



NICOLAUS COPERNICUS
UNIVERSITY
IN TORUŃ



Quality in Sport. eISSN 2450-3118.

Journal Home Page

<https://apcz.umk.pl/QS/index>

JURECZKO, Aleksandra, OSIŃSKI, Damian, KAWA, Zuzanna, KASPRZAK, Maria, JĘDRZEJEWSKA, Aleksandra, KLECZAJ, Klaudia, STARCZEWSKI, Łukasz, JAWOROWSKA, Julia, BABIARZ, Gabriela, and KANARSZCZUK, Julia. Zastosowanie sieci neuronowych oraz modeli uczenia maszynowego w diagnostyce, klasyfikacji oraz indywidualnym leczeniu schizofrenii. Application of Neural Networks and Machine Learning Models in the Diagnosis, Classification and Individual Treatment of Schizophrenia. Quality in Sport. 2026;54:70480. eISSN 2450-3118. <https://doi.org/10.12775/QS.2026.54.70480>

The journal has been awarded 20 points in the parametric evaluation by the Ministry of Higher Education and Science of Poland. This is according to the Annex to the announcement of the Minister of Higher Education and Science dated 05.01.2024, No. 32553. The journal has a Unique Identifier: 201398. Scientific disciplines assigned: Economics and Finance (Field of Social Sciences); Management and Quality Sciences (Field of Social Sciences).

Punkty Ministerialne z 2019 - aktualny rok 20 punktów. Załącznik do komunikatu Ministra Szkolnictwa Wyższego i Nauki z dnia 05.01.2024 Lp. 32553. Posiada Unikatowy Identyfikator Czasopisma: 201398. Przynależność dyscypliny naukowej: Ekonomia i finanse (Dziedzina nauk społecznych); Nauki o zarządzaniu i jakości (Dziedzina nauk społecznych). © The Authors 2026.

This article is published with open access under the License Open Journal Systems of Nicolaus Copernicus University in Toruń, Poland. Open Access: This article is distributed under the terms of the Creative Commons Attribution Noncommercial License, which permits any noncommercial use, distribution, and reproduction in any medium, provided the original author(s) and source are credited. This is an open access article licensed under the terms of the Creative Commons Attribution Non-commercial Share Alike License (<http://creativecommons.org/licenses/by-nc-sa/4.0/>), which permits unrestricted, non-commercial use, distribution, and reproduction in any medium, provided the work is properly cited.

The authors declare that there is no conflict of interest regarding the publication of this paper.

Received: 01.04.2026. Revised: 07.04.2026. Accepted: 08.04.2026. Published: 10.04.2026.

Zastosowanie sieci neuronowych oraz modeli uczenia maszynowego w diagnostyce, klasyfikacji oraz indywidualnym leczeniu schizofrenii

Application of Neural Networks and Machine Learning Models in the Diagnosis, Classification and Individual Treatment of Schizophrenia

Aleksandra Jureczko

ORCID <https://orcid.org/0009-0005-5562-2637>

E-mail olajureczko01@gmail.com

Student Scientific Club at the Department of Medical Informatics and Statistics with e-Health Lab, Medical University of Lublin,
Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Damian Osiński

ORCID <https://orcid.org/0009-0005-5197-3173>

E-mail osinski.damian00@gmail.com

Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Zuzanna Kawa

ORCID <https://orcid.org/0009-0009-2579-2888>

E-mail zuziak772@gmail.com

Student Scientific Club at the Department of Medical Informatics and Statistics with e-Health Lab, Medical University of Lublin
Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Maria Kasprzak

ORCID <https://orcid.org/0009-0005-4201-2231>

E-mail kasprzak.maria.anna@gmail.com

Student Scientific Club at the Department of Medical Informatics and Statistics with e-Health Lab, Medical University of Lublin,
Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Aleksandra Jędrzejewska

ORCID <https://orcid.org/0009-0002-8118-1810>

E-mail ola.jedrzejewska@o2.pl

Student Scientific Club at the Department of Medical Informatics and Statistics with e-Health Lab, Medical University of Lublin,
Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Klaudia Kleczaj

ORCID <https://orcid.org/0000-0002-2534-6863>

E-mail klaudia.kleczaj@gmail.com

Student Scientific Club at the Department of Medical Informatics and Statistics with e-Health Lab, Medical University of Lublin,
Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Łukasz Starczewski

ORCID <https://orcid.org/0009-0000-2258-4885>

E-mail lukasz.starczewski7@gmail.com

Medical University of Warsaw, ul. Żwirki i Wigury 61, 02-091 Warszawa, Poland

Julia Jaworowska

ORCID <https://orcid.org/0009-0006-5770-7578>

E-mail j.u.l.a.jaworowska@gmail.com

Student Scientific Club at the Department of Medical Informatics and Statistics with e-Health Lab, Medical University of Lublin,
Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Gabriela Babiarz

ORCID <https://orcid.org/0009-0002-2715-6470>

E-mail gabrielakarolina.babiarz@gmail.com

Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

Julia Kanarszczuk

ORCID <https://orcid.org/0009-0001-7482-2379>

E-mail jkanarszczuk01@gmail.com

Medical University of Lublin, Aleje Raławickie 1, 20-059 Lublin, Poland

ABSTRAKT

Wprowadzenie. Schizofrenia jest przewlekłym, poważnym oraz postępującym zaburzeniem psychicznym, na którego przebieg wpływ mają czynniki genetyczne, epigenetyczne oraz środowiskowe. Objawy pojawiają się zazwyczaj między 16 a 30 rokiem życia, a możemy podzielić je na trzy kategorie: objawy pozytywne, negatywne oraz poznawcze. W ciągu

ostatnich lat wykorzystanie technik sztucznej inteligencji w psychiatrii wzrosło. Istnieją badania, które dowodzą skuteczności m.in. metod deep learning w diagnostyce czy leczeniu chorób psychiatrycznych.

Cel pracy. Podsumowanie aktualnego stanu wiedzy dotyczącego zastosowania sieci neuronowych oraz modeli uczenia maszynowego w diagnostyce, klasyfikacji i spersonalizowanym leczeniu schizofrenii.

Materiały i metody. Przeprowadzono przegląd piśmiennictwa z wykorzystaniem publikacji dostępnych w bazach PubMed oraz Google Scholar z lat 2019-2024. Wybrano najbardziej aktualne i istotne badania na podstawie odpowiednich słów kluczowych.

Wyniki. Techniki sztucznej inteligencji umożliwiają tworzenie modeli diagnostycznych i prognostycznych identyfikujących pacjentów ze schizofrenią na podstawie danych z badań MRI i EEG, a także nagrań audio i wideo oraz informacji genetycznych. Klasyfikacja pacjentów opiera się głównie na analizie EEG i MRI. Jednak zastosowanie uczenia maszynowego w personalizacji leczenia pozostaje ograniczone. Istotnymi wyzwaniami pozostają kwestie etyczne, ochrona danych oraz specyfika relacji lekarz-pacjent w psychiatrii.

Wnioski. Sztuczna inteligencja wykazuje potencjał w diagnostyce, prognozowaniu i leczeniu schizofrenii, jednak jej wdrożenie w codziennej praktyce klinicznej wymaga dalszych badań, udoskonalenia metodologii oraz dokładnego uwzględnienia aspektów etycznych i prawnych.

Słowa kluczowe: schizofrenia, uczenie maszynowe, sieci neuronowe, głębokie uczenie, sztuczna inteligencja, diagnozowanie schizofrenii, leczenie schizofrenii, klasyfikacja schizofrenii

ABSTRACT

Introduction. Schizophrenia is a chronic, severe, and progressive mental disorder whose course is influenced by genetic, epigenetic, and environmental factors. Symptoms typically appear between the ages of 16 and 30 and can be divided into three categories: positive, negative and cognitive symptoms. In recent years, the use of artificial intelligence techniques in psychiatry has increased. Numerous studies demonstrate the effectiveness of methods such as deep learning in the diagnosis and treatment of psychiatric disorders.

Aim of the study. To summarize the current state of knowledge regarding the application of neural networks and machine learning models in the diagnosis, classification and personalized treatment of schizophrenia.

Methods and materials. A literature review was conducted using publications available in the PubMed and Google Scholar databases from 2019-2024. The most relevant and recent studies were selected using appropriate keywords.

Results. Artificial intelligence techniques enable the development of diagnostic and prognostic models identifying patients with schizophrenia based on MRI and EEG data, as well as audio, video recordings and genetic information. Patient classification is mainly based on EEG and MRI analyses. However, the use of machine learning for treatment personalization remains limited. Ethical issues, data protection, and the nature of the physician-patient relationship in psychiatry remain important challenges.

Conclusions. Artificial intelligence shows potential in the diagnosis, prognosis and treatment of schizophrenia, but its implementation in clinical practice requires further research, methodological improvement and careful consideration of ethical and legal aspects.

Keywords: schizophrenia, machine learning, neural networks, deep learning, artificial intelligence, diagnosis of schizophrenia, treatment of schizophrenia, classification of schizophrenia

I. Wprowadzenie

Schizofrenia jest przewlekłym, poważnym oraz postępującym zaburzeniem psychicznym, na którego przebieg wpływ mają czynniki genetyczne, epigenetyczne oraz środowiskowe [11,18,20]. Wiąże się z pogorszeniem jakości życia, zarówno tego społecznego, jak i zawodowego [11,17]. Schizofrenia dotyczy prawie 1% populacji [2]. Częstość występowania wśród kobiet i mężczyzn jest porównywalna [18]. Jest to choroba ludzi młodych [1]. Objawy pojawiają się zazwyczaj między 16 a 30 rokiem życia, a możemy podzielić je na trzy kategorie: objawy pozytywne, negatywne oraz poznawcze [11]. Do objawów najbardziej charakterystycznych dla schizofrenii należą: halucynacje, urojenia, zdezorganizowana mowa, upośledzenie funkcji poznawczych, uwagi i pamięci [10,11]. W celu zwiększenia wskaźnika wyleczeń oraz zapobiegania gwałtownemu postępowi choroby, ważna jest wczesna diagnoza oraz skuteczne interwencje i metody leczenia [10].

W ciągu ostatnich lat wykorzystanie technik sztucznej inteligencji w psychiatrii wzrosło. Z uwagi na trudności w klasyfikacji zaburzeń psychicznych, wiele najnowszych osiągnięć wiąże nadzieje z podejściami opartymi na uczeniu maszynowym. Istnieją badania, które dowodzą skuteczności m.in. metod deep learning w diagnostyce czy leczeniu chorób psychiatrycznych [8]. Wykorzystanie technologii sztucznej inteligencji w medycynie staje się coraz bardziej

popularne, jednak jej rozwój w dziedzinach psychiatrycznych postępuje stosunkowo wolno [10].

II. Cel pracy

Podsumowanie obecnego stanu wiedzy na temat zastosowania sieci neuronowych oraz modeli uczenia maszynowego w diagnostyce, klasyfikacji oraz indywidualnym leczeniu schizofrenii.

III. Metodyka i materiały

Dokonano przeglądu literatury dostępnej w elektronicznych bazach danych PubMed oraz Google Scholar. Przeszukiwania ograniczono do informacji publikowanych w latach 2019-2024. Używano następujących słów kluczowych: machine learning, schizophrenia, neural network, deep learning, artificial intelligence, diagnosis of schizophrenia, treatment of schizophrenia, classification of schizophrenia.

IV. Wyniki

IV a. Podstawy teoretyczne

Obecnie sztuczna inteligencja (AI) wspiera wczesne diagnozowanie schorzeń, pogłębianie wiedzy na temat rozwoju chorób, optymalizację dawkowania leków i terapii oraz poszukiwanie innowacyjnych metod leczenia. Jej kluczową zaletą jest zdolność szybkiej analizy wzorców w ogromnych zbiorach danych [15].

Duża część sztucznej inteligencji bazuje na uczeniu maszynowym (ML). Uczenie maszynowe integruje idee z różnych dziedzin, takich jak informatyka, statystyka, lingwistyka, obejmując wiele specjalistycznych gałęzi, w tym głębokie uczenie (deep learning, DL). Algorytmy ML wykorzystują duże zbiory danych treningowych, aby stworzyć najbardziej efektywny model przewidywania wyników [4]. Jest to analiza algorytmów komputerowych, które samodzielnie doskonalą się poprzez zdobyte doświadczenie oraz wykorzystywanie danych [9].

Algorytmy głębokiego uczenia zdobywają wiedzę bezpośrednio z surowych danych, bez potrzeby ingerencji człowieka, co daje im przewagę w wykrywaniu ukrytych zależności. W tym procesie każdy poziom uczy się przekształcać swoje dane wejściowe w bardziej złożone i abstrakcyjne reprezentacje. Głębokie uczenie automatycznie dostosowuje, które cechy są najbardziej odpowiednie dla poszczególnych warstw. Ze względu na swoje podobieństwo do ludzkiego sposobu myślenia, DL jest często uznawane za bardziej „ludzkie” i mniej mechaniczne niż tradycyjne uczenie maszynowe [9,15].

Sieć neuronowa (NN) jest to grupa połączonych „neuronów” wykorzystująca modele matematyczne lub obliczeniowe do przetwarzania danych. Jest to system adaptujący swoją strukturę na podstawie wewnętrznych i zewnętrznych informacji przepływających przez sieć. Stosowana jest do kształtowania złożonych relacji między danymi wejściowymi i wyjściowymi czy też do znajdowania wzorców w danych [9]. W medycynie wykorzystywane są do analizy oraz integrowania ogromnej ilości danych na temat pacjentów. [5]. Udowodniono, że ich zastosowanie może doprowadzić do powstawania narzędzi diagnostycznych, dzięki którym będzie możliwa identyfikacja jednostek chorobowych, co mogłoby zoptymalizować proces podejmowania ukierunkowanych decyzji medycznych przez lekarza [5,6]. Oprócz analizy i integracji danych, sieci neuronowe stosowane są również w analizie obrazów medycznych, prognozowaniu przebiegu choroby czy diagnostyce [6].

IV b. AI w diagnostyce schizofrenii

Schizofrenię obecnie rozpoznaje się w oparciu o kryteria cech fenotypowych w ramach czasowych [11]. Techniki uczenia maszynowego i ich możliwości przetwarzania dużych ilości danych pozwoliły na powstanie modeli diagnostycznych pomagających dokładniej identyfikować schizofrenię oraz modele prognostyczne, które mogą być pomocne w przewidywaniu przebiegu rozwoju choroby, objawów czy powikłań takich jak samobójstwa [18]. Część badań do identyfikacji pacjentów ze schizofrenią wykorzystują EEG oraz funkcjonalne czy strukturalne MRI (fMRI/sMRI) przy użyciu technik uczenia maszynowego, natomiast inne uwzględniają objawy, funkcje poznawcze i sygnały niewerbalne w celu klasyfikacji pacjentów [12,13].

Sieci neuronowe są coraz częściej stosowane do analizy badań MRI mózgu. Badania dowiodły skuteczności w klasyfikowaniu obrazów MRI chorych ze schizofrenią na poziomie 85%. Inne badanie również z wykorzystaniem sieci neuronowych klasyfikowały badania MRI pacjentów z dokładnością 84,14-84,43% oraz wykazano, że kluczowymi obszarami mózgu były środkowe i dolne płaty skroniowe. Badania oparte na uczeniu maszynowym ze średnią dokładnością wynoszącą 90% odróżniały osoby chore od zdrowych [18]. Czasami istnieją pewne trudności w diagnozowaniu schizofrenii ze względu na podobne objawy występujące np. we wczesnym dzieciństwie w przypadku ADHD czy zaburzeniach ze spektrum autyzmu. Mając ten aspekt na uwadze, przydatne jest posiadanie danych z badań MRI od pacjentów ze schizofrenią w zróżnicowanych przedziałach wiekowych, dzięki czemu modele DL mogą z większą dokładnością diagnozować i pomagać specjalistom [13].

EEG wykorzystywane jest ze względu na swoją większą dostępność, łatwość użycia oraz powtarzalność procedury w porównaniu z badaniem MRI. EEG ma również przewagę pod względem możliwości rejestrowania nagłych zmian aktywności elektrycznej mózgu [14,16]. Techniki uczenia maszynowego mogą zwiększyć precyzję diagnozy schizofrenii na podstawie wyników EEG. W badaniach dokładność diagnozy przy użyciu sieci neuronowych wynosiła między 98,07 a 99,22%. Co więcej, sugerowane jest, że mogą być użyteczne we wczesnym wykrywaniu schizofrenii [18].

Sieci neuronowe mogą również analizować treści w formie audio, co zostało wykorzystane w badaniu, w którym mowa chorych ze schizofrenią została odróżniana od mowy osób zdrowych z dokładnością 97,68%. Ponadto wykorzystywane są również nagrania wideo. Badanie posługujące się nagraniami twarzy po rozmaitych stymulacjach emocjonalnych wykazało 89% dokładności sieci neuronowych w identyfikacji osób ze schizofrenią, dzięki zgromadzonym danym. Uczenie maszynowe może również posługiwać się informacjami genetycznymi do diagnozowania schizofrenii. W jednym z badań sieci neuronowe zostały „nauczone” rozróżniania schizofrenii od choroby afektywnej dwubiegunowej, dzięki wprowadzeniu wzorców genetycznych dla każdej z podanych chorób, opartych na około 70 genach. Prawdopodobieństwo prawidłowego „zakwalifikowania” pacjenta dla schizofrenii wyniosło 95,65%, a dla ChAD - 97,01% [18].

IV c. Klasyfikacja pacjentów

W badaniu mającym na celu sklasyfikowanie pacjentów chorych na schizofrenię (SCZ) i zdrowych pacjentów kontrolnych (HC) oraz pacjentów ze schizofrenią z dominującymi objawami pozytywnymi (PS) i tych z dominującymi objawami negatywnymi (NS) poddano wszystkim badaniu EEG. Analizowane były sygnały EEG z ośmiu obszarów zainteresowania (ROI): prawy i lewy dolny zakręt czołowy (IFG), grzbietowo-boczna kora przedczołowa (DLPFC), dolny płat ciemieniowy (IPL) i górny zakręt skroniowy (STG). Klasyfikacja ta bazuje na uczeniu maszynowym przy wykorzystaniu jednej z najpopularniejszych metod ML zwaną SVM (maszyna wektorów nośnych). W chwili, gdy do modelu wprowadzono oddzielnie istotne cechy specyficzne dla poszczególnych obszarów zainteresowania, wykryte zostało, że cechy związane z aktywnością gamma w prawym IFG są najdokładniejsze (dokładność 78,95%; czułość 84,62%; swoistość 66,67%; AUC 75,64%), następnie w lewym DLPFC (dokładność 73,68%; czułość 91,67%; swoistość 42,86%; AUC 67,26%) i prawym STG (dokładność 73,68%; czułość 100%; swoistość 16,67%; AUC 58,33%). Natomiast w przypadku klasyfikacji grup PS i NS analiza z uwzględnieniem specyfiki regionu wykazała, że cechy związane z

aktywnością delta w lewym IFG okazały się najdokładniejsze (dokładność 89,29%; czułość 88,89%; swoistość 90%; AUC 89,44%), a następnie w prawym IFG (dokładność 82,14%; czułość 83,33%; swoistość 80%; AUC 81,67%). Podsumowując badanie wykazało, że kolejno: prawa IFG, lewa DLPFC, prawa STG najlepiej klasyfikowały SCZ od zdrowych oraz lewy IFG, a następnie prawy IFG były obszarami o najdokładniejszych cechach do klasyfikacji podgrup PS i NS. Wyniki wskazują, że IFG jest ROI kluczowym dla zapewnienia największej dokładności cech w obu przypadkach klasyfikacyjnych. Na podstawie analizowanego badania można wnioskować, że oparta na SVM klasyfikacja i podklasyfikacja pacjentów ze schizofrenią przy użyciu danych EEG jest optymalna i może pomóc w poprawie „ważności” i zmniejszeniu „heterogeniczności” w ich diagnozowaniu [14].

W jednym z badań po włączeniu obrazów otrzymanych podczas funkcjonalnego MRI w stanie spoczynku, przy wykorzystaniu modelu głębokiego uczenia można było klasyfikować pacjentów ze schizofrenią i zdrowych osób kontrolnych z dokładnością 85,5%. Można wnioskować, że głębokie uczenie posiada umiejętność klasyfikowania psychozy u pacjentów z wykorzystaniem danych neuroanatomicznych i neurofunkcjonalnych [8]. W innym badaniu wykorzystującym badanie MRI mózgu oraz techniki AI udowodniono możliwość neuroanatomicznej identyfikacji podtypów schizofrenii z dokładnością 63-71% oraz klasyfikację schizofrenii i zdrowych pacjentów kontrolnych przy zastosowaniu fMRI z dokładnością 87% [15].

W badaniu mającym na celu wyszczególnić pacjentów, u których jest większe ryzyko występowania schizofrenii odpornej na leczenie (TRS), dzięki zastosowaniu metod uczenia maszynowego wysnuto następujące wnioski. Do czynników wysokiego ryzyka wystąpienia TRS należą: wczesny wiek pierwszego kontaktu z psychiatrą, problemy edukacyjne, zaburzenia psychiczne okresu młodzieńczego oraz przerwy w stosowaniu leczenia z powodu nieprzestrzegania zaleceń [17].

IV d. Indywidualne leczenie

Leczenie schizofrenii można podzielić na nefarmakologiczne oraz farmakologiczne. Do nefarmakologicznego leczenia zaliczamy m.in. terapię poznawczo-behawioralną, która pomaga pacjentom osiągać akceptowalny poziom funkcjonowania psychospołecznego. Jednak podstawą terapii pozostaje leczenie farmakologiczne oparte na lekach wpływających na wychwyty zwrotne oraz uwalnianie neuroprzekazników [11]. Leczenie „evidence-based” jest obecnie wiodącym nurtem w medycynie, jednakże nie każda z zaproponowanych terapii odniesie sukces w leczeniu wszystkich pacjentów z daną jednostką chorobową. W niektórych

przypadkach lekarze muszą kierować się „metodą prób i błędów” w poszukiwaniu idealnego leku dla danego pacjenta [19]. Dobór leku powinien brać pod uwagę dotychczasową reakcję pacjenta na dany preparat, możliwe działania niepożądane oraz sposób jego podania [2]. Ze względu na lepsze rokowanie pacjentów rozpoczynających leczenie na początkowym etapie choroby, kluczowe jest wczesne zdiagnozowanie schizofrenii [3].

Badania z wykorzystaniem metod uczenia maszynowego (ML) dowiodły, że 60% pacjentów z pierwszym epizodem schizofrenii po zastosowaniu pierwszego leku przeciwpsychotycznego osiągnęło znaczącą redukcję objawów. U około $\frac{1}{3}$ do $\frac{3}{4}$ pacjentów konieczna była zmiana leku lub przerwanie leczenia w ciągu 12 miesięcy od jego rozpoczęcia. Wiązało się to z niewystarczającą skutecznością lub wystąpieniem działań niepożądanych.

Inne badanie z zastosowaniem ML, mające na celu opracowanie zindywidualizowanych zasad leczenia (ITR) pierwszego epizodu schizofrenii, wykazało następujące wyniki: risperidon, sulpiryd i kwetiapina były najczęściej przepisywanymi lekami przez lekarzy, ale były rzadko zalecane przez ITR dla pacjentów, kolejno 11,1%; 1,1% i 4%. Arypiprazol (31,9%) i amisulpryd (30,2%) były najczęściej zalecanymi przez ITR lekami natomiast były rzadko przepisywane [7].

IV e. Ograniczenia

Nastawienie lekarzy do wykorzystywania technik sztucznej inteligencji w medycynie są w pewnym stopniu pozytywne, jednakże istnieje niepewność co do kwestii prawnych czy etycznych. Nastawienie to różni się również w zależności od wykonywanej specjalizacji [4]. W psychiatrii lekarze są szczególnie zaniepokojeni aspektem etycznym wykorzystania technik AI. Największe obawy dotyczą zagadnień poufności danych, dokładności obliczeń, bezpieczeństwa algorytmów czy ewentualnego pomijania indywidualnych cech pacjenta w stawianiu diagnozy czy proponowaniu leczenia. Mając na uwadze sposób „uczenia się” algorytmów AI może dojść do sytuacji, że są one niekompletne, stronnicze czy złej jakości, co doprowadzi do otrzymywania niewiarygodnych wyników. Wiąże się to z koniecznością kontroli otrzymanych rezultatów klasycznymi metodami diagnostycznymi, aby mieć pewność co do ich trafności [18]. Zastosowanie AI w psychiatrii jest dyskusyjne również z powodu bazowania praktyków tej specjalizacji na bardziej subiektywnym podejściu do pacjenta, bezpośredniej obserwacji jego zachowań czy emocji [15]. Na ten moment nierozstrzygnięte kwestie etyczne zastosowania modeli sztucznej inteligencji ograniczają ich wykorzystywanie w medycynie [18].

Obserwuje się również brak dostępu do dużych baz danych dotyczących historii choroby pacjentów [11]. Małe bazy mogą doprowadzić do nadmiernego generalizowania wyników, co uniemożliwi zastosowanie algorytmów do stosowania ich w innych, niezależnych próbach [21]. Ponadto istnieją badania pokazujące, że znaczna część lekarzy nie ma przeszkolenia w odpowiednim wykorzystywaniu technik AI, co jest kolejnym ograniczeniem wykorzystania ich w pełnym wymiarze [4].

V. Wnioski

Techniki sztucznej inteligencji pozwalają na utworzenie modeli diagnostycznych i prognostycznych. Uczenie maszynowe czy sieci neuronowe z dużą dokładnością rozpoznają chorych ze schizofrenią na podstawie zdjęć MRI czy badania EEG. Do identyfikacji tych chorych analizowane są również nagrania audio, wideo czy informacje genetyczne. Jeśli chodzi o klasyfikację chorych za pomocą technik AI, ponownie zastosowanie wykazały badania EEG oraz MRI. Możliwe było wyznaczenie czynników ryzyka wystąpienia schizofrenii odpornej na leczenie. Możliwość dostosowania indywidualnego leczenia schizofrenii z wykorzystaniem technik AI nie jest jeszcze wystarczająco rozwinięta, ze względu na dużą grupę czynników, którą trzeba brać pod uwagę wybierając odpowiednie leki dla chorego. Uczenie maszynowe może obecnie wspierać wstępny dobór leków, które mogłyby okazać się lepsze na początku leczenia, a które mogą nie być zwykle wybierane w pierwszej kolejności. Obecnie dużą przeszkodą w szerszym zastosowaniu technik sztucznej inteligencji w medycynie jest brak uregulowanych kwestii etycznych ich wykorzystania. W psychiatrii również ze względu na bardziej subiektywne podejście do pacjenta zastosowanie tych metod na ten moment jest ograniczone. Gdy bazy danych wykorzystywane do tworzenia algorytmów będą wystarczająco duże oraz przeszkolenie personelu medycznego w odpowiednim korzystaniu z udogodnień AI ulegnie poprawie, to w przyszłości techniki te mogą stać się dobrym źródłem pomocy w codziennej praktyce lekarzy.

Disclosure

Conceptualization: Aleksandra Jureczko

Methodology: Julia Jaworowska

Software: Damian Osiński

Check: Klaudia Kleczaj

Formal analysis: Zuzanna Kawa

Investigation: Aleksandra Jędrzejewska

Resources: Maria Kasprzak

Data curation: Julia Kanarszczuk

Writing -rough preparation: Gabriela Babiarz

Writing -review and editing: Łukasz Starczewski

Visualization: Aleksandra Jureczko

Supervision: Aleksandra Jureczko

Project administration: Aleksandra Jureczko

Oświadczenia:

Wszyscy autorzy przeczytali i zgodzili się z opublikowaną wersją manuskryptu.

Oświadczenie o finansowaniu:

Badania te nie otrzymały środków zewnętrznych

Oświadczenie instytucjonalnej komisji rewizyjnej:

Nie dotyczy

Oświadczenie o świadomej zgodzie:

Nie dotyczy

Oświadczenie o dostępności danych:

Nie dotyczy

Oświadczenie o konflikcie interesów:

Autorzy zaprzeczają konfliktowi interesów

Deklaracja dotycząca wykorzystania narzędzi sztucznej inteligencji:

Autorzy skorzystali z narzędzia ChatGPT wyłącznie w celu przetłumaczenia, poprawy językowej i stylistycznej tekstu. Po jego użyciu dokonano pełnej weryfikacji, redakcji oraz zatwierdzenia treści. Autorzy ponoszą pełną odpowiedzialność za merytoryczną zawartość publikacji.

Bibliografia. References:

1. Jauhar S, Johnstone M, McKenna PJ. Schizophrenia. *Lancet*. 2022 Jan 29;399(10323):473-486. doi: 10.1016/S0140-6736(21)01730-X. PMID: 35093231.
2. Marder SR, Cannon TD. Schizophrenia. *N Engl J Med*. 2019 Oct 31;381(18):1753-1761. doi: 10.1056/NEJMra1808803. PMID: 31665579.
3. Crawford P, Go KV. Schizophrenia. *Am Fam Physician*. 2022 Oct;106(4):388-396. PMID: 36260895.
4. Monteith S, Glenn T, Geddes J, Whybrow PC, Achtyes E, Bauer M. Expectations for Artificial Intelligence (AI) in Psychiatry. *Curr Psychiatry Rep*. 2022 Nov;24(11):709-721. doi: 10.1007/s11920-022-01378-5. Epub 2022 Oct 10. PMID: 36214931; PMCID: PMC9549456.
5. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to Machine Learning, Neural Networks, and Deep Learning. *Transl Vis Sci Technol*. 2020 Feb 27;9(2):14. doi: 10.1167/tvst.9.2.14. PMID: 32704420; PMCID: PMC7347027.
6. Yuan G, Lv B, Hao C. Application of artificial neural networks in reproductive medicine. *Hum Fertil (Camb)*. 2023 Dec;26(5):1195-1201. doi: 10.1080/14647273.2022.2156301. Epub 2023 Jan 11. PMID: 36628627.
7. Wu CS, Luedtke AR, Sadikova E, Tsai HJ, Liao SC, Liu CC, Gau SS, VanderWeele TJ, Kessler RC. Development and Validation of a Machine Learning Individualized Treatment Rule in First-Episode Schizophrenia. *JAMA Netw Open*. 2020 Feb 5;3(2):e1921660. doi: 10.1001/jamanetworkopen.2019.21660. PMID: 32083693; PMCID: PMC7043195.
8. Pham, Kay T., Amir Nabizadeh, and Salih Sele. "Artificial intelligence and chatbots in psychiatry." *Psychiatric Quarterly* 93.1 (2022): 249-253. <https://doi.org/10.1007/s11126-022-09973-8>
9. Adwitiya Ray, Akansha Bhardwaj, Yogender Kumar Malik, Shipra Singh, Rajiv Gupta, Artificial intelligence and Psychiatry: An overview, *Asian Journal of Psychiatry*, Volume 70, 2022, 103021, ISSN 1876-2018, <https://doi.org/10.1016/j.ajp.2022.103021>.
10. Sun J, Dong QX, Wang SW, Zheng YB, Liu XX, Lu TS, Yuan K, Shi J, Hu B, Lu L, Han Y. Artificial intelligence in psychiatry research, diagnosis, and therapy. *Asian J Psychiatr*. 2023 Sep;87:103705. doi: 10.1016/j.ajp.2023.103705. Epub 2023 Jul 22. PMID: 37506575.
11. Lai JW, Ang CKE, Acharya UR, Cheong KH. Schizophrenia: A Survey of Artificial Intelligence Techniques Applied to Detection and Classification. *Int J Environ Res*

- Public Health. 2021 Jun 5;18(11):6099. doi: 10.3390/ijerph18116099. PMID: 34198829; PMCID: PMC8201065.
12. Góngora Alonso S, Marques G, Agarwal D, De la Torre Díez I, Franco-Martín M. Comparison of Machine Learning Algorithms in the Prediction of Hospitalized Patients with Schizophrenia. *Sensors (Basel)*. 2022 Mar 25;22(7):2517. doi: 10.3390/s22072517. PMID: 35408133; PMCID: PMC9003328.
 13. Sadeghi D, Shoeibi A, Ghassemi N, Moridian P, Khadem A, Alizadehsani R, Teshnehlab M, Gorriz JM, Khozeimeh F, Zhang YD, Nahavandi S, Acharya UR. An overview of artificial intelligence techniques for diagnosis of Schizophrenia based on magnetic resonance imaging modalities: Methods, challenges, and future works. *Comput Biol Med*. 2022 Jul;146:105554. doi: 10.1016/j.compbiomed.2022.105554. Epub 2022 May 10. PMID: 35569333.
 14. Tikka SK, Singh BK, Nizamie SH, Garg S, Mandal S, Thakur K, Singh LK. Artificial intelligence-based classification of schizophrenia: A high density electroencephalographic and support vector machine study. *Indian J Psychiatry*. 2020 May-Jun;62(3):273-282. doi: 10.4103/psychiatry.IndianJPsychiatry_91_20. Epub 2020 May 15. PMID: 32773870; PMCID: PMC7368447.
 15. Graham S, Depp C, Lee EE, Nebeker C, Tu X, Kim HC, Jeste DV. Artificial Intelligence for Mental Health and Mental Illnesses: an Overview. *Curr Psychiatry Rep*. 2019 Nov 7;21(11):116. doi: 10.1007/s11920-019-1094-0. PMID: 31701320; PMCID: PMC7274446.
 16. Sharaev MG, Malashenkova IK, Maslennikova AV, Zakharova NV, Bernstein AV, Burnaev EV, Mamedova GS, Krynskiy SA, Ogurtsov DP, Kondrateva EA, Druzhinina PV, Zubrikhina MO, Arkhipov AY, Strelets VB, Ushakov VL. Diagnosis of Schizophrenia Based on the Data of Various Modalities: Biomarkers and Machine Learning Techniques (Review). *Sovrem Tekhnologii Med*. 2022;14(5):53-75. doi: 10.17691/stm2022.14.5.06. Epub 2022 Sep 29. PMID: 37181835; PMCID: PMC10171060.
 17. Barruel D, Hilbey J, Charlet J, Chaumette B, Krebs MO, Dauriac-Le Masson V. Predicting treatment resistance in schizophrenia patients: Machine learning highlights the role of early pathophysiologic features. *Schizophr Res*. 2024 Aug;270:1-10. doi: 10.1016/j.schres.2024.05.011. Epub 2024 May 31. PMID: 38823319.
 18. Gashkarimov VR, Sultanova RI, Efremov IS, Asadullin AR. Machine learning techniques in diagnostics and prediction of the clinical features of schizophrenia: a

narrative review. *Consort Psychiatr.* 2023 Sep 29;4(3):43-53. doi: 10.17816/CP11030. PMID: 38249535; PMCID: PMC10795943.

19. Kessler RC, Bossarte RM, Luedtke A, Zaslavsky AM, Zubizarreta JR. Machine learning methods for developing precision treatment rules with observational data. *Behav Res Ther.* 2019 Sep;120:103412. doi: 10.1016/j.brat.2019.103412. Epub 2019 May 28. PMID: 31233922; PMCID: PMC7556331.
20. Lisoway AJ, Chen CC, Zai CC, Tiwari AK, Kennedy JL. Toward personalized medicine in schizophrenia: Genetics and epigenetics of antipsychotic treatment. *Schizophr Res.* 2021 Jun;232:112-124. doi: 10.1016/j.schres.2021.05.010. Epub 2021 May 25. PMID: 34049235.
21. Del Fabro L, Bondi E, Serio F, Maggioni E, D'Agostino A, Brambilla P. Machine learning methods to predict outcomes of pharmacological treatment in psychosis. *Transl Psychiatry.* 2023 Mar 2;13(1):75. doi: 10.1038/s41398-023-02371-z. PMID: 36864017; PMCID: PMC9981732.