld dolarów. W 2019 kwota ta wzrosła do 7 mld, a w 2020 było to już 20 mld dolarów. Należy dodać, że na pierwszym miejscu spośród różnych sektorów gospodarki, w których rozwój sztucznej inteligencji jest kluczowy, wymieniono sektor zdrowia (Szponar, 2020).

AI jest dziedziną badań, której celem jest opracowanie programów komputerowych, które w działaniu wykazują się „rozumowaniem” podobnym do ludzkiego. Jeszcze przez długi czas większość narzędzi opartych na jej wykorzystaniu będzie cechować wąski zakres przeznaczenia do wykonywania określonego zadania, z którym radzić sobie będą lepiej od człowieka. Algorytmy głębokiego uczenia oparte na sieciach neuronowych, które mają możliwość rozpoznawania patologicznych obrazów zmian chorobowych, są coraz częściej wykorzystywane w medycynie. Rezultaty prowadzonych prac wskazują, że wyniki oparte na systemach AI mogą być niezwykle precyzyjne i pomocne zarówno w procesie diagnostycznym, jak i terapeutycznym. W istocie dla świata medycyny stworzenie (w oparciu o sieci neuronowe) urządzeń, które będą myśleć tak samo jak człowiek, nigdy nie było celem samym w sobie. Kluczowe jest natomiast tworzenie systemów wspierających i ułatwiających pracę człowieka, tak aby była bardziej wydajna i precyzyjna.

Algorytmy AI w medycynie nie są powszechnie stosowane jako samodzielne systemy podejmujące decyzje. Większość badaczy skłania się do tezy, że współdziałanie sztucznej i ludzkiej inteligencji usprawnia działania lekarzy i zmniejsza ryzyko popełnienia błędu. Wiele z tych narzędzi może mieć przełomowe znaczenie w diagnostyce i leczeniu niektórych chorób.

Nadchodzące lata przyniosą medykom kolejne, coraz lepiej funkcjonujące wysokospecjalistyczne narzędzia, zwiększające ich kompetencje i możliwości. Prawdopodobnie dalszy postęp badań nad sztuczną inteligencją w medycynie przyczyni się też do dokładnej walidacji zarówno już istniejących, jak i przyszłych systemów i doprowadzi do ich upowszechnienia. W licznych dziedzinach medycyny pojawiły się już systemy o udowodnionej skuteczności. To właśnie skuteczność i bezpieczeństwo będą w dużej mierze warunkowały sukces takich technologii. W ten sposób sztuczna inteligencja z technologicznego novum, jakim była pod koniec XX wieku, stanie się standardem niezbędnym do wykonywania codziennej pracy lekarza.

Przy opracowywaniu zautomatyzowanej analizy obrazu opartej na konwolucyjnych sieciach neuronowych dla zastosowań medycznych – na przykład w patomorfologii czy dermatologii – powszechnym zjawiskiem jest ograniczona ilość danych, ponieważ zbudowanie dużej ilości odpowiednich, wysokiej jakości danych jest bardzo kosztowne i czasochłonne (Chang i in., 2019). Jednym z czynników wpływających na powodzenie dalszych prac nad algorytmami analizującymi obrazy będzie rzetelne gromadzenie i porządkowanie danych.

Konsekwencją wykorzystania nowych technologii jest bardziej precyzyjna ocena stanu klinicznego pacjenta, nawet na odległość, a tym samym – możliwość szybszej interwencji terapeutycznej. Ograniczeniem konstrukcji programu komputerowego jest zawsze właściwy dobór i poprawna interpretacja danych wejściowych, na podstawie których system się uczy. Zbyt homogenna grupa może zawęzić krąg późniejszych diagnoz, a źle dobrana – spowodować powstanie błędów merytorycznych. Ponadto zapisy nieprawidłowo lub nieprecyzyjnie zarejestrowane przez pacjenta mogą być źródłem pomyłki diagnostycznej. Stąd też powszechny jest pogląd, że aby zminimalizować lub uniknąć ryzyka popełnienia błędu, samodzielne programy komputerowe winne być nadzorowane przez człowieka.

Należy być świadomym, że do wprowadzania zmian w medycynie konieczna jest ich akceptacja przez społeczność medyczną w oparciu o twarde dowody naukowe. W latach 50. XIX w. Ignacy Semmelweis przyczynił się do głębokich przemian poprzez skłonienie lekarzy do mycia rąk. Wdrożył tę praktykę na wiedeńskim oddziale położniczym i szybko zaobserwował, że śmiertelność spowodowana „gorączką połogową” zmniejszyła się z około 10% do poniżej 2%. Choć dziś jego przełomowy pomysł wydaje się być oczywistością, to wówczas wielu lekarzy nie dowierzało, że istnienie niewidzialnych dla ich oka drobnoustrojów może być przyczyną zwiększonej śmiertelności pacjentów. Dzięki otwartości personelu medycznego na fakty z czasem praktyka ta zaczęła przynosić rezultaty w skali globalnej. Również obecnie, w okresie, który coraz częściej nazywany jest erą sztucznej inteligencji, niezmiernie ważne będzie to, jak społeczność naukowa, lekarze, ale także pacjenci będą nastawieni do istnienia nowych technologii w sektorze medycznym, a istotnym czynnikiem warunkującym zaufanie do tego typu rozwiązań są coraz liczniejsze dowody naukowe na temat ich skuteczności.

Bibliografia

- Abdolmanafi A., Cheriet F., Duong L., Ibrahim R., Dahdah N. 2020. An automatic diagnostic system of coronary artery lesions in Kawasaki disease using intravascular optical coherence tomography imaging. *Biophotonics* 13, nr art. e201900112. DOI: [10.1002/jbio.201900112](https://doi.org/10.1002/jbio.201900112).
- Abràmoff M., Lou Y., Erginay W.C., Ryan A., Folk J., Niemeijer M. 2016. Improved Automated Detection of Diabetic Retinopathy on a Publicly Available Dataset Through Integration of Deep Learning. *Investigative Ophthalmology & Visual Science* 57, str. 5200–5206. DOI: [10.1167/iovs.16-19964](https://doi.org/10.1167/iovs.16-19964).
- Adamopoulou E., Moussiades L. 2020. An Overview of Chatbot Technology. In: Maglogiannis I., Iliadis L., Pimenidis E. (red.) *Artificial Intelligence Applications and Innovations. 16th IFIP WG 12.5 International Conference, AIAI 2020, Neos Marmaras, Greece, June 5–7, 2020, Proceedings, Part II*. Springer, Cham. DOI: [10.1007/978-3-030-49186-4_31](https://doi.org/10.1007/978-3-030-49186-4_31).
- Ahmed M., Toor A., O’Neil K., Friedland D. 2017. Cognitive Computing and the Future of Health Care Cognitive Computing and the Future of Healthcare: The Cognitive Power of IBM Watson Has the Potential to Transform Global Personalized Medicine. *IEEE Pulse* 8(3), str. 4–9. DOI: [10.1109/mpul.2017.2678098](https://doi.org/10.1109/mpul.2017.2678098).
- Alagappan M., Glissen Brown J., Mori Y., Berzin T.M. 2018. Artificial intelligence in gastrointestinal endoscopy: The future is almost here. *World Journal Of Gastrointestinal Endoscopy* 10(10), str. 239–249. DOI: [10.4253/wjge.v10.i10.239](https://doi.org/10.4253/wjge.v10.i10.239).
- Albawi S., Mohammed T., Al-Zawi S. 2017. *Understanding of a convolutional neural network*. International Conference on Engineering and Technology (ICET), str. 1–6. DOI: [10.1109/ICEngTechnol.2017.8308186](https://doi.org/10.1109/ICEngTechnol.2017.8308186).
- Anderson J., Rosenfeld E. 2000. *Talking Nets: An Oral History of Neural Networks*. MIT Press, Cambridge, str. 54–60.
- Atomwise. 2015. Dostępne online: <https://www.atomwise.com/2015/03/24/atomwise-finds-first-evidence-towards-new-ebola-treatments/> (dostęp: 20.12.2021).
- Brinker T., Hekler A., Enk A., Klode J., Hauschild A., Berking C., Schilling B., Haferkamp S., Schadendorf D., Holland-Letz T., Utikal J., Von Kalle C. 2019. Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task. *European Journal of Cancer* 113, str. 47–54. DOI: [10.1016/j.ejca.2019.04.001](https://doi.org/10.1016/j.ejca.2019.04.001).
- Bulten W., Pinckaers H., Van Boven H., Vink R., de Bel T., van Ginneken B., van der Laak J., Hulsbergen-van de Kaa C., Litjens G. 2020. Automated deep-learning system for Gleason grading of prostate cancer using biopsies: a diagnostic study. *The Lancet Oncology* 21(2), str. 233–241. DOI: [10.1016/s1470-2045\(19\)30739-9](https://doi.org/10.1016/s1470-2045(19)30739-9).
- Chandrasekar R. 2014. Elementary? Question answering, IBM’s Watson, and the Jeopardy! challenge. *Reson* 19, str. 222–241. DOI: [10.1007/s12045-014-0029-7](https://doi.org/10.1007/s12045-014-0029-7).
- Chang H., Jung C., Woo J., Lee S., Cho J., Kim S.W., Kwak T. 2019. Artificial Intelligence in Pathology. *Journal of pathology and translational medicine* 53(1), str. 1–12. DOI: [10.4132/jptm.2018.12.16](https://doi.org/10.4132/jptm.2018.12.16).
- Chang C., Xu K., Guo C., Wang J., Yan Q., Zhang J., He F., Zhu Y. 2018. PANDA-view: an easy-to-use tool for statistical analysis and visualization of quantitative proteomics data. *Bioinformatics* 34(20), str. 3594–3596. DOI: [10.1093/bioinformatics/bty408](https://doi.org/10.1093/bioinformatics/bty408).
- COVID-19 Open Research Dataset Challenge (CORD-19). 2021. Dostępne online: <https://www.kaggle.com/datasets/allen-institute-for-ai/CORD-19-research-challenge> (dostęp: 20.12.2021)
- Dietterich T. 1995. Overfitting and undercomputing in machine learning. *ACM Computing Surveys* 27(3), str. 326–327. DOI: [10.1145/212094.212114](https://doi.org/10.1145/212094.212114).
- Divya S., Indumathi V., Ishwarya S., Priyasankari M., Kalpana S. 2018. A Self-Diagnosis Medical Chatbot Using Artificial Intelligence. *Journal of Web Development and Web Designing* 3(1) str. 1–7.
- El Naqa I., Murphy M. 2015. What Is Machine Learning? W: El Naqa I., Li R. (red.) *Machine Learning in Radiation Oncology: Theory and Applications*. Springer Publishing, Nowy Jork, str. 3–11.
- English R.A., Lebovitz Y., Giffin R.B., Institute of Medicin (U.S.), Forum on Drug Discovery, Development, and Translation. 2010. *Transforming clinical research in the United States: challenges and opportunities: workshop summary*. Waszyngton, National Academies Press.
- Esteva A., Kuprel B., Novoa, R. Ko J., Swetter S., Blau H., Thrun S. 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542(7639), str. 115–118. DOI: [10.1038/nature21056](https://doi.org/10.1038/nature21056).
- Fadhil A., Gabrielli S. 2017. Addressing challenges in promoting healthy lifestyles: the AI-chatbot approach. W: *Proceedings of the 11th EAI International Conference on Pervasive Computing Technologies for*

- Healthcare (PervasiveHealth '17)*. Association for Computing Machinery, Nowy Jork, str. 261–265. DOI: [10.1145/3154862.3154914](https://doi.org/10.1145/3154862.3154914).
- Forbus K.D., Kuipers B., Lieberman H. 2016. Remembering Marvin Minsky. *AI Magazine* 37(3), str. 94–98. DOI: [10.1609/aimag.v37i3.2677](https://doi.org/10.1609/aimag.v37i3.2677).
- Gao W., Li M., Wu R., Du W., Zhang S., Yin S., Chen Z., Huang H. 2021. The design and application of an automated microscope developed based on deep learning for fungal detection in dermatology. *Mycoses* 64(3), str. 245–251. DOI: [10.1111/myc.13209](https://doi.org/10.1111/myc.13209).
- Garba S., Ahmed A., Mai A., Makama G., Odigie V. 2010. Proliferations of Scientific Medical Journals: A Burden or A Blessing. *Oman Medical Journal* 25(4), str. 311–314. DOI: [10.5001/omj.2010.89](https://doi.org/10.5001/omj.2010.89).
- García-Campos M., Espinal-Enríquez J., Hernández-Lemus E. 2015. Pathway Analysis: State of the Art. *Frontiers in Physiology* (6), nr art 383. DOI: [10.3389/fphys.2015.00383](https://doi.org/10.3389/fphys.2015.00383).
- Gargeya R., Leng T. 2017. Automated Identification of Diabetic Retinopathy Using Deep Learning. *Ophthalmology* 124(7), str. 962–969. DOI: [10.1016/j.ophtha.2017.02.008](https://doi.org/10.1016/j.ophtha.2017.02.008).
- General Problem Solver. 2021. Dostępne online: <https://www.oxfordreference.com/view/10.1093/oi/authority.20110803095847145> (dostęp: 20.12.2021).
- Gulshan V., Peng L., Coram M., Stumpe M.C., Wu D., Narayanaswamy A., Venugopalan S., Widner K., Madams T., Cuadros J., Kim R., Raman R., Nelson P.C., Mega J.L., Webster D.R. 2016. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *The Journal of the American Medical Association* 316(22), str. 2402–2410. DOI: [10.1001/jama.2016.17216](https://doi.org/10.1001/jama.2016.17216).
- Haenlein M., Kaplan A. 2019. A Brief History of Artificial Intelligence: On the Past, Present, and Future of Artificial Intelligence. *California Management Review* 61(4), str. 1–10. DOI: [10.1177/0008125619864925](https://doi.org/10.1177/0008125619864925).
- Hagiwara A., Otsuka Y., Hori M., Tachibana Y., Yokoyama K., Fujita S., Andica C., Kamagata K., Irie R., Koshino S., Maekawa T., Chougar L., Wada A., Takemura M., Hattori N., Aoki S. 2019. Improving the Quality of Synthetic FLAIR Images with Deep Learning Using a Conditional Generative Adversarial Network for Pixel-by-Pixel Image Translation. *American Journal of Neuroradiology* 40(2), str. 224–230. DOI: [10.3174/ajnr.A5927](https://doi.org/10.3174/ajnr.A5927).
- Hammernik K., Würfl T., Pock T., Maier A.A. 2017. A Deep Learning Architecture for Limited-Angle Computed Tomography Reconstruction. W: Maier-Hein K., Deserno T., Handels H., Tolxdorff T. Bildverarbeitung für die Medizin. Algorithmen – Systeme – Anwendungen. Proceedings des Workshops vom 12. bis 14. März 2017 in Heidelberg. Springer, Berlin, Heidelberg, str. 92–97.
- Hofvind S., Sagstad S., Sebuødegård S., Chen Y., Roman M., Lee Cl. 2018. Interval Breast Cancer Rates and Histopathologic Tumor Characteristics after False-Positive Findings at Mammography in a Population-based Screening Program. *Radiology* 287(1), str. 58–67. DOI: [10.1148/radiol.2017162159](https://doi.org/10.1148/radiol.2017162159).
- Hosny A., Parmar C., Quackenbush J., Schwartz L., Aerts H. 2018. Artificial intelligence in radiology. *Nature Reviews Cancer* 18(8), str. 500–510. DOI: [10.1038/s41568-018-0016-5](https://doi.org/10.1038/s41568-018-0016-5).
- IBM. 2021a. Dostępne online: <https://www.ibm.com/ibm/history/ibm100/us/en/icons/deepblue/> (dostęp: 20.12.2021).
- IBM. 2021b. Dostępne online: <https://www.ibm.com/cloud/learn/supervised-learning> (dostęp: 20.12.2021).
- IBM. 2021c. Dostępne online: <https://www.ibm.com/pl-pl/marketplace/clinical-trial-matching-oncology> (dostęp: 20.12.2021).
- IBM. 2021d. Dostępne online: <https://www.ibm.com/watson-health/solutions/cancer-research-treatment> (dostęp: 20.12.2021).
- Insilico. 2021. Dostępne online: <https://insilico.com/pandaomics> (dostęp: 20.12.2021).
- Jiang X., Coffee M., Bari A., Wang J., Jiang X., Huang J., Shi J., Dai J., Cai J., Zhang X., Wu Z., He G., Huang Y. 2020. Towards an Artificial Intelligence Framework for Data-Driven Prediction of Coronavirus Clinical Severity. *CMC-Computers, Materials & Continua* 63(1), str. 537–551. DOI: [10.32604/cmc.2020.010691](https://doi.org/10.32604/cmc.2020.010691).
- Jurowski K. 2021. Nauki omiczne (omics). Dostępne online: <https://kamiljurowski.wordpress.com/praca-naukowa/nauki-omiczne/> (dostęp 20.12.2021)
- Kashou A., May A., Noseworthy P. 2020. Artificial Intelligence-Enabled ECG: a Modern Lens on an Old Technology. *Current Cardiology Reports* 22(8), nr art. 57. DOI: [10.1007/s11886-020-01317-x](https://doi.org/10.1007/s11886-020-01317-x).
- Kazemian P., Lavieri M., Van Oyen M., Andrews C., Stein J. 2017. Personalized Prediction of Glaucoma Progression Under Different Target Intraocular Pressure Levels Using Filtered Forecasting Methods. *Ophthalmology* 125(4), str. 569–577. DOI: [10.1016/j.ophtha.2017.10.033](https://doi.org/10.1016/j.ophtha.2017.10.033).

- Kent J. 2018. *Health IT Analytics*. Dostępne online: <https://healthitanalytics.com/news/big-data-to-see-explosive-growth-challenging-healthcare-organizations> (dostęp: 3.03.2022).
- Kim M., Kang J., Kim D., Song H., Min H., Nam Y., Park D., Lee J.-G. 2020. Hi-COVIDNet: Deep Learning Approach to Predict Inbound COVID-19 Patients and Case Study in South Korea. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '20)*. Association for Computing Machinery, New York, str. 3466–3473. DOI: [10.1145/3394486.3412864](https://doi.org/10.1145/3394486.3412864).
- Kooi T., Litjens G., van Ginneken B., Gubern-Mérida A., Sánchez CI., Mann R., den Heeten A., Karssemeijer N. 2017. Large scale deep learning for computer aided detection of mammographic lesions. *Medical Image Analysis* 35, str. 303–312. DOI: [10.1016/j.media.2016.07.007](https://doi.org/10.1016/j.media.2016.07.007).
- Korbar B., Olofson A., Mirafior A., Nicka C., Suriawinata M., Torresani L., Suriawinata A., Hassanpour S. 2017. Deep Learning for Classification of Colorectal Polyps on Whole-slide Images. *Journal of Pathology Informatics* 25(8), nr art. 30. DOI: [10.4103/jpi.jpi_34_17](https://doi.org/10.4103/jpi.jpi_34_17).
- Kulikowski C. 2019. Beginnings of Artificial Intelligence in Medicine (AIM): Computational Artifice Assisting Scientific Inquiry and Clinical Art – with Reflections on Present AIM Challenges. *Yearbook of Medical Informatics* 28(1), str. 249–256. DOI: [10.1055/s-0039-1677895](https://doi.org/10.1055/s-0039-1677895).
- Lång K., Hofvind S., Rodríguez-Ruiz A., Andersson I. 2021. Can artificial intelligence reduce the interval cancer rate in mammography screening? *European Radiology* 31(8), str. 5940–5947. DOI: [10.1007/s00330-021-07686-3](https://doi.org/10.1007/s00330-021-07686-3).
- Le A., Salifu M.O., McFarlane I.M. 2021. Artificial Intelligence in Colorectal Polyp Detection and Characterization. *International Journal of Clinical Research & Trials* 6, nr art. 157. DOI: [10.15344/2456-8007/2021/157](https://doi.org/10.15344/2456-8007/2021/157).
- Le M., Ibrahim M., Sagun S., Lacroix T., Nickel M. 2020. Neural Relational Autoregression for High-Resolution COVID-19 Forecasting. Facebook AI Research. Dostępne online: <https://ai.facebook.com/research/publications/neural-relational-autoregression-for-high-resolution-covid-19-forecasting/> (dostęp: 3.03.2022).
- Mandrekar J.N. 2010. Receiver Operating Characteristic Curve in Diagnostic Test Assessment. *Journal of Thoracic Oncology* 5(9), str. 1315–1316. DOI: [10.1097/jto.0b013e3181ec173d](https://doi.org/10.1097/jto.0b013e3181ec173d).
- Masche J., Le N. 2018. A Review of Technologies for Conversational Systems. *Advances in Intelligent Systems and Computing* 629, str. 212–225. DOI: [10.1007/978-3-319-61911-8_19](https://doi.org/10.1007/978-3-319-61911-8_19).
- McCarthy J., Minsky M., Rochester N. 2006. Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine* 27(4), nr art. 12. DOI: [10.1609/aimag.v27i4.1904](https://doi.org/10.1609/aimag.v27i4.1904).
- Mori Y., Kudo S., Wakamura K., Misawa M., Ogawa Y., Kutsukawa M., Kudo T., Hayashi T., Miyachi H., Ishida F., Inoue H. 2015. Novel computer-aided diagnostic system for colorectal lesions by using endocytoscopy (with videos). *Gastrointestinal Endoscopy* 81(3), str. 621–629. DOI: [10.1016/j.gie.2014.09.008](https://doi.org/10.1016/j.gie.2014.09.008).
- Mori Y., Kudo S., Misawa M., Saito Y., Ikematsu H., Hotta K., Ohtsuka K., Urushibara F., Kataoka S., Ogawa Y., Maeda Y., Takeda K., Nakamura H., Ichimasa K., Kudo T., Hayashi T., Wakamura K., Ishida F., Inoue H., Itoh H., Oda M., Mori K. 2018. Real-Time Use of Artificial Intelligence in Identification of Diminutive Polyps During Colonoscopy: A Prospective Study. *Annals of Internal Medicine* 169(6), str. 357–366. DOI: [10.7326/M18-0249](https://doi.org/10.7326/M18-0249).
- National Cancer Institute. 2020. Dostępne online: <https://www.cancer.gov/about-nci/organization/ccg/research/structural-genomics/tcga> (dostęp: 20.12.2021).
- National Library of Medicine. 2021a. Dostępne online: https://www.nlm.nih.gov/bsd/medline_cit_counts_yr_pub.html (dostęp: 20.12.2021).
- National Library of Medicine. 2021b. Dostępne online: <https://clinicaltrials.gov/ct2/resources/trends> (dostęp: 20.12.2021).
- OECD. 2018a. Magnetic resonance imaging (MRI) exams. Dostępne online: <https://doi.org/10.1787/1d89353f-en> (dostęp: 20.12.2021).
- OECD. 2018b. Computed tomography (CT) exams. Dostępne online: <https://doi.org/10.1787/3c994537-en> (dostęp: 20.12.2021).
- Ozerov I., Lezhnina K., Izumchenko E., Artemov A., Medintsev S., Vanhaelen Q., Aliper A., Vijg J., Osipov A., Labat I., West M., Buzdin A., Cantor C., Nikolsky Y., Borisov N., Irincheeva I., Khokhlovich E., Sidransky D., Camargo M.L., Zhavoronkov A. 2016. In Silico Pathway Activation Network Decomposition Analysis (iPANDA) as a method for biomarker development. *Nature Communications* 7(13427). DOI: [10.1038/ncomms13427](https://doi.org/10.1038/ncomms13427).

- Peek N., Combi C., Marin R., Bellazzi R. 2015. Thirty years of artificial intelligence in medicine (AIME) conferences: A review of research themes. *Artificial Intelligence in Medicine* 65(1), str. 61–73. DOI: [10.1016/j.artmed.2015.07.003](https://doi.org/10.1016/j.artmed.2015.07.003).
- Rajpurkar, P., Irvin J., Zhu K., Brandon Y., Hershel M., Duan T., Ding D., Bagul A., Langlotz C., Shpanskaya K., Lungren M., Ng A.Y. 2017. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. arXiv, Cornell University, Nowy Jork. DOI: [10.48550/arXiv.1711.05225](https://doi.org/10.48550/arXiv.1711.05225).
- Robertson S., Azizpour H., Smith K., Hartman J. 2018. Digital image analysis in breast pathology-from image processing techniques to artificial intelligence. *Translational Research* 194, str. 19–35. DOI: [10.1016/j.trsl.2017.10.010](https://doi.org/10.1016/j.trsl.2017.10.010).
- Sarkar S., Chow J. 2020. Artificial intelligence in radiotherapy. *Reports of Practical Oncology and Radiotherapy* 25(4), str. 656–666. DOI: [10.1016/j.rpor.2020.03.015](https://doi.org/10.1016/j.rpor.2020.03.015).
- Seah J., Tang J., Kitchen A., Gaillard F., Dixon A. 2019. Chest Radiographs in Congestive Heart Failure: Visualizing Neural Network Learning. *Radiology* 290(2), str. 514–522. DOI: [10.1148/radiol.2018180887](https://doi.org/10.1148/radiol.2018180887).
- Shelke A., Inamdar M., Shah V., Tiwari A., Hussain A., Chafekar T., Mehendale N. 2020. Chest X-ray classification using Deep learning for automated COVID-19 screening. *SN Computer Science* 2(4), nr art. 300. DOI: [10.1101/2020.06.21.20136598](https://doi.org/10.1101/2020.06.21.20136598).
- Shorten C., Khoshgoftaar T., Furht B. 2021. Deep Learning applications for COVID-19. *Journal of Big Data* 8, nr art. 18. DOI: [10.1186/s40537-020-00392-9](https://doi.org/10.1186/s40537-020-00392-9).
- Silver D., Schrittwieser J., Simonyan K., Antonoglou I., Huang A., Guez A., Hubert T., Baker L., Lai M., Bolton A., Chen Y., Lillicrap T., Hui F., Sifre L., Driessche G., Graepel T., Hassabis D. 2017. Mastering the game of Go without human knowledge. *Nature* 550, str. 354–359. DOI: [10.1038/nature24270](https://doi.org/10.1038/nature24270).
- Swain J.M., Cara O. 2019. Changing the home literacy environment through participation in family literacy programmes. *Journal of Early Childhood Literacy* 19(4), str. 431–458. DOI: [10.1177/1468798417745118](https://doi.org/10.1177/1468798417745118)
- Szolovits P. 1982. Artificial Intelligence in Medicine. W: Szolovits P. (red.) AAAS Selected Symposia Series, t. 51. str. 8–12. Westview Press, Nowy Jork.
- Szponar A. 2020. *Jak algorytmy wpływają na zdrowie? Sztuczna inteligencja w medycynie*. Comarch Healthcare, Kraków. Dostępne online: https://www.computerworld.pl/g1/tinymce/files/File/panstwo2021/partners/Comarch_PL_WP_AI-w-medycynie.pdf (dostęp: 20.12.2021).
- Tan C., Sun F., Kong T., Zhang W., Yang C., Liu C. 2018. A Survey on Deep Transfer Learning. W: Kůrková V., Manolopoulos Y., Hammer B., Iliadis L., Maglogiannis I. (red.) *Artificial Neural Networks and Machine Learning – ICANN 2018. ICANN 2018. 27th International Conference on Artificial Neural Networks, Rhodes, Greece, October 4-7, 2018, Proceedings, Part III*. Springer, Cham. DOI: [10.1007/978-3-030-01424-7_27](https://doi.org/10.1007/978-3-030-01424-7_27).
- Technologie „omiczne” – EUPATI Toolbox. 2021. Dostępne online: <https://toolbox.eupati.eu/glossary/technologie-omiczne/?lang=pl> (dostęp: 20.12.2021).
- Ting D., Pasquale L., Peng L., Campbell J., Lee A., Raman R., Tan G., Schmetterer L., Keane P., Wong T.Y. 2018. Artificial intelligence and deep learning. *British Journal of Ophthalmology* 103(2) str. 167–175. DOI: [10.1136/bjophthalmol-2018-313173](https://doi.org/10.1136/bjophthalmol-2018-313173).
- Topol E.J. 2019. High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine* 25, str. 44–56. DOI: [10.1038/s41591-018-0300-7](https://doi.org/10.1038/s41591-018-0300-7).
- Turing A.M. 1950. Computing machinery and intelligence. *Mind* 59(236), str. 433–460. DOI: [10.1093/mind/LIX.236.433](https://doi.org/10.1093/mind/LIX.236.433).
- Vaidyam A., Wisniewski H., Halamka J., Kashavan M., Torous J. 2019. Chatbots and Conversational Agents in Mental Health: A Review of the Psychiatric Landscape. *The Canadian Journal of Psychiatry* 64(7), str. 456–464. DOI: [10.1177/0706743719828977](https://doi.org/10.1177/0706743719828977).
- Wang H., Zhou Z., Li Y., Chen Z., Lu P., Wang W., Liu W., Yu L. 2017. Comparison of machine learning methods for classifying mediastinal lymph node metastasis of non-small cell lung cancer from 18F-FDG PET/CT images. *EJNMMI Research* 7(1), nr art. 11. DOI: [10.1186/s13550-017-0260-9](https://doi.org/10.1186/s13550-017-0260-9).
- Wang S.C. 2003. Artificial Neural Network. W: Wang S.C. *Interdisciplinary Computing in Java Programming*. Springer, Nowy Jork, str. 81–100. DOI: [10.1007/978-1-4615-0377-4](https://doi.org/10.1007/978-1-4615-0377-4).
- Widrow B., Winter R. 1988. Neural Nets for Adaptive Filtering and Adaptive Pattern Recognition. *Computer* 21(3), str. 25–39. DOI: [10.1109/2.29](https://doi.org/10.1109/2.29).
- Xu T., Zhang H., Huang X., Metaxas D.N. 2016. Multimodal Deep Learning for Cervical Dysplasia Diagnosis. W: Ourselin S., Joskowicz L., Sabuncu M., Unal G., Wells W. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2016. MICCAI 2016. 19th International Conference, Athens, Greece,*

- October 17-21, 2016, *Proceedings, Part II*. Springer, Cham, str. 115–123.
DOI: [10.1007/978-3-319-46723-8_14](https://doi.org/10.1007/978-3-319-46723-8_14).
- Zeroual A., Harrou F., Dairi A., Sun Y. 2020. Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. *Chaos, Solitons, and Fractals* 140(110121). DOI: [10.1016/j.chaos.2020.110121](https://doi.org/10.1016/j.chaos.2020.110121).
- Zhang J., Gajjala S. Agrawal P., Tison G., Hallock L., Beussink-Nelson L., Lassen M., Fan E., Aras M., Jordan C., Fleischmann K., Melisko M., Qasim A., Shah S., Bajcsy R., Deo R. 2018. *Circulation* 138(16), str. 1623–1635. DOI: [10.1161/CIRCULATIONAHA.118.034338](https://doi.org/10.1161/CIRCULATIONAHA.118.034338).
- Zhang W.J., Yang G., Lin Y., Ji C., Gupta M.M. 2018. On Definition of Deep Learning. *2018 World Automation Congress (WAC)*, str. 1–5. DOI: [10.23919/WAC.2018.8430387](https://doi.org/10.23919/WAC.2018.8430387).
- Zhavoronkov A., Ivanenkov Y., Aliper A., Veselov M., Aladinskiy V., Aladinskaya A., Terentiev V., Polykovskiy D., Kuznetsov M., Asadulaev A., Volkov Y., Zholus A., Shayakhmetov R., Zhebrak A., Minaeva L., Zagribelnyy B., Lee L., Soll R., Madge D., Xing L., Guo T., Aspuru-Guzik A. 2019. Deep learning enables rapid identification of potent DDR1 kinase inhibitors. *Nature Biotechnology* (37), str. 1038–1040.
DOI: [10.1038/s41587-019-0224-x](https://doi.org/10.1038/s41587-019-0224-x).
- Zweig M.H., Campbell G. 1993. Receiver-operating characteristic (ROC) plots: a fundamental evaluation tool in clinical medicine. *Clinical Chemistry* 39(4), str. 561–577.

