

ROZDZIAŁ II

ZASTOSOWANIE SZTUCZNEJ INTELIGENCJI I BIG DATA W DIAGNOSTYCE MEDYCZNEJ

Medycyna była jednym z pierwszych obszarów zastosowań technologii opartych na sztucznej inteligencji w postaci systemów ekspertowych, które wspierały diagnostykę chorób zakaźnych oraz ogólnych problemów medycyny wewnętrznej w latach 70. i 80. XX wieku¹. Od tamtego czasu badania niezmiennie ewoluowały w kierunku bardziej zaawansowanych metod, które coraz skuteczniej radzą sobie ze złożonością danych medycznych. Postęp w dziedzinie sztucznej inteligencji i big data zmienił oblicze współczesnej branży medycznej, wprowadzając innowacyjne algorytmy uczenia maszynowego.

Rozwój digitalizacji dokumentacji medycznej również dołożył swoją cegiełkę do zmiany modelu funkcjonowania sektora opieki zdrowotnej, otwierając nowe perspektywy w zakresie analizy i zarządzania danymi². W wyniku trenowania modeli sztucznej inteligencji na medycznych cyfrowych zbiorach big data, zaawansowane algorytmy potrafią wykrywać wzorce i zależności w nowych danych – są to częstokroć sygnały bardzo subtelne, które mogą umknąć uwadze badaczy.

Dzięki uczeniu maszynowemu możliwe staje się dokładniejsze rozpoznawanie chorób w krótszym czasie, co jest szczególnie ważne w przypadku schorzeń o złożonej etiologii³. Sztuczna inteligencja oferuje zatem nowe narzędzia

¹ D. E. O'Leary, Expert Systems, [w:] Wiley Encyclopedia of Computer Science and Engineering, Wiley 2008, s. 1-28. <https://doi.org/10.1002/9780470050118.ecse146>

² P. Jain, M. Gyanchandani, N. Khare, Big data privacy: a technological perspective and review, Journal of Big Data, nr 3(25), Springer 2016, s. 1-25. <https://doi.org/10.1186/s40537-016-0059-y>

³ A. Rajkomar, J. Dean, I. Kohane, Machine Learning in Medicine, The New England Journal of Medicine, nr 380(14), Massachusetts Medical Society 2019, s. 1347–1358. <https://doi.org/10.1056/NEJMr1814259>

diagnozowania i monitorowania pacjentów, służąc jako wsparcie dla wiedzy i doświadczenia lekarzy specjalistów. Ponadto, można zaobserwować wzrost zastosowania sztucznej inteligencji w obrazowaniu medycznym, personalizacji leczenia oraz szybkiej diagnostyce w sytuacjach kryzysowych⁴. Zaletą algorytmów opartych na sztucznej inteligencji jest ich zdolność do równoległej analizy, oceny wielu czynników naraz oraz transfer wiedzy⁵, co przekłada się na efektywność w procesie interpretacji przez człowieka uzyskanych wyników.

Nowe algorytmy w medycynie

W kontekście praktycznych zastosowań sztucznej inteligencji, jej rozwój w medycynie przejawia się przede wszystkim w rosnącej liczbie zaawansowanych algorytmów i związanych z nimi patentów, które wspierają nowoczesną diagnostykę, prewencję oraz monitorowanie stanu zdrowia, zintegrowanych z urządzeniami noszonymi przez pacjentów. Widać to wyraźnie w zwiększającej się liczbie zgłoszeń takich algorytmów do instytucji regulacyjnych. Między wrześniem 2014 r. a lipcem 2019 r. amerykańska rządowa Agencja ds. Żywności i Leków (ang. U.S. Food and Drug Administration, FDA) zatwierdziła do zastosowań medycznych prawie trzydzieści algorytmów opartych na sztucznej inteligencji⁶. Algorytmy te mają szerokie zastosowania w bardzo różnych obszarach medycyny, takich jak kardiologia (np. wykrywanie migotania przedsionków, arytmii, analiza EKG), onkologia (np. wykrywanie raka piersi, płuc, wątroby), diabetologia (monitorowanie i zarządzanie cukrzycą) oraz obrazowanie medyczne (np. interpretacja USG, tomografii komputerowej, rezonansu magnetycznego)⁷. Oczywiście, skuteczność tych algorytmów jest ściśle uzależniona od jakości danych dostępnych do treningu maszynowego i wyników walidacji tych algorytmów w rzeczywistych warunkach medycznych.

⁴ V. R. P. Chinimilli, L. N. Sadasivuni, G. L. Anga, P. K. Bhansali, The rise of artificial intelligence: A concise review, *IAES International Journal of Artificial Intelligence (IJ-AI)*, nr 13(2), June 2024, s. 2226-2235. <https://doi.org/10.11591/ijai.v13.i2.pp2226-2235>

⁵ R. Afouni, Organizational Learning in the Rise of Machine Learning, 40th International Conference on Information Systems, ICIS 2019, s. 1-17. https://aisel.aisnet.org/icis2019/business_models/business_models/2 [dostęp 05.2024]

⁶ A. Kaplan, H. Cao, J. M. FitzGerald, N. Iannotti, E. Yang, J. W. H. Kocks, K. Kostikas, D. Price, H. K. Reddel, I. Tsiligianni, C. F. Vogelmeier, P. Pfister, P. Mastoridis, Artificial Intelligence/ Machine Learning in Respiratory Medicine and Potential Role in Asthma and COPD Diagnosis, *The Journal of Allergy and Clinical Immunology: In Practice*, nr 9(6), Elsevier 2021, s. 2255-2261. <https://doi.org/10.1016/j.jaip.2021.02.014>

⁷ A. Rajkomar, J. Dean, I. Kohane, Machine Learning in Medicine, *The New England Journal of Medicine*, nr 380(14), Massachusetts Medical Society 2019, s. 1347-1358. <https://doi.org/10.1056/NEJMr1814259>

Znaczna część z zatwierdzonych przez FDA innowacyjnych algorytmów koncentruje się na wsparciu i ulepszeniu diagnostyki. Od 2016 roku widać rosnącą liczbę algorytmów wspierających analizę obrazów medycznych, takich jak USG, rezonans magnetyczny i mammografia. Coraz więcej rozwiązań powstaje również w obszarze automatyzacji i wspomagania procesu diagnozy chorób, co pozwala na bardziej efektywną opiekę nad pacjentem⁸. Z kolei na lepsze dostosowanie terapii do indywidualnych potrzeb pacjenta wskazują takie algorytmy jak inteligentne zarządzanie dawkami insuliny (InPen), monitorowanie glikemii (One Drop, Medtronic) albo monitorowanie migotania przedsionków (Apple, PhysiQ Heart Rhythm Module). Pozwalają one na personalizowane leczenie oraz monitorowanie stanu pacjenta w czasie rzeczywistym.

Wprowadzenie rozwiązań szybkiej reakcji na sytuacje kryzysowe jest istotne w kontekście ratowania życia i szybkiej diagnozy. Algorytmy wspierające triage i diagnozę pacjentów w sytuacjach kryzysowych (Aidoc), triage krwotoków wewnątrzczaszkowych (MaxQ) oraz wykrywanie udarów (Viz.ai) mają na celu przyspieszenie reakcji medycznej w sytuacjach, w których czas podjęcia interwencji jest kluczowy.

Na rosnące zainteresowanie prewencją i wczesnym wykrywaniem problemów zdrowotnych w zdrowiu publicznym wskazuje powstawanie algorytmów dotyczących oceny funkcji poznawczych, takich jak ocena pamięci osób starszych (Cantab Mobile), diagnoza autyzmu (Cognoa) i wykrywanie zaburzeń snu (EnsoSleep). Pojawiają się również algorytmy zintegrowane z urządzeniami mobilnymi i urządzeniami noszonymi przez pacjentów⁹. Jako przykład można wymienić choćby wykrywanie migotania przedsionków (Apple Watch), analizę EKG (Verly Study Watch) i wspomniany algorytm analizujący zmiany glikemii (One Drop, Medtronic). Technologie te umożliwiają ciągłe monitorowanie stanu zdrowia i oferują możliwość natychmiastowej interwencji w przypadku sytuacji kryzysowej.

⁸ Y. Kumar, A. Koul, R. Singla, M. F. Ijaz, Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda, *Journal of Ambient Intelligence and Humanized Computing*, nr 14, Springer 2023, s. 8459-8486. <https://doi.org/10.1007/s12652-021-03612-z>

⁹ B. Raju, F. Jumah, O. Ashraf, V. Narayan, G. Gupta, H. Sun, P. Hilden, A. Nanda, Big data, machine learning, and artificial intelligence: a field guide for neurosurgeons, *Journal of Neurosurgery*, nr 135(2), AANS 2021, s. 373-383. <https://doi.org/10.3171/2020.5.JNS201288>; M. Yahaya, A. Umagba, S. Obeta, T. Maruyama, Critical Evaluation of the Future Role of Artificial Intelligence in Business and Society, *Journal of Artificial Intelligence, Machine Learning and Data Science*, nr 1(1), URF Publishers 2023, s. 21-29. <https://doi.org/10.51219/JAIMLD/Moshood-Yahaya/03>

W lutym 2018 roku FDA zatwierdziła oprogramowanie do diagnozowania udaru mózgu, które wykorzystuje algorytm sztucznej inteligencji do podejmowania pierwszych, autonomicznych decyzji¹⁰. Analizuje on wyniki tomografii komputerowej pod kątem wskaźników związanych z udarem i samodzielnie powiadamia specjalistę w przypadku podejrzenia niedrożności naczyń. Dwa miesiące później, w kwietniu 2018 roku, FDA zezwoliła na wprowadzenie na rynek pierwszego urządzenia medycznego opartego na algorytmie sztucznej inteligencji do wykrywania umiarkowanego lub cięższego stopnia retinopatii cukrzycowej u dorosłych z cukrzycą¹¹. Urządzenie to umożliwia przeprowadzanie badań przesiewowych bez konieczności interpretacji obrazu lub wyników przez specjalistę, dzięki czemu może być używane przez pracowników ochrony zdrowia, którzy na co dzień nie zajmują się opieką okulistyczną¹². Instytucjonalne zatwierdzenie tych narzędzi bazujących na algorytmach uczenia maszynowego i big data nie tylko jest przykładem zmiany podejścia do profilaktyki udaru czy sposobu postępowania z retinopatią cukrzycową, ale również stanowi przykład niezwykle transformacyjnego wpływu sztucznej inteligencji na opiekę zdrowotną.

Systemy informacji szpitalnej, laboratoryjnej i archiwizacji

Rozwój systemów informatycznych oraz transformacja cyfrowa w medycynie przyczyniły się do poprawy jakości opieki zdrowotnej, zarządzania danymi pacjentów i rozwoju personalizowanej medycyny. Placówki medyczne korzystają z różnego rodzaju systemów komputerowych, ułatwiających zarządzanie ogromnymi ilościami danych¹³. Systemy te łączą umiejętności i wiedzę ludzi z inteligencją maszynową, zwiększając wydajność pracy i precyzję wykonywanych zadań,

¹⁰ FDA News Release, FDA permits marketing of clinical decision support software for alerting providers of a potential stroke in patients, FDA.gov 2018, <https://www.fda.gov/news-events/press-announcements/fda-permits-marketing-clinical-decision-support-software-alerting-providers-potential-stroke> [dostęp 05.2024]

¹¹ FDA News Release, FDA permits marketing of artificial intelligence-based device to detect certain diabetes-related eye problems, FDA.gov 2018, <https://www.fda.gov/news-events/press-announcements/fda-permits-marketing-artificial-intelligence-based-device-detect-certain-diabetes-related-eye> [dostęp 05.2024]

¹² A. Kaplan, H. Cao, J. M. Fitzgerald, N. Iannotti, E. Yang, J. W. H. Kocks, K. Kostikas, D. Price, H. K. Reddel, I. Tsiligianni, C. F. Vogelmeier, P. Pfister, P. Mastoridis, Artificial Intelligence/Machine Learning in Respiratory Medicine and Potential Role in Asthma and COPD Diagnosis, *The Journal of Allergy and Clinical Immunology: In Practice*, nr 9(6), Elsevier 2021, s. 2255-2261. <https://doi.org/10.1016/j.jaip.2021.02.014>

¹³ Y. K. Dwivedi, L. Hughes, E. Ismagilova i in., Artificial Intelligence (AI): Multidisciplinary Perspectives on Emerging Challenges, Opportunities, and Agenda for Research, Practice and Policy, *International Journal of Information Management*, nr 57, Article 101994, Elsevier 2021, s. 1-97. <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>

minimalizując ryzyko ludzkich błędów podczas przetwarzania danych medycznych¹⁴. Wśród tych systemów można wymienić systemy informacji szpitalnej, klinicznej, laboratoryjnej i radiologicznej – każdy z nich odgrywa ważną rolę w integracji danych, umożliwiając ich szybkie udostępnianie i analizę¹⁵:

- Systemy informacji szpitalnej (ang. Hospital Information Systems, HIS) wspierają zarządzanie pracą szpitala, np. rejestracją pacjentów, planowaniem zabiegów czy obsługą płatności.
- Systemy informacji klinicznej (ang. Clinical Information Systems, CIS) wspierają pracę lekarzy, umożliwiając im łatwy dostęp do danych, takich jak wyniki badań czy historie chorób pacjentów.
- Systemy informacji laboratoryjnej (ang. Laboratory Information Systems, LIS) zarządzają danymi z badań laboratoryjnych w zakresie szybszej ich dostępności dla lekarzy i pacjentów.
- Systemy informacji radiologicznej (ang. Radiology Information Systems, RIS) wspierają zarządzanie pracą w działach radiologii, planowania badań obrazowych i obsługi wyników.
- Systemy archiwizacji i komunikacji obrazów (ang. Picture Archiving and Communication Systems, PACS) umożliwiają przechowywanie obrazów medycznych, oraz umożliwiają ich łatwe przeglądanie i przesyłanie.

Opisane systemy HIS, CIS, LIS, RIS i PACS wspierają różne aspekty pracy medycznej. Automatyzacja procesów administracyjnych w opiece zdrowotnej, od zarządzania operacjami wewnątrzszpitalnymi po szybszy dostęp do wyników badań i obrazów diagnostycznych, przynosi korzyści, które znacząco wpływają na jakość świadczonych usług oraz pozwalają na znaczne oszczędności czasu – zarówno pacjentów, jak i personelu medycznego¹⁶. Poprawia to istotnie komfort pacjentów, ale również zwiększa efektywność wykorzystania zasobów szpitalnych, co jest korzystne dla wszystkich stron. Widać więc wyraźnie, iż w szerszym kontekście, dzięki usprawnieniu pracy poprzez systemy informatyczne, cyfryzacja medycyny przyczynia się do transformacji całego sektora opieki zdrowotnej.

¹⁴ W. Xu, M. J. Dainoff, L. Ge, Z. Gao, From Human-Computer Interaction to Human-AI Interaction: New Challenges and Opportunities for Enabling Human-Centered AI, ArXiv 2021, s. 1-73. <https://arxiv.org/abs/2105.05424v1>

¹⁵ Y. Yu, M. Li, L. Liu, Y. Li, J. Wang, Clinical big data and deep learning: Applications, challenges, and future outlooks, Big Data Mining and Analytics, nr 2(4), IEEE 2019, s. 288-305. <https://doi.org/10.26599/BDMA.2019.9020007>

¹⁶ M. Islam, T. N. Poly, Y.-C. Li, Recent Advancement of Clinical Information Systems: Opportunities and Challenges, Yearbook of Medical Informatics, nr 27(01), Schattauer 2018, s. 83-90. <https://doi.org/10.1055/s-0038-1667075>

Big data w badaniach medycznych i rozwoju nowych terapii

W branży medycznej od dawna zbiera się różnego rodzaju dane, takie jak wyniki badań klinicznych, dokumentację szpitalną lub informacje od ubezpieczycieli. Jednak obecnie dzięki technologii można pracować na bardzo dużych zestawach danych i łączyć informacje z różnych źródeł – z badań naukowych oraz praktyki lekarskiej. Dzięki temu można zaobserwować, jak big data w badaniach medycznych już rewolucjonizuje sposób, w jaki diagnozuje się, leczy i przewiduje nowe wzorce rozwoju chorób. Jest to tematyka o rosnącym znaczeniu, która wpływa na rozwój współczesnej medycyny i opieki zdrowotnej. Branża medyczna w XXI wieku istotnie wiąże się z big data, ponieważ medycyna generuje obecnie ogromne ilości danych, które stają się coraz bardziej złożone i trudne do interpretacji za pomocą tradycyjnych metod. Pochodzą one z różnorodnych źródeł, między innymi takich jak dokumentacja medyczna pacjentów, wyniki badań, obrazowanie medyczne, badania genetyczne. Włączyć tu też można dane z urządzeń noszonych przez pacjentów, np. specjalistyczne urządzenia medyczne monitorujących stan zdrowia lub zwykłe smartwatche.

Bardzo dobrą ilustrację stanowią tutaj elektroniczne karty zdrowia (ang. Electronic Health Records, EHRs), które są wspierane i zalecane przez UE¹⁷, a których rynek w Europie ma osiągnąć wartość 2,37 miliarda USD do końca 2024 roku. Z kolei prognozy wzrastającej wartości przychodów z rozwiązań w zakresie elektronicznej dokumentacji medycznej są przewidywane na poziomie 3,94 miliarda USD do końca 2034 roku¹⁸. Otóż elektroniczne karty zdrowia zawierają informacje o każdym aspekcie zdrowia pacjenta, od historii chorób, przez wyniki badań diagnostycznych, aż po informacje o przebiegu leczenia. Przy czym dane te są dynamicznie uaktualniane i rozbudowywane, co tworzy poważne wyzwania związane z ich efektywnym przetwarzaniem i wykorzystywaniem w czasie rzeczywistym – wymaga to zastosowania zaawansowanych narzędzi analizy i metod obliczeniowych.

W kontekście big data, dane z urządzeń noszonych przez pacjentów, od zaawansowanych medycznych urządzeń monitorujących po codziennie noszone smartwatche, wprowadzają nową jakość w monitorowaniu zdrowia pacjentów.

¹⁷ Zalecenie Komisji UE 2019/243, które ma na celu ułatwienie transgranicznej interoperacyjności elektronicznej dokumentacji medycznej w UE. <https://digitalhealth.europe.eu/glossary/european-electronic-health-record-exchange-format/> [dostęp 05.2024]

¹⁸ Fact.MR, Electronic Health Records Industry Analysis in Europe (2024-2034), raport, 2024, <https://www.factmr.com/report/europe-electronic-health-records-market> [dostęp 05.2024]

Urządzenia takie mogą zbierać dane w czasie rzeczywistym, monitorując takie parametry jak rytm serca, poziom tlenu we krwi, aktywność fizyczną czy jakość snu. Analiza tych danych dostarcza informacji, które mogą być wykorzystywane do wczesnego wykrywania nieprawidłowości zdrowotnych lub do dostosowania leczenia do bieżących potrzeb pacjenta. Dane te mogą mieć także charakter nieliniowy i obejmować długie okresy, co dodatkowo komplikuje ich analizę, ale jednocześnie otwiera drzwi do bardziej precyzyjnej medycyny personalizowanej. Dlatego też jednym z głównych zastosowań big data w badaniach medycznych jest odkrywanie nowych wzorców i zależności w przebiegu chorób oraz opracowywanie bardziej skutecznych strategii leczenia. To podejście jest szczególnie obiecujące w badaniach nad chorobami przewlekłymi i rzadkimi.

Ogromne zbiory danych klinicznych dostępne w postaci cyfrowej przyczyniają się do zupełnie nowych podejść w kwestii badań naukowych w obszarze medycyny. Połączenie różnych źródeł danych w jednym systemie i użycie ich w zaawansowanych modelach uczenia maszynowego i głębokiego uczenia istotnie poszerza zakres badań medycznych i pozwala na bardziej holistyczne podejście do leczenia, wpływając na przyszłość medycyny. W zależności od obranego celu badania zgromadzonych danych klinicznych, modele głębokiego uczenia są zazwyczaj wykorzystywane w czterech następujących obszarach¹⁹: wczesne ostrzeganie o potencjalnym problemie zdrowotnym, identyfikowanie czynników ryzyka, diagnostyka pomocnicza oraz prognoza rozwoju choroby. W praktyce oznacza to wsparcie lekarzy w podejmowaniu decyzji, np. w przewidywaniu ryzyka wystąpienia danej choroby, identyfikacji objawów specyficznych dla określonego schorzenia lub przewidywaniu, jak będzie przebiegała choroba. Dzięki temu można lepiej dostosować leczenie do indywidualnych potrzeb danej osoby, stąd też istotnym i często dyskutowanym aspektem jest personalizacja medycyny i teranostyka²⁰. Big data umożliwia analizę indywidualnych profili pacjentów, uwzględniając ich genetykę, styl życia i historię medyczną. Pozwala to na dostosowanie terapii do konkretnego pacjenta, zwiększając skuteczność leczenia i minimalizując efekty uboczne. Na przykład w onkologii analiza danych genetycznych pacjentów pozwala na dopasowanie terapii celowanej, co może znacząco zwiększyć skuteczność leczenia.

¹⁹ Y. Yu, M. Li, L. Liu, Y. Li, J. Wang, Clinical big data and deep learning: Applications, challenges, and future outlooks, *Big Data Mining and Analytics*, nr 2(4), IEEE 2019, s. 288-305. <https://doi.org/10.26599/BDMA.2019.9020007>

²⁰ MedicalPress, *Medycyna nuklearna - trendy i prognozy*, komentarz eksperta, 2023, https://medicalpress.pl/rynek/medycyna-nuklearna-trendy-i-prognozy_YWA8YLLv9D/ [dostęp 05.2024]

W diagnostyce onkologicznej sztuczna inteligencja wykazuje obiecujący potencjał w identyfikacji pacjentów o wysokim ryzyku poważnych incydentów zdrowotnych. Może pomagać w predykcji przejścia choroby w jej bardziej zaawansowany stan lub w predykcji nawrotu choroby, bazując na danych i wynikach badań dostępnych w elektronicznej dokumentacji medycznej²¹. Przykładem takiego zastosowania jest algorytm, który klasyfikuje raka skóry na podstawie analizy obrazu wykonanej wideodermatoskopii. Badania Estevy i zespołu wykazały, że taki algorytm może osiągnąć dokładność podobną do tej, jaką posiada wykwalifikowany dermatolog²². Sztuczna inteligencja może precyzyjniej określać granice guza, wspierając onkologów w interpretacji obrazów oraz w dokładnym planowaniu najodpowiedniejszej strategii terapeutycznej.

Z kolei w diagnostyce okulistycznej tomografia optyczna, czyli optyczna koherentna tomografia oka (ang. Optical Coherence Tomography, ang. OCT) pozwala zobaczyć strukturę siatkówki oka i wykryć różne choroby zagrażające wzrokowi. Algorytmy uczenia maszynowego wykorzystywane do analizy skanów z tomografii optycznej pomagają w automatycznym przetwarzaniu tych skanów oraz sugerują czy pacjent powinien być skierowany na pogłębiające badania, czy powinien być jak najszybciej skierowany na leczenie²³. Algorytmy te mogą przesiewać ogromne ilości danych obrazowych, aby zidentyfikować potencjalne nieprawidłowości, co znacznie skraca czas procesu diagnostycznego, decydujący o skierowaniu pacjenta na szczegółowe badania lub rozpoczęciu odpowiedniej terapii.

Algorytmy uczenia maszynowego zastosowane w psychiatrii i neurologii są w stanie przetwarzać ogromne ilości danych behawioralnych dla lepszego zrozumienia zaburzeń psychicznych i neurologicznych. Na przykład, analiza wzorców snu może wskazywać na potencjalne zaburzenia snu lub prowadzić do rozwoju nowych zaburzeń, co daje pole dla wczesnej interwencji. Innym przykładem jest analiza wzorców użytkowania smartfona, aby wykrywać zmiany sugerujące pogorszenie stanu psychicznego²⁴.

²¹ J. A. M. Sidey-Gibbons, C. J. Sidey-Gibbons, Machine learning in medicine: a practical introduction, BMC Medical Research Methodology, nr 19, Article 64, Springer Nature 2019, s. 1-18. <https://doi.org/10.1186/s12874-019-0681-4>

²² A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau, S. Thrun, Dermatologist-level classification of skin cancer with deep neural networks, Nature, nr 542, Article 7639, Springer Nature 2017, s. 115-118. <https://doi.org/10.1038/nature21056>

²³ S. D. Auger, B. M. Jacobs, R. Dobson, Ch. R. Marshall, A. J. Noyce, Big data, machine learning and artificial intelligence: a neurologist's guide, Practical Neurology, nr 21(1), BMJ 2021, s. 4-11. <https://doi.org/10.1136/practneurol-2020-002688>

²⁴ J. Lee, W. Kim, Prediction of Problematic Smartphone Use: A Machine Learning Approach, International Journal of Environmental Research and Public Health, nr 18(12), Article 6458, MDPI 2021. s. 1-13. <https://doi.org/10.3390/ijerph18126458>

Uczenie maszynowe znajduje praktyczne zastosowanie przy przetwarzaniu elektrycznej aktywności mózgu w postaci zapisów elektroencefalogramu (ang. electroencephalogram, EEG). Badania z użyciem głębokiego uczenia na zapisach elektroencefalogramów wykazały, że nawet do 15% osób po ostrym urazie mózgu, które nie reagowały na polecenia słowne, wykazywały wykrywalną aktywność mózgu w odpowiedzi na te polecenia²⁵. Zainicjowało to badania w kierunku ukrytej świadomości u pacjentów w śpiączce.

Zastosowanie sztucznej inteligencji w hodowli komórek i tkanek znacząco przyczynia się do postępu w biotechnologii i medycynie regeneracyjnej. Dzięki temu, możliwe jest bardziej efektywne projektowanie protokołów hodowlanych oraz tworzenie bardziej złożonych modeli hodowli, takich jak hodowle 3D, czyli trójwymiarowe struktury tkankowe, które naśladują naturalne narządy²⁶. Badania nad takimi organoidami otwierają nowe perspektywy w testowaniu skuteczności leków, zanim zostaną one zastosowane w terapii ludzi, co znacznie zwiększa bezpieczeństwo i skuteczność leczenia.

Warto również zwrócić uwagę na rolę big data w badaniach epidemiologicznych. Analiza dużych zbiorów danych pozwala na szybsze wykrywanie ognisk chorób zakaźnych, monitorowanie rozprzestrzeniania się epidemii oraz ocenę skuteczności interwencji zdrowotnych na poziomie populacji. Wykorzystując dane demograficzne, informacje o mobilności ludności oraz np. dane z mediów społecznościowych, dzięki sztucznej inteligencji można tworzyć modele rozprzestrzeniania się chorób w czasie rzeczywistym. Przykładem może być analiza rozprzestrzeniania się koronawirusa SARS-CoV-2, który powoduje chorobę znaną jako COVID-19. W trakcie pandemii COVID-19 big data oraz modele uczenia maszynowego pozwalały na śledzenie ognisk choroby, ocenę ryzyka transmisji oraz planowanie interwencji zdrowotnych²⁷. Ponadto, niezwykle przedsięwzięciem naukowym, które połączyło zaawansowane technologie, globalną współpracę oraz szybkie tempo badań, było zaprojektowanie szczepionki w trakcie pandemii COVID-19. Proces ten wymagał jednoczesnego zastosowania klasycznych metod

²⁵ S. D. Auger, B. M. Jacobs, R. Dobson, Ch. R. Marshall, A. J. Noyce, Big data, machine learning and artificial intelligence: a neurologist's guide, *Practical Neurology*, nr 21(1), BMJ 2021, s. 4-11. <https://doi.org/10.1136/practneurol-2020-002688>

²⁶ H. Nosrati, M. Nosrati, Artificial Intelligence in Regenerative Medicine: Applications and Implications, *Biomimetics*, nr 8(5), Article 442, MDPI 2023, s.1-23. <https://doi.org/10.3390/biomimetics8050442>

²⁷ Q. Pham, D. C. Nguyen, T. Huynh-The, W. Hwang, P. N. Pathirana, Artificial Intelligence (AI) and Big Data for Coronavirus (COVID-19) Pandemic: A Survey on the State-of-the-Arts, *IEEE Transactions on Artificial Intelligence*, IEEE 2020, s. 1-17. <https://doi.org/10.13140/RG.2.2.23518.38727>

badawczych oraz innowacyjnych rozwiązań, w tym analiz big data i sztucznej inteligencji²⁸. Szczepionki oparte na technologii mRNA (udostępnione w zasadzie równolegle przez firmy Pfizer-BioNTech oraz Moderna), zostały opracowane w rekordowym czasie. Było to możliwe dzięki szybkiemu zsekwencjonowaniu wirusa (chińscy naukowcy zrobili to z końcem grudnia 2019 r.²⁹) i szybkiego udostępnienia tych danych społeczności naukowej na całym świecie. Następnie zastosowano po raz pierwszy na dużą skalę technologię mRNA, gdzie analiza dużych zbiorów danych odegrała kluczową rolę: badacze wykorzystali dane z badań klinicznych, aby szybko oceniać skuteczność i bezpieczeństwo różnych prototypów szczepionek. Sztuczna inteligencja pomogła w analizie tych wyników i identyfikacji potencjalnych skutków ubocznych³⁰.

Postęp w zakresie cyfryzacji danych klinicznych oraz integracja różnych źródeł zbiorów big data znacząco poszerzają możliwości medycyny dzięki zastosowaniu zaawansowanych modeli uczenia maszynowego i głębokiego uczenia. Zastosowanie głębokiego uczenia w analizie danych medycznych rewolucjonizuje procesy diagnostyczne i terapeutyczne, otwierając nowe możliwości w personalizowanej medycynie. Rosnąca liczba opracowywanych algorytmów wskazuje na intensyfikację badań nad zastosowaniem zaawansowanych metod analitycznych w medycynie.

Przetwarzanie obrazów na potrzeby decyzji klinicznych

Rozwój sztucznych sieci neuronowych oraz głębokich sieci neuronowych w ostatnich latach silnie wpłynął na rozwój możliwości analizy obrazów medycznych. Różnorodność architektur tych sieci umożliwia dostosowanie metod głębokiego uczenia do specyficznych zadań medycznych. W zależności od konfiguracji hiperparametrów i procesu uczenia modelu, sieci neuronowe mogą wspierać lekarzy w predykcji chorób na podstawie analizy obrazów medycznych.

²⁸ L. L. Wang, K. Lo, Text mining approaches for dealing with the rapidly expanding literature on COVID-19, *Briefings in Bioinformatics*, nr 22(2), Oxford Academic 2021, s. 781-799. <https://doi.org/10.1093/bib/bbaa296>

²⁹ G. Demaneuf, Sequencing and early analysis of SARS-CoV-2 (27 Dec 2019) - The crushed hopes of Little Mountain Dog of Vision Medicals, preprint 2022, s. 1-54. <https://doi.org/10.13140/RG.2.2.21497.54888/1>

³⁰ R. Kaushik, R. Kant, M. Christodoulides, Artificial intelligence in accelerating vaccine development - current and future perspectives, *Frontiers in Bacteriology*, nr 2, Article 1258159, Frontiers Media 2023, s. 1-8. <https://doi.org/10.3389/fbrio.2023.1258159>

Poniżej omówiono wiodące zastosowania tych technologii pod kątem przetwarzania obrazowania medycznego³¹:

1. Diagnostyka chorób oczu skupia się na precyzyjnej detekcji zmian chorobowych w obrazach siatkówki. Głębokie sieci neuronowe konwolucyjne (ang. Convolutional Neural Networks, CNN) oraz ich warianty, są powszechnie wykorzystywane do wykrywania i klasyfikacji chorób oczu, takich jak zwyrodnienie plamki żółtej związanej z wiekiem oraz retinopatia cukrzycowa.
2. Segmentacja obrazów jest używana przykładowo na potrzeby kardiologii do identyfikacji czynników ryzyka. Metody segmentacji obrazów opierają się na sieciach CNN i głębokich sieciach neuronowych (ang. Deep Neural Network, DNN).
3. Zastosowane w diagnostyce neurodegeneracyjnej modele pozwalają na klasyfikację pacjentów na grupy kontrolne oraz na identyfikację różnych stadiów chorób takich jak Alzheimer, choroba Huntingtona lub schizofrenia. Metody te obejmują CNN, rekurencyjne sieci neuronowe (ang. Recurrent Neural Networks, RNN), autoenkodery ułożone w stos (ang. Stacked Autoencoder, SAE) i architektury głębokich sieci przekonań (ang. Deep Belief Networks, DBN).
4. Zastosowane w analizie obrazów rezonansu magnetycznego modele pozwalają na segmentację i klasyfikację różnych struktur anatomicznych (np. lewa komora serca, kręgi, krążki międzykręgowe). Modele CNN są dominujące w tej dziedzinie, ale inne architektury, takie jak RNN, również są stosowane, na przykład w celu identyfikacji konkretnych faz cyklu sercowego.
5. Analiza obrazów z tomografii komputerowej, w której sieci CNN są wykorzystywane do segmentacji różnych narządów (np. wątroby, nerek, trzustki) oraz do detekcji zmian patologicznych, takich jak polipy jelitowe.

³¹ Y. Yu, M. Li, L. Liu, Y. Li, J. Wang, Clinical big data and deep learning: Applications, challenges, and future outlooks, *Big Data Mining and Analytics*, nr 2(4), IEEE 2019, s. 288-305. <https://doi.org/10.26599/BDMA.2019.9020007>; D. S. Kermany, M. Goldbaum, W. Cai, C. C. S. Valentim, H. Liang, i in., Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning, *Cell*, nr 172(5), Elsevier 2018, s. 1122-1131. <https://doi.org/10.1016/j.cell.2018.02.010>; R. Poplin, A. V. Varadarajan, K. Blumer, Y. Liu, M. V. McConnell, G. S. Corrado, L. Peng, D. R. Webster, Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning, *Nature Biomedical Engineering*, nr 2(2), Springer Nature 2018, s. 158-164. <https://doi.org/10.1038/s41551-018-0195-0>; Q. Zhou, J. Wang, X. Yu, S. Wang, Y. Zhang, A Survey of Deep Learning for Alzheimer's Disease, *Machine Learning and Knowledge Extraction*, nr 5(2), MDPI 2023, s. 611-668. <https://doi.org/10.3390/make5020035>

6. Klasyfikacja i detekcja w obrazach rentgenowskich, gdzie głębokie uczenie jest używane w wykrywaniu wielu schorzeń, od chorób płucnych (np. gruźlica, choroby śródmiąższowe) po zmiany nowotworowe (np. rozróżnianie między masami złośliwymi a torbielami łagodnymi). Techniki takie jak CNN oraz SAE znajdują szerokie zastosowanie w klasyfikacji tkanek, analizie gęstości piersi i wykrywaniu patologii.
7. Prognozowanie przebiegu chorób, np. prognozy przeżywalności pacjentów oraz przewidywanie śmiertelności wśród osób starszych na podstawie obrazów medycznych.

Na podstawie powyższej listy zastosowań sztucznych sieci neuronowych można zauważyć, że w analizie obrazów medycznych najczęściej stosowane są sieci CNN. Różnorodność architektur tych sieci (np. CNN, RNN, SAE, DBN) jest elastycznie dostosowywana do specyficznych zadań, takich jak detekcja, klasyfikacja, segmentacja czy predykcja, w zależności od przeznaczenia danego modelu.

Przetwarzanie języka naturalnego w branży medycznej

Wspomniane sztuczne sieci neuronowe oraz architektury głębokiego uczenia są wykorzystywane w różnorodnych zadaniach obejmujących przetwarzanie tekstu pochodzącego z systemów medycznych. Pod kątem przetwarzania i analiz danych tekstowych w języku naturalnym, można wymienić wiodące zastosowania³²:

1. Automatyzacja kodowania ICD. Sieci RNN i CNN są stosowane do automatycznego przypisywania kodów ICD-9 oraz ICD-10 na podstawie dokumentacji medycznej.
2. Automatyczne przypisywanie przyczyn zgonu. Sieci RNN okazały się skuteczne w przypisywaniu kodów ICD-10 do przyczyn zgonu zawartych w dokumentacji medycznej.

³² Y. Yu, M. Li, L. Liu, Y. Li, J. Wang, Clinical big data and deep learning: Applications, challenges, and future outlooks, *Big Data Mining and Analytics*, nr 2(4), IEEE 2019, s. 288-305. <https://doi.org/10.26599/BDMA.2019.9020007>; E. Hossain, R. Rana, N. Higgins, J. Soar, P. D. Barua, A. R. Pisani, K. Turner, Natural Language Processing in Electronic Health Records in relation to healthcare decision-making: A systematic review, *Computers in Biology and Medicine*, nr 155, Article 106649, Elsevier 2023, s.1-58. <https://doi.org/10.1016/j.compbiomed.2023.106649>; F. Grässer, S. Kallumadi, H. Malberg, S. Zaunseder, Aspect-Based Sentiment Analysis of Drug Reviews Applying Cross-Domain and Cross-Data Learning. [w:] DH'18: 2018 International Digital Health Conference, ACM, New York, USA, 2018, s. 1-5. <https://doi.org/10.1145/3194658.3194677>; N. Bakkar, T. Kovalik, I. Lorenzini, S. Spangler, A. Lacoste, K. Sponaugle, Ph. Ferrante, E. Argentinis, R. Sattler, B. Bowser, Artificial intelligence in neurodegenerative disease research: use of IBM Watson to identify additional RNA-binding proteins altered in amyotrophic lateral sclerosis. *Acta Neuropathologica*, nr 135(2), Springer 2018, s. 227-247. <https://doi.org/10.1007/s00401-017-1785-8>.

3. Ekstrakcja fenotypów i relacji między pojęciami medycznymi. Sieci CNN i RNN zostały wykorzystane do klasyfikacji powiązań i asocjacji oraz do ekstrakcji genotypów i fenotypów z danych medycznych³³. Zastosowanie analizy genotypów i fenotypów pozwala na identyfikowanie mutacji, które mogą odpowiadać za rozwój konkretnych chorób, co umożliwia wczesną diagnozę i ukierunkowaną terapię.
4. Ekstrakcja informacji z raportów medycznych i deidentyfikacja (nazywana też anonimizacją danych). Sieci RNN oraz kombinacje RNN i CNN są skuteczne w wyodrębnianiu wielu informacji z raportów patologicznych. RNN są również stosowane w celu maskowania danych osobowych pacjentów w zapisach medycznych, co jest ważne z punktu widzenia zachowania prywatności i ochrony danych osobowych w dokumentacji badań.
5. Rozpoznawanie nazwanych encji (ang. Named Entity Recognition, NER). Sieci RNN są stosowane do identyfikacji i klasyfikacji encji, czyli pojęć takich jak nazwy leków, substancji czynnych lub chorób, występujących w danych tekstowych.
6. Analiza sentymentu. Użycie słowników sentymentu oraz modeli kategoryzacji pozwala analizować wydźwięk emocjonalny tekstu, a dzięki ich zastosowaniu, można lepiej zrozumieć nastroje pacjentów na podstawie wypełnianych ankiet dotyczących doświadczeń z placówką, lekarzem i przebytą terapią w opiece zdrowotnej.
7. Identyfikacja tematów w zbiorze dokumentów. Metoda używana do znajdowania tematów w zbiorze dokumentów to ukryta alokacja Dirichleta (ang. Latent Dirichlet Allocation, LDA). Zakłada ona, że każdy dokument w zbiorze danych tekstowych jest mieszaniną różnych tematów, a każdy temat jest mieszaniną tworzących go słów. Jest ona bardzo przydatnym narzędziem do analizowania tematów pojawiających się w dużych zbiorach tekstowych. Przykładowo, analiza LDA zbioru tekstowych recenzji leków może wykazać, że substancja lecznicza o nazwie *citalopram* należy zarówno do grupy leków antydepresyjnych, jak i do grupy tematycznych recenzji leków powodujących efekty uboczne, takich jak nudności³⁴.

³³ M. Baddour, S. Paquelet, P. Rollier, M. De Tayrac, O. Dameron, T. Labbe, Phenotypes Extraction from Text: Analysis and Perspective in the LLM Era, Proceedings of 2024 IEEE 12th International Conference on Intelligent Systems, IEEE 2024, s. 1-8. <https://doi.org/10.1109/IS61756.2024.10705235>

³⁴ C. J. Harrison, C. J. Sidey-Gibbons, Machine learning in medicine: a practical introduction to natural language processing, BMC Medical Research Methodology, nr 21, Article 158, Springer Nature 2021, s. 1-11. <https://doi.org/10.1186/s12874-021-01347-1>

Analizując wiodące zastosowania przetwarzania języka naturalnego można zauważyć, że w analizie tekstów medycznych najczęściej stosowane są sieci RNN oraz ich odmiany, co wynika ze zdolności tych sieci do modelowania kontekstu i sekwencji w dokumentach medycznych. Połączenie dwóch architektur sieci neuronowych RNN i CNN jest zazwyczaj stosowane w bardziej złożonych i wymagających zadaniach, takich jak na przykład wieloaspektowa ekstrakcja informacji z raportów patologicznych (dotyczących biopsji i materiału pooperacyjnego)³⁵. Zautomatyzowana analiza tekstu medycznego na rosnącej ilości dokumentacji klinicznej umożliwia wydobywanie istotnych informacji z elektronicznych kart pacjentów i raportów laboratoryjnych i tym samym wspiera automatyzację wielu procesów administracyjnych placówek medycznych.

Dane wielomodalne

Jednym z wyzwań związanych z big data we współczesnej medycynie jest różnorodność formatów danych. Metody obrazowania medycznego, takie jak tomografia komputerowa (ang. Computed Tomography, CT), rezonans magnetyczny (ang. Magnetic Resonance Imaging, MRI) i cholangiografia (ang. Magnetic Resonance Cholangiopancreatography, MRCP) czy ultrasonografia (ang. Ultrasonography, USG), generują olbrzymie ilości danych obrazowych. Dane obrazowe różnią się fundamentalnie od danych półustrukturyzowanych i tekstowych zawartych w elektronicznych kartach zdrowia. Dodatkowo wymagają one zaawansowanych metod przetwarzania obrazu i specjalistycznych technik analizy wzorców oraz równie specjalistycznych narzędzi do wykonywania takich analiz. Pokonanie tych problemów jest kluczowe, ponieważ przetwarzanie dużych zbiorów danych obrazowych umożliwia identyfikowanie subtelnych zmian w tkankach, które mogą wskazywać na rozwój ogniska chorobowego lub nowotworu, zanim stanie się to widoczne dla ludzkiego oka.

Podobny problem dotyczy innych zadań związanych z różnymi formatami danych, pozyskiwanych z różnorodnych źródeł, takich jak raporty radiologiczne, notatki z przyjęcia i wypisu ze szpitala, akty zgonu, a nawet wyniki autopsji. We wszystkich tych sytuacjach analiza danych powinna obejmować pełen zakres informacji, począwszy od diagnozy, przez przebieg leczenia, aż po wyniki

³⁵ G. Huang, Y. Li, S. Jameel, Y. Long, G. Papanastasiou, From explainable to interpretable deep learning for natural language processing in healthcare: How far from reality?, *Computational and Structural Biotechnology Journal*, nr 24, Elsevier 2024, s. 362-373. <https://doi.org/10.1016/j.csbj.2024.05.004>

końcowe³⁶. Istotną cechą tych analiz jest użycie danych wielomodalnych, co oznacza, że dane pochodzące z różnych źródeł (np. tekst, obrazy, wyniki badań) powinny być analizowane łącznie, co pozwala na uzyskanie pełniejszego obrazu stanu pacjenta i może prowadzić do bardziej trafnych diagnoz oraz lepszego planowania leczenia.

Z pomocą przychodzą tutaj algorytmy uczenia maszynowego i głębokich sieci neuronowych. Pod kątem przetwarzania danych wielomodalnych i analiz różnorodnych danych klinicznych, można wymienić wiodące ich zastosowania³⁷:

1. Szerokie zastosowanie CNN i DNN w diagnostyce obrazowej, np. w rozpoznawaniu obrazów radiologicznych lub wykrywaniu zmian mikroaneuryzmatycznych w siatkówce oka.
2. Analiza notatek z przyjęcia do szpitala czy podsumowania wypisów, gdzie algorytmy DNN pozwalają na identyfikację kluczowych informacji medycznych w dokumentach i rozpoznawania nazwanych encji (NER), jest szczególnie przydatne przy przypisywaniu kodów ICD.
3. W połączeniu z danymi obrazowymi oraz tekstowymi, metody takie jak DNN i RNN umożliwiają wczesne wykrywanie ryzyka chorób, takich jak choroba Alzheimera czy niewydolność serca, pomagając w identyfikacji osób zagrożonych rozwinięciem się danego schorzenia.
4. Algorytmy RNN, DNN oraz DBN są używane do przewidywania chorób na podstawie kodów medycznych, informacji demograficznych oraz wyników badań laboratoryjnych, bazując na analizie danych z elektronicznej dokumentacji medycznej.

³⁶ G. Litjens, T. Kooi, B. E. Bejnordi, A. A. A. Setio, F. Ciompi, M. Ghafoorian, J. A. W. M. van der Laak, B. van Ginneken, C. I. Sanchez, A survey on deep learning in medical image analysis, *Medical Image Analysis*, nr 42, Elsevier 2017, s. 60-88. <https://doi.org/10.1016/j.media.2017.07.005>

³⁷ Y. Yu, M. Li, L. Liu, Y. Li, J. Wang, Clinical big data and deep learning: Applications, challenges, and future outlooks, *Big Data Mining and Analytics*, nr 2(4), IEEE 2019, s. 288-305. <https://doi.org/10.26599/BDMA.2019.9020007>; L. Dai, R. Fang, H. Li, X. Hou, B. Sheng, Q. Wu, W. Jia, Clinical Report Guided Retinal Microaneurysm Detection With Multi-Sieving Deep Learning, *IEEE Transactions on Medical Imaging*, nr 37(5), IEEE 2018, s. 1149-1161. <https://doi.org/10.1109/TMI.2018.2794988>; Y. Wu, M. Jiang, J. Xu, D. Zhi, H. Xu, Clinical Named Entity Recognition Using Deep Learning Models, *AMIA Annual Symposium Proceedings*, AMIA 2018, s. 1812-1819; D. Fraile Navarro, K. Ijaz, D. Rezazadegan, H. Rahimi-Ardabili, M. Dras, E. Coiera, S. Berkovsky, Clinical named entity recognition and relation extraction using natural language processing of medical free text: A systematic review, *International Journal of Medical Informatics*, nr 177, Article 105122, Elsevier 2023, s. 1-21. <https://doi.org/10.1016/j.ijmedinf.2023.105122>; A. Rajkomar, E. Oren, K. Chen, A. M. Dai, N. Hajaj, M. Hardt, P. J. Liu, X. Liu, J. Marcus, M. Sun, P. Sundberg i in., Scalable and accurate deep learning with electronic health records, *npj Digital Medicine*, nr 1(1), Article 18, Springer Nature 2018, s. 1-26. <https://doi.org/10.1038/s41746-018-0029-1>

5. Algorytmy CNN, DNN i RNN umożliwiają prognozowanie nieplanowanych readmisji, czyli oceny ryzyka powrotu pacjenta do szpitala. W tym kontekście modele sieci neuronowych dokonują długoterminowych prognoz dotyczących konkretnego pacjenta, takich jak np. 30-dniowe nieplanowane przyjęcia, długość pobytu w szpitalu czy końcowa diagnoza. Takie modele pomagają w usprawnianiu procesów opieki poszpitalnej oraz zarządzaniu zasobami szpitala, a nawet w prognozowaniu śmiertelności w trakcie pobytu w szpitalu.

W kontekście danych wielomodalnych, algorytmy uczenia maszynowego i analityka big data mają również kluczowe znaczenie w usprawnieniu procesu identyfikacji, monitorowania i oceny bezpieczeństwa w farmakoterapii. Wspomniana wcześniej amerykańska rządowa agencja FDA wspiera nadzór nad bezpieczeństwem po wprowadzeniu leków i terapeutycznych produktów biologicznych oraz zarządza systemem zgłaszania i gromadzenia opisów wystąpień zdarzeń niepożądanych. Zaprojektowana w tym celu baza danych FAERS (ang. FDA's Adverse Event Reporting System, FAERS)³⁸, zawiera raporty o zdarzeniach niepożądanych, raporty o błędach w stosowaniu leków i skargi dotyczące jakości produktów skutkujące zdarzeniami niepożądanymi, które zostały przesłane do FDA. Dlatego też dzięki wykorzystaniu danych z bazy FAERS możliwe jest trenowanie modeli uczenia maszynowego, aby na czas rozpoznawać informacje, które mogą sugerować, że jakiś lek wywołuje działania niepożądane lub niebezpieczne dla pacjentów. Dzięki temu procesowi, jeśli algorytm wykryje sygnał ostrzegawczy, można podjąć szybkie działania, np. sprawdzić, czy dany lek jest bezpieczny, a jeśli nie – podjąć odpowiednie kroki zapobiegawcze, takie jak szybkie poinformowanie personelu medycznego lub wycofanie leku z rynku. Wykorzystując analizę bardzo dużych zbiorów danych bazy FAERS algorytmy mogą automatycznie sortować i przetwarzać zgłoszenia o działaniach niepożądanych, wykrywając potencjalnie niebezpieczne wzorce i trendy oraz identyfikując zależność między stosowaniem określonego leku a występowaniem działań niepożądanych³⁹.

Sztuczna inteligencja odgrywa coraz większą rolę w medycynie i farmakologii, zwłaszcza w procesie projektowania leków i odkrywania nowych substancji leczniczych. Identyfikacja nowych cząsteczek i wybór tych najbardziej obiecujących do badań klinicznych są istotnymi krokami w procesie odkrywania leków.

³⁸ FDA's Adverse Event Reporting System (FAERS), <https://www.fda.gov/drugs/surveillance/fdas-adverse-event-reporting-system-faers> [dostęp 05.2024]

³⁹ A. H. Ali, S. Saber, Leveraging FAERS and Big Data Analytics with Machine Learning for Advanced Healthcare Solutions, *Applied Research in Artificial Intelligence and Cloud Computing*, nr 5(1), ResearchBerg 2022, s. 121-134.

Jednakże jednym z głównych wyzwań w tym procesie jest jego czasochłonność i złożoność – stosując tradycyjne metody, odkrywanie nowego leku może trwać wiele lat. Sztuczna inteligencja zmienia ten schemat i przyspiesza tempo odkrywania leków. Dzięki analizie big data i modelowaniu komputerowemu algorytmy sztucznej inteligencji prognozują i oceniają, jak różne związki chemiczne będą oddziaływać z celami biologicznymi⁴⁰. Badania w nanomedycynie pokazują, że poprzez przetwarzanie zbiorów danych big data i rozpoznawanie w nich złożonych wzorców modele sztucznej inteligencji wspierają projektowanie nanotechnologii na potrzeby diagnostyki i leczenia, a także optymalizację właściwości materiałów na podstawie ich interakcji z lekami docelowymi, płynami biologicznymi, układami odpornościowymi i błonami komórkowymi⁴¹. Dzięki wykorzystaniu sztucznej inteligencji możliwe jest szybkie analizowanie tysięcy potencjalnych cząsteczek, przewidywanie ich właściwości farmakologicznych oraz ocena, które z nich mają największe szanse na sukces terapeutyczny. W rezultacie skraca to czas potrzebny na opracowanie nowych terapii oraz pozwala skoncentrować się na tych cząsteczkach, które mają największy potencjał w walce z określonymi chorobami⁴². Sztuczna inteligencja umożliwia zatem zwiększenie tempa odkrywania leków, jednocześnie obniżając koszty związane z badaniami klinicznymi.

Nie ma wątpliwości co do tego, że big data już odgrywa i będzie wciąż odgrywać kluczową rolę w przyszłości medycyny, poprzez korzystanie zarówno z nowych źródeł informacji oraz stosowanie nowoczesnych technik analizy na już posiadanych danych, które szpitale i inne placówki medyczne gromadziły przez lata. W miarę jak technologie analiz big data będą się rozwijać, można spodziewać się jeszcze bardziej zaawansowanych narzędzi, wspierających personel medyczny w podejmowaniu decyzji diagnostycznych i terapeutycznych. Jednakże, pomimo ogromnych korzyści, stosowanie big data w medycynie wiąże się również z bardzo istotnymi wyzwaniami. Aktualnie najważniejszym z nich jest problem zapewnienia prywatności i bezpieczeństwa danych pacjentów⁴³. Wrażliwe dane

⁴⁰ M. K. Goshisht, Machine Learning and Deep Learning in Synthetic Biology: Key Architectures, Applications, and Challenges, ACS Omega, nr 9(9), ACS Publications 2024, s. 9921-9945. <https://doi.org/10.1021/acsomega.3c05913>

⁴¹ M. O. Ori, F. M. Ekpan, H. S. Samuel, O. P. Ekwuatu, Integration of Artificial Intelligence in Nanomedicine, Eurasian Journal of Science and Technology, nr 4(2), Sami Publishing 2024, s. 88-104. <https://doi.org/10.48309/EJST.2024.422419.1105>

⁴² B. Raju, F. Jumah, O. Ashraf, V. Narayan, G. Gupta, H. Sun, P. Hilden, A. Nanda, Big data, machine learning, and artificial intelligence: a field guide for neurosurgeons, Journal of Neurosurgery, nr 135(2), AANS 2021, s. 373-383. <https://doi.org/10.3171/2020.5.JNS201288>

⁴³ C.-A. Azencott, Machine learning and genomics: precision medicine versus patient privacy, Philosophical Transactions: Mathematical, Physical and Engineering Sciences, nr 376(2128), The Royal Society 2018, s. 1-13. <https://doi.org/10.1098/rsta.2017.0350>

medyczne muszą być odpowiednio chronione, co wymaga zaawansowanych metod szyfrowania i zgodności z regulacjami prawnymi, choćby takimi jak RODO (Rozporządzenie o Ochronie Danych Osobowych) oraz GDPR (ang. General Data Protection Regulation)⁴⁴.

Na zakończenie tego rozdziału należy podkreślić znaczenie interdyscyplinarności w badaniach medycznych wykorzystujących big data. Skuteczna analiza, która prowadzi do głębszego zrozumienia chorób, personalizacji leczenia i poprawy zdrowia publicznego, wymaga współpracy specjalistów z różnych dziedzin, takich jak medycyna, informatyka, statystyka, a także etyka. Ta multidyscyplinarna perspektywa jest niezbędna do pełnego wykorzystania potencjału big data w badaniach medycznych i rozwoju nowych terapii.

⁴⁴ H. Benbya, T. H. Davenport, S. Pachidi, Artificial Intelligence in Organizations: Current state and future opportunities, MIS Quarterly Executive, nr 19(4), MISRC 2020, s. 1-15. <https://doi.org/10.17863/CAM.63213>