

JĘDRZEJEWSKA, Aleksandra, KASPRZAK, Maria, JURECZKO, Aleksandra, KLECZAJ, Klaudia, JAWOROWSKA, Julia, LEVADNA, Valentyna, OSIŃSKI, Damian, KAWA, Zuzanna, BABIARZ, Gabriela and KANARSZCZUK, Julia. The use of machine learning methods in the diagnosis of depression - a systematic review. Quality in Sport. 2026;50:68033. eISSN 2450-3118.

<https://doi.org/10.12775/QS.2026.50.68033>

<https://apcz.umk.pl/QS/article/view/68033>

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. Przypisane dyscypliny naukowe: 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: 06.01.2026. Revised: 24.01.2026. Accepted: 24.01.2026. Published: 30.01.2026.

Użycie metod uczenia maszynowego w diagnostyce depresji - przegląd systematyczny

The use of machine learning methods in the diagnosis of depression - a systematic review

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 Racławickie 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 Racławickie 1, 20-059 Lublin, Poland

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 Racławickie 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

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

Valentyna Levadna, ORCID <https://orcid.org/0009-0007-0287-7112>

E-mail valyalevavnaya27@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 Osinski, 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

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

Abstract

Introduction: Nowadays, depression is one of the most common illnesses, affecting over 300 million people worldwide. Over the course of a lifetime, several dozen percent of the adult population of various ages and backgrounds will experience it. Depression is a debilitating disorder characterized by low mood, reduced interests, impaired cognitive functions, and vegetative symptoms such as sleep or appetite disturbances. According to the World Health Organization (WHO), it is the leading cause of disability and has a significant impact on quality of life, both privately and professionally. Its symptoms are heterogeneous and often overlap with other disorders, which means that this illness is not always accurately diagnosed. To assist physicians, in recent years researchers in this field have developed numerous machine learning methods aimed at improving the diagnostic and treatment process of this condition.

Aim of the study: The aim of this study is to summarize the current state of knowledge on the use of machine learning methods in the diagnosis of depression.

Methods and materials: A literature review was conducted using the PubMed database with relevant search terms.

Results: Articles describing studies that applied machine learning methods to predict and identify depression were included in the review. The machine learning models in these studies used data derived from neuroimaging, electronic health records (EHR), and peripheral blood transcriptomes.

Conclusion: Our review suggests that machine learning has great potential in the diagnosis of depression. This area of artificial intelligence offers new ways to analyze data and automate diagnostic processes. In the future, machine learning algorithms may become an integral part of standard psychiatric diagnostics.

Key words: depression, diagnostics, machine learning, artificial intelligence

Abstrakt

Wprowadzenie: W dzisiejszych czasach depresja jest jedną z najczęściej występujących chorób, dotykającą ponad 300 milionów ludzi na świecie. W ciągu całego życia choruje na nią kilkanaście procent populacji osób dorosłych w różnym wieku i z różnych środowisk. Depresja to wyniszczająca choroba charakteryzująca się obniżonym nastrojem, zmniejszonymi zainteresowaniami, upośledzonymi funkcjami poznawczymi i objawami wegetatywnymi, takimi jak zaburzenia snu lub apetytu. Według Światowej Organizacji Zdrowia (WHO), stanowi główną przyczynę niepełnosprawności oraz znacząco wpływa na jakość życia, zarówno w sferze prywatnej, jak i zawodowej. Jej objawy są niejednorodne i często pokrywają się z innymi zaburzeniami, co sprawia, że choroba ta nie zawsze jest trafnie diagnozowana. Aby pomóc lekarzom, w ciągu ostatnich kilku lat badacze w tej dziedzinie opracowali wiele metod uczenia maszynowego, które mają pomóc w poprawie procesu diagnostyki i leczenia tej choroby.

Cel pracy: Celem tej pracy jest podsumowanie aktualnego stanu wiedzy na temat użycia metod uczenia maszynowego w diagnostyce depresji.

Metody i materiały: Dokonano przeglądu literatury dostępnej w bazie PubMed używając kluczowych wyrażeń.

Wyniki: Do przeglądu wybrano artykuły opisujące badania, w których wykorzystano metody uczenia maszynowego w celu przewidywania i identyfikacji depresji. Modele uczenia maszynowego w tych badaniach wykorzystywały dane pochodzące z neuroobrazowania, elektronicznej dokumentacji medycznej (EHR) oraz transkryptomy krwi obwodowej.

Podsumowanie: Nasz przegląd sugeruje, że uczenie maszynowe ma ogromny potencjał w diagnostyce depresji. Ten obszar sztucznej inteligencji oferuje nowe sposoby analizy danych i

automatyzacji procesów diagnostycznych. W przyszłości, algorytmy uczenia maszynowego mogą stać się integralną częścią standardowej diagnostyki psychiatrycznej.

Słowa klucze: depresja, diagnostyka, uczenie maszynowe, sztuczna inteligencja

I. Wprowadzenie

Obecnie depresja jest jedną z najpowszechniejszych i najpoważniejszych chorób psychicznych, której doświadcza ponad 300 milionów ludzi na całym świecie [1]. Około dwa razy częściej dotyka kobiet niż mężczyzn i występuje u jednego na sześciu dorosłych w ciągu ich życia [2]. Jej globalna częstość występowania wzrosła gwałtownie o 48% ze 172 milionów do 258 milionów w latach 1990–2017 [3]. Etiologia depresji jest wieloczynnikowa, a jej dziedziczność szacuje się na około 35%. Ważną rolę odgrywają również czynniki środowiskowe, w tym przemoc seksualna, fizyczna i emocjonalna w dzieciństwie [2]. Znana jest jako jedno z głównych zaburzeń nastroju, charakteryzujące się znaczną i długotrwałą depresją emocjonalną, spowolnionym myśleniem i upośledzeniem funkcji poznawczych [4]. Towarzyszą temu takie objawy jak niepokój i pobudzenie, wyczerpanie i brak energii, poczucie winy lub bezwartościowości [5]. Choroba ta stanowi główną przyczynę niesprawności i niezdolności do pracy na świecie, a także może prowadzić do innych problemów zdrowotnych. Tacy pacjenci obarczeni są większym ryzykiem cukrzycy, otyłości, udaru, chorób układu krążenia, nowotworów czy choroby Alzheimera [2]. Ponadto nieleczona depresja jest głównym czynnikiem przyczyniającym się do samobójstw, dotykającym setki tysięcy przypadków rocznie [6,7]. Dlatego też, tak ważne jest jej wczesne rozpoznanie i wdrożenie odpowiedniego leczenia.

W ciągu ostatnich lat odnotowano nieznaczną poprawę w opiece nad zdrowiem psychicznym w kontekście depresji [8]. Wynika to z faktu, że depresja jest złożoną jednostką kliniczną, której objawy są niejednorodne i często pokrywają się z objawami innych zaburzeń, takich jak choroba afektywna dwubiegunowa, schizofrenia czy choroba Parkinsona. Może to stanowić trudności dla lekarzy w zakresie zarówno dokładnej diagnozy, jak i dobrania odpowiedniego, skutecznego leczenia [6,9]. Obecnie identyfikacja osób z depresją opiera się całkowicie na doświadczeniu klinicysty [6]. Diagnoza stawiana jest w dużej mierze na podstawie samodzielnie opisywanych objawów i wywiadów klinicznych [1]. Złotym standardem jest ustrukturyzowany wywiad psychiatryczny [10], który obejmuje sprawdzone skale depresji,

takie jak Center for Epidemiologic Studies–Depression Scale, Hamilton Rating Scale for Depression-17, Montgomery-Asberg Depression Rating Scale i Beck Depression Inventory [11]. Chociaż jest rutynowo stosowana, metoda ta pozostaje subiektywna dla klinicysty przeprowadzającego wywiad, co może prowadzić do różnic w diagnozie [1]. Ponadto istnieje uprzedzenie społeczne wokół diagnoz depresji, co utrudnia wielu pacjentom bycie szczerymi co do swoich myśli i uczuć podczas wizyt lekarskich [11].

W związku z tym problemem, badane są alternatywne metody obiektywnej diagnozy opartej na biologii, które pozwolą na lepszą identyfikację osób cierpiących na depresję i ugotują drogę do skuteczniejszych interwencji i prawidłowo dobranych strategii leczenia [13,13]. Aby pomóc klinicystom, badacze w tej dziedzinie opracowali wiele metod uczenia maszynowego (ang. machine learning, ML)[6]. Uczenie maszynowe jest poddziedziną sztucznej inteligencji, której celem jest uczenie się nowych elementów wiedzy z dużych ilości danych [14]. W ostatnich latach metody te zyskują na znaczeniu jako narzędzie wspomagające procesy diagnostyczne w medycynie. ML może poprawić wydajność procesu diagnostycznego, gwarantując jednocześnie jego dokładność. Ponadto może dostarczać istotnych klinicznie informacji, które uzupełniają informacje tradycyjnych metod [14].

II. Cel pracy

Celem tej pracy jest podsumowanie aktualnego stanu wiedzy na temat użycia metod uczenia maszynowego w diagnostyce depresji oraz zilustrowanie, w jaki sposób ML może przyczynić się do procesu diagnostycznego w psychiatrii.

III. Metody i materiały

Dokonano przeglądu literatury dostępnej w elektronicznej bazie danych PubMed używając kluczowych wyrażeń. Przeszukiwania ograniczono do informacji opublikowanych między październikiem 2015 r. a październikiem 2024 r. przy użyciu terminów wyszukiwania “depression”, “diagnostics”, “machine learning”, “artificial intelligence” zarówno w izolacji, jak i w połączeniu. Badania zostały uwzględnione, jeśli skupiały się na klasyfikacji osób z depresją i zdrowych osób stanowiących grupę kontrolną (lub innych zaburzeń mózgu) przy użyciu metod uczenia maszynowego.

IV. Wyniki

A. W sytuacjach, w których klasyfikacja DSM (Diagnostic and Statistical Manual of Mental Disorders) jest niejednoznaczna, a subiektywne wrażenie kliniczne może być mylące, potrzebne jest obiektywne ale i też skuteczne narzędzie diagnostyczne wykorzystujące na przykład pomiary obrazowania mózgu [15]. Neuroobrazowanie, w szczególności metodą rezonansu magnetycznego (MRI) wykazało swoją zdolność do nieinwazyjnego badania struktury i funkcji mózgu u pacjentów z depresją, co może posłużyć jako potężne narzędzie do badania różnicujących biomarkerów [9].

Różne cechy mózgu związane z depresją są badane za pomocą różnych modalności MRI. Ogólnie wyróżnia się metody obrazowania strukturalnego i funkcjonalnego. Najczęstsze metody MRI stosowane do badania struktury mózgu obejmują obrazowanie T1-ważone, T2-ważone oraz obrazowanie tensora dyfuzji (DTI). Obrazy T1-ważone wykorzystuje się do badania obszarów korowych. Dzięki wysokiemu kontrastowi między istotą szarą i białą pozwalają na precyzyjniejsze oznaczanie regionów istoty szarej. Obrazowanie to poprzez badanie regionalnych różnic i zmian objętości, umożliwia ocenę nasilenia zaniku w obszarach korowych. Obrazy T2-ważone służą do oceny hiperintensywności istoty białej (WMH), które wiążą się z niedokrwiennymi zmianami w mózgu. Pomiary objętości WMH są istotne w identyfikacji depresji (zwłaszcza depresji późnego wieku), gdyż są powiązane z jej rozwojem lub ryzykiem rozwoju. Natomiast aktywność mózgu, a także łączność funkcjonalna między różnymi obszarami korowymi jest badana za pomocą obrazowania fMRI poprzez wykorzystanie ukrytego przepływu krwi. Tak uzyskane dane anatomiczne i fizjologiczne dają wielowymiarowy obraz struktury i funkcji mózgu. Umożliwia to budowę modeli ML, które rozróżniają osoby z depresją od zdrowych [9]. W latach 2016-2017 przeprowadzonych zostało kilkanaście badań opartych na uczeniu maszynowym, które wykorzystywały obrazowanie metodą rezonansu magnetycznego jako dostęp do gromadzenia danych. Do porównania wybrano tylko te, które skupiały się na odróżnieniu pacjentów z MDD (major depressive disorder) od zdrowej kontroli (HC) [15].

Tabela 1. Podsumowuje różne aspekty 10 wybranych badań.

Referencje	Wielkość próby	Funkcja	Metoda	Walidacja krzyżowa	Dokładność
16	MDD = 58 HC = 65	FC (rsfMRI)	PLS	LOOCV	80.0%
17	MDD = 29 HC = 33 (1st sample); MDD = 46 HC = 57 (2nd sample)	FC (rsfMRI)	SVM	LOOCV	91.9% (1st sample) 86.4% (2nd sample)
18	MDD = 31 HC = 29	FC (rsfMRI)	SVM	LOOCV	95.0%
19	MDD = 25 HC = 25	FA (DTI)	SVM	LOOCV	74.0%
20	MDD = 180 HC = 180	FC (rsfMRI)	SVM	10-fold CV	45.0%~56.1%
21	MDD = 38 HC = 29	FC (rsfMRI)	SVM	LOOCV	76.1%
22	MDD = 333 (4 biotypes) HC = 378	FC (rsfMRI)	SVM	LOOCV	89.2%
23	MDD = 23 HC = 20	GM, WM (sMRI)	SVM	5-fold CV	70.0%
24	MDD = 15 HC = 19	Spatial independent components (rsfMRI)	SVM	5-fold CV	66.0%
25	MDD = 16 HC = 16	Contrast maps (task fMRI)	SVM	LOOCV	75.0%

MDD, major depressive disorder; GM, gray matter; MRI, magnetic resonance imaging; DTI, diffusion tensor images; FC, functional connectivity; WM, white matter; CV, cross-validation; LOOCV, leave-one-out cross-validation; FA, fractional anisotropy; PLS, partial least squares regression; SVM, support vector machines.

Funkcje wykorzystywane w powyższych badaniach koncentrowały się głównie na wykorzystaniu cech fMRI (7 fMRI w stanie spoczynku; 1 fMRI związane z zadaniem). Ogólnie rzecz biorąc, dane gromadzone za pomocą rsfMRI wykazały wyższą dokładność niż inne modalności. Ponadto prawie wszystkie wybrane badania wykorzystywały metodę SVM jako podstawową metodę klasyfikacji i metodę LOOCV do walidacji krzyżowej. SVM jest najpopularniejszym wyborem wśród metod, dzięki niezawodnym podstawom teoretycznym i elastycznej reakcji na dane wielowymiarowe. Duża zmienność jej wydajności może wynikać z różnych rozmiarów próbek. Nie mniej jednak wyniki tych badań wskazują, że uczenie SVM stosowane do danych neuroobrazowania może klasyfikować obecność lub brak MDD. W przypadku walidacji krzyżowej zaletą metody LOOCV jest dostarczanie większej ilości danych do etapu szkolenia metody uczenia się. Podsumowując, w wybranych badaniach podejście łączące spoczynkową łączność funkcjonalną MRI i wieloczynnikową analizę wzorców pozwoliło na pomyślną identyfikację pacjentów z depresją. Należy jednak podkreślić, że zdecydowana większość tych badań obejmowała niewielkie próby, które nie przekładają się na bardziej realistyczną populację. Dlatego też istnieje potrzeba uwzględnienia większych rozmiarów prób w przyszłych badaniach [15].

B. Proces diagnostyczny depresji przeprowadzany przez lekarzy podstawowej lub specjalistycznej opieki zdrowotnej zazwyczaj opiera się na Międzynarodowym Katalogu Chorób Światowej Organizacji Zdrowia w wersji 10 lub 11, ICD-10/11, Podręczniku diagnostycznym i statystycznym zaburzeń psychicznych DSM lub na podstawie scenariusza wywiadu, takiego jak Composite International Diagnostic Interview (CIDI). Pomocne mogą być również standardowe kwestionariusze, takie jak Hospital Anxiety and Depression Scale (HADS), Beck Depression Inventory (BDI) czy Patient Health Questionnaire-9 (PHQ-9) [7, 26]. PHQ-9 jest uważany za złoty standard w badaniach przesiewowych i został potwierdzony na arenie międzynarodowej [26]. W ostatnich latach podjęto wiele prób wspierania wczesnych diagnoz depresji. Badacze skorzystali między innymi z rosnącej dostępności elektronicznej dokumentacji medycznej (EHR) oraz nowych postępów w uczeniu maszynowym (ML). Użycie EHR w krajach rozwiniętych jest dobrze ugruntowane. Na przykład w krajach tj. USA, Wielka Brytania, Australia, Nowa Zelandia i Holandia, wykorzystanie tego systemu w opiece

podstawowej przekroczyło 90%. Warto zauważyć, że połączenie technik uczenia maszynowego z danymi EHR było już stosowane w innych dziedzinach medycyny, co umożliwiło stworzenie m.in. modeli predykcyjnych dla schorzeń sercowo-naczyniowych i cukrzycy [7].

W 2023 roku porównano badania, w których wykorzystano metody uczenia maszynowego do trenowania, walidacji i testowania modeli uczenia maszynowego w celu przewidywania i identyfikacji zaburzeń depresyjnych na podstawie danych EHR. Badania różniły się pod względem wybranej definicji depresji oraz rodzaju i zakresu predyktorów. W części badań zastosowano kombinację definicji opartych na kodach NHS Read, kodach SNOMED (Systematized Nomenclature For Medicine), ocenach opartych na ICD lub DSM i/lub przepisywaniu leków przeciwdepresyjnych (AD). Natomiast w części wykorzystano kwestionariusze, takie jak PHQ-9 lub HADS. W większości badań użyto takich predyktorów jak: płeć, wiek, objawy i inne diagnozy psychiatryczne, choroby współistniejące, historię rodzinną (nadużycia fizyczne/seksualne/substancji), palenie, czynniki społeczne/rodzinne (żałoba, rozwód, samotne rodzicielstwo), nadużywanie alkoholu/substancji. Co więcej, niektóre predyktory zostały zdefiniowane poprzez wstępne przetworzenie notatek klinicznych/innych informacji tekstowych. Kilka badań wykorzystało również pomiary fizjologiczne, na przykład wskaźnik masy ciała (BMI), ciśnienie krwi i cholesterol, jako predyktory niekategoryczne.

Do najpowszechniejszych technik statystycznych, zastosowanych do klasyfikacji depresji, należą modele regresji i Random Forest, XGBoost i SVM. Ogólna wydajność modelu w porównywanych badaniach wynosiła 0,78 przy odchyleniu standardowym 0,07 (wartość AUC-ROC). Jednym z czynników ograniczających wydajność jest definicja samej depresji i użytych predyktorów. Niezbędne jest prawidłowe i dokładne zdefiniowanie depresji, ponieważ ta definicja jest używana do trenowania ML. Ponadto, dane tj. rodzinna historia depresji, alkoholu, narkotyków, przemocy fizycznej i seksualnej oraz współistnienie innych problemów zdrowia psychicznego wydają się być niedostatecznie rejestrowane. Skutkuje to usunięciem istotnych czynników predykcyjnych z powodu niskiej częstości ich występowania [27]. Co więcej, wykorzystywanie recept na leki przeciwdepresyjne jako części definicji może błędnie identyfikować zbyt wiele przypadków [27]. Wynika to z faktu, że leki te są również przepisywane w przypadkach tj. zaburzenia lękowe, przewlekły ból, zaburzenia obsesyjno-kompulsywne czy zespół stresu pourazowego [7].

C. Coraz więcej badań dowodzi, że sygnalizacja molekularna depresji jest powiązana z ekspresją mikroRNA i że dysregulacja tego procesu może inicjować lub zaostrzać patofizjologię depresji. Już w 2012 roku odkryto, że ekspresja kilku mikroRNA w korze przedczołowej osób dotkniętych zaburzeniami depresyjnymi (które popełniły samobójstwo) była znacznie obniżona, w porównaniu z dopasowanymi uczestnikami próby kontrolnej [28]. ML odniosło już sukces w zakresie wykrywania biomarkerów, prognozy i diagnozy chorób w psychiatrii [29]. Np. badania z 2019 wykazały skuteczne wykorzystanie ML w identyfikacji sygnatury mikroRNA w surowicy dla choroby Alzheimera, która może przewidywać stan choroby z dokładnością 85,7% [30]. Biorąc pod uwagę ważną rolę mikroRNA w patofizjologii depresji i skuteczność ML w wykorzystywaniu złożonych danych, w 2020 roku podjęto badania w celu wykazania czy analiza profili mikroRNA we krwi przez ML może służyć jako nowe podejście do odkrywania biomarkerów w MDD. Uczestnicy badania zostali zrekrutowani z kliniki ambulatoryjnej Douglas Mental Health University Institute w Montrealu w Kanadzie i ocenieni przez doświadczonego psychiatrę przy użyciu SCID-I zgodnie z kryteriami DSM-IV. Liczba próbek mikroRNA obejmowała 140 przypadków depresji i 28 zdrowych osób kontrolnych. Całkowita liczba cech mikroRNA wynosiła 285. Do analizy danych przez ML użyto najnowocześniejszego, ale interpretowalnego podejścia regularized gradient boosted machines (implementacja XGBoost, Chen i Guestrin, 2016)[28], jako że algorytm ten sprawdził się już w poprzednim badaniu dotyczącym schizofrenii [31]. Przypadki MDD można było odróżnić od zdrowych osób kontrolnych z AUC wynoszącym 0,97. Wyniki sugerują, że analiza profili mikroRNA we krwi przez ML może stanowić niezawodne podejście do odkrywania biomarkerów depresji i prowadzić do jej szybszej i trafniejszej diagnozy. Wielkość próby w tym badaniu była jednak stosunkowo niewielka, dlatego istnieje potrzeba dalszych badań obejmujących większą liczbę próbek i uwzględniających inne szczegółowe dane kliniczne pacjentów [28].

D. W celu poprawy diagnostyki i zrozumienia etiologii depresji w 2021 roku przeprowadzono badanie, którego głównym celem było stworzenie modelu predykcyjnego do diagnozy tej choroby w oparciu o transkryptomy krwi obwodowej. Zebrano dziewięć zestawów danych ekspresji RNA pacjentów z zaburzeniami depresyjnymi i zdrowych próbek pochodzących z bazy danych Gene Expression Omnibus. Następnie przeprowadzono metaanalizę aby odkryć różnicowo ekspresjonowane geny (DEG) różniące się między osobami chorymi a grupą kontrolną. W ten sposób ujawniono, że sześć DEGs (AKR1C3, ARG1, KLRB1, MAFG, TPST1 i WWC3) może odgrywać ważną rolę w patofizjologii depresji. Następnie zbadano je

pod kątem ich zdolności diagnostycznych. Każdy gen oceniano indywidualnie. Tym sposobem uzyskano AUC wynoszącą odpowiednio $0,63 \pm 0,04$, $0,67 \pm 0,07$, $0,70 \pm 0,11$, $0,64 \pm 0,08$, $0,68 \pm 0,07$ i $0,62 \pm 0,09$. Aby uzyskać lepszą skuteczność diagnostyczną, porównano cztery modele ML (SVM, RF, kNN i NB) z AUC wynoszącym odpowiednio $0,84 \pm 0,09$, $0,81 \pm 0,10$, $0,73 \pm 0,11$ i $0,83 \pm 0,09$. Ze względu na najwyższą średnią AUC wybrano SVM jako model diagnostyczny dla depresji. Ostatecznie badacze uzyskali model diagnostyczny SVM obejmujący 70 genów cech, który był w stanie odróżnić próbki MDD od zdrowych osób kontrolnych i wygenerował AUC wynoszące 0,83. Wyniki pokazały, że moc predykcyjna tego modelu była wyższa niż pojedynczego genu jako wskaźnika klasyfikacji. Badanie to dostarczyło kilku biomarkerów, które mogą być cennym podejściem do diagnozowania zaburzeń depresyjnych w praktyce klinicznej. Ponadto zwraca uwagę na to, w jaki sposób metaanaliza i ML mogą być wykorzystywane do znajdowania względnie obiektywnych markerów transkrypcyjnych dla złożonych chorób psychicznych [13].

V. Podsumowanie

Powyższy przegląd potwierdza potencjalne zastosowanie technik uczenia maszynowego w diagnostyce zaburzeń depresyjnych. Wyniki tego przeglądu wskazują, że wykorzystanie technik uczenia maszynowego i neuroobrazowania, EHR czy transkryptomów krwi obwodowej może zapewnić wydajność porównywalną lub nawet wyższą niż ta, którą można uzyskać w opiece podstawowej. Ponadto takie podejście może znacząco usprawnić proces wykrywania choroby, umożliwić wcześniejsze interwencje oraz poprawić efektywność leczenia, co jest szczególnie istotne w kontekście globalnego wzrostu liczby przypadków depresji. Podsumowując, przyszłe badania powinny koncentrować się na wykorzystywaniu większych prób oraz integracji różnych źródeł danych, aby tworzyć bardziej wszechstronne narzędzia diagnostyczne.

Conceptualization: Aleksandra Jędrzejewska

Methodology: Maria Kasprzak

Software: Zuzanna Kawa

Check: Damian Osiński

Formal analysis: Aleksandra Jureczko

Investigation: Klaudia Kleczaj

Resources: Valentyna Levadna

Data curation: Damian Osiński

Writing - rough preparation: Julia Jaworowska

Writing - review and editing: Gabriela Babiarz

Visualization: Julia Kanarszczuk

Supervision: Aleksandra Jędrzejewska

Project administration: Maria Kasprzak

Wszyscy autorzy przeczytali i zgodzili się z opublikowaną wersją manuskryptu.

Oświadczenie dotyczące finansowania:

Niniejsze badanie nie otrzymało 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. Taylor B, Hobensack M, Niño de Rivera S, Zhao Y, Masterson Creber R, Cato K. Identifying Depression Through Machine Learning Analysis of Omics Data: Scoping Review. *JMIR Nurs*. 2024 Jul 19;7:e54810. doi: 10.2196/54810. PMID: 39028994; PMCID: PMC11297379.
2. Otte C, Gold SM, Penninx BW, Pariante CM, Etkin A, Fava M, Mohr DC, Schatzberg AF. Major depressive disorder. *Nat Rev Dis Primers*. 2016 Sep 15;2:16065. doi: 10.1038/nrdp.2016.65. PMID: 27629598.
3. Liu Q, He H, Yang J, Feng X, Zhao F, Lyu J. Changes in the global burden of depression from 1990 to 2017: Findings from the Global Burden of Disease study. *J Psychiatr Res*. 2020 Jul;126:134-140. doi: 10.1016/j.jpsychires.2019.08.002. Epub 2019 Aug 10. PMID: 31439359.
4. Li X, Zhang X, Zhu J, Mao W, Sun S, Wang Z, Xia C, Hu B. Depression recognition using machine learning methods with different feature generation strategies. *Artif Intell Med*. 2019 Aug;99:101696. doi: 10.1016/j.artmed.2019.07.004. Epub 2019 Jul 17. PMID: 31606115.
5. Khadidos AO, Alyoubi KH, Mahato S, Khadidos AO, Nandan Mohanty S. Machine Learning and Electroencephalogram Signal based Diagnosis of Dipression. *Neurosci Lett*. 2023 Jul 13;809:137313. doi: 10.1016/j.neulet.2023.137313. Epub 2023 May 29. PMID: 37257682.
6. Bhadra S, Kumar CJ. An insight into diagnosis of depression using machine learning techniques: a systematic review. *Curr Med Res Opin*. 2022 May;38(5):749-771. doi: 10.1080/03007995.2022.2038487. Epub 2022 Feb 17. PMID: 35129401.
7. Nickson D, Meyer C, Walasek L, Toro C. Prediction and diagnosis of depression using machine learning with electronic health records data: a systematic review. *BMC Med Inform Decis Mak*. 2023 Nov 27;23(1):271. doi: 10.1186/s12911-023-02341-x. PMID: 38012655; PMCID: PMC10680172.
8. Walther A, Cannistraci CV, Simons K, Durán C, Gerl MJ, Wehrli S, et al. Lipidomics in major depressive disorder. *Front Psychiatry*. Oct 15, 2018;9:459. [FREE Full text] [doi: 10.3389/fpsyt.2018.00459] [Medline: 30374314]

9. Patel MJ, Khalaf A, Aizenstein HJ. Studying depression using imaging and machine learning methods. *Neuroimage Clin.* 2015 Nov 10;10:115-23. doi: 10.1016/j.nicl.2015.11.003. PMID: 26759786; PMCID: PMC4683422.
10. Tomasik J, Han SY, Barton-Owen G, Mirea D, Martin-Key NA, Rustogi N, et al. A machine learning algorithm to differentiate bipolar disorder from major depressive disorder using an online mental health questionnaire and blood biomarker data. *Transl Psychiatry.* Jan 12, 2021;11(1):41. [FREE Full text] [doi: 10.1038/s41398-020-01181-x] [Medline: 33436544]
11. Bhak Y, Jeong HO, Cho YS, Jeon S, Cho J, Gim J, et al. Depression and suicide risk prediction models using blood-derived multi-omics data. *Transl Psychiatry.* Oct 17, 2019;9(1):262. [FREE Full text] [doi: 10.1038/s41398-019-0595-2] [Medline: 31624227]
12. Chao YS, Lin KF, Wu CJ, Wu HC, Hsu HT, Tsao LC, et al. Simulation study to demonstrate biases created by diagnostic criteria of mental illnesses: major depressive episodes, dysthymia, and manic episodes. *BMJ Open.* Nov 10, 2020;10(11):e037022. [FREE Full text] [doi: 10.1136/bmjopen-2020-037022] [Medline: 33172939]
13. Zhao S, Bao Z, Zhao X, Xu M, Li MD, Yang Z. Identification of Diagnostic Markers for Major Depressive Disorder Using Machine Learning Methods. *Front Neurosci.* 2021 Jun 18;15:645998. doi: 10.3389/fnins.2021.645998. PMID: 34220416; PMCID: PMC8249859.
14. Colledani D, Anselmi P, Robusto E. Machine learning-decision tree classifiers in psychiatric assessment: An application to the diagnosis of major depressive disorder. *Psychiatry Res.* 2023 Apr;322:115127. doi: 10.1016/j.psychres.2023.115127. Epub 2023 Feb 22. PMID: 36842398.
15. Gao S, Calhoun VD, Sui J. Machine learning in major depression: From classification to treatment outcome prediction. *CNS Neurosci Ther.* 2018 Nov;24(11):1037-1052. doi: 10.1111/cns.13048. Epub 2018 Aug 23. PMID: 30136381; PMCID: PMC6324186.
16. Yoshida K, Shimizu Y, Yoshimoto J, Takamura M, Okada G, Okamoto Y, Yamawaki S, Doya K. Prediction of clinical depression scores and detection of changes in whole-brain using resting-state functional MRI data with partial least squares regression. *PLoS One.* 2017 Jul 12;12(7):e0179638. doi: 10.1371/journal.pone.0179638. PMID: 28700672; PMCID: PMC5507488.
17. Zhong X, Shi H, Ming Q, Dong D, Zhang X, Zeng LL, Yao S. Whole-brain resting-state functional connectivity identified major depressive disorder: A multivariate pattern

- analysis in two independent samples. *J Affect Disord*. 2017 Aug 15;218:346-352. doi: 10.1016/j.jad.2017.04.040. Epub 2017 Apr 21. PMID: 28499208.
18. Wang X, Ren Y, Zhang W. Depression Disorder Classification of fMRI Data Using Sparse Low-Rank Functional Brain Network and Graph-Based Features. *Comput Math Methods Med*. 2017;2017:3609821. doi: 10.1155/2017/3609821. Epub 2017 Apr 12. PMID: 28487746; PMCID: PMC5405576.
 19. Schnyer DM, Clasen PC, Gonzalez C, Beevers CG. Evaluating the diagnostic utility of applying a machine learning algorithm to diffusion tensor MRI measures in individuals with major depressive disorder. *Psychiatry Res Neuroimaging*. 2017 Jun 30;264:1-9. doi: 10.1016/j.psychresns.2017.03.003. Epub 2017 Mar 23. PMID: 28388468; PMCID: PMC5486995.
 20. Sundermann B, Feder S, Wersching H, Teuber A, Schwindt W, Kugel H, Heindel W, Arolt V, Berger K, Pfeleiderer B. Diagnostic classification of unipolar depression based on resting-state functional connectivity MRI: effects of generalization to a diverse sample. *J Neural Transm (Vienna)*. 2017 May;124(5):589-605. doi: 10.1007/s00702-016-1673-8. Epub 2016 Dec 31. PMID: 28040847.
 21. Bhaumik R, Jenkins LM, Gowins JR, Jacobs RH, Barba A, Bhaumik DK, Langenecker SA. Multivariate pattern analysis strategies in detection of remitted major depressive disorder using resting state functional connectivity. *Neuroimage Clin*. 2016 Mar 2;16:390-398. doi: 10.1016/j.nicl.2016.02.018. PMID: 28861340; PMCID: PMC5570580.
 22. Drysdale AT, Grosenick L, Downar J, Dunlop K, Mansouri F, Meng Y, Fetcho RN, Zebley B, Oathes DJ, Etkin A, Schatzberg AF, Sudheimer K, Keller J, Mayberg HS, Gunning FM, Alexopoulos GS, Fox MD, Pascual-Leone A, Voss HU, Casey BJ, Dubin MJ, Liston C. Resting-state connectivity biomarkers define neurophysiological subtypes of depression. *Nat Med*. 2017 Jan;23(1):28-38. doi: 10.1038/nm.4246. Epub 2016 Dec 5. Erratum in: *Nat Med*. 2017 Feb 7;23(2):264. doi: 10.1038/nm0217-264d. PMID: 27918562; PMCID: PMC5624035.
 23. Sankar A, Zhang T, Gaonkar B, Doshi J, Erus G, Costafreda SG, Marangell L, Davatzikos C, Fu CH. Diagnostic potential of structural neuroimaging for depression from a multi-ethnic community sample. *BJPsych Open*. 2016 Jul 1;2(4):247-254. doi: 10.1192/bjpo.bp.115.002493. PMID: 27703783; PMCID: PMC4995169.
 24. Ramasubbu R, Brown MR, Cortese F, Gaxiola I, Goodyear B, Greenshaw AJ, Dursun SM, Greiner R. Accuracy of automated classification of major depressive disorder as a

- function of symptom severity. *Neuroimage Clin.* 2016 Jul 27;12:320-31. doi: 10.1016/j.nicl.2016.07.012. PMID: 27551669; PMCID: PMC4983635.
25. Yang W, Chen Q, Liu P, Cheng H, Cui Q, Wei D, Zhang Q, Qiu J. Abnormal brain activation during directed forgetting of negative memory in depressed patients. *J Affect Disord.* 2016 Jan 15;190:880-888. doi: 10.1016/j.jad.2015.05.034. PMID: 26639452.
 26. Kroenke K. PHQ-9: global uptake of a depression scale. *World Psychiatry.* 2021 Feb;20(1):135-136. doi: 10.1002/wps.20821. PMID: 33432739; PMCID: PMC7801833.
 27. Nichols L, Ryan R, Connor C, Birchwood M, Marshall T. Derivation of a prediction model for a diagnosis of depression in young adults: a matched case-control study using electronic primary care records. *Early Interv Psychiatry.* 2018 Jun;12(3):444-455. doi: 10.1111/eip.12332. Epub 2016 Mar 30. PMID: 27027490.
 28. Qi B, Fiori LM, Turecki G, Trakadis YJ. Machine Learning Analysis of Blood microRNA Data in Major Depression: A Case-Control Study for Biomarker Discovery. *Int J Neuropsychopharmacol.* 2020 Nov 26;23(8):505-510. doi: 10.1093/ijnp/pyaa029. PMID: 32365192; PMCID: PMC7689198.
 29. Dwyer DB, Falkai P, Koutsouleris N. Machine Learning Approaches for Clinical Psychology and Psychiatry. *Annu Rev Clin Psychol.* 2018 May 7;14:91-118. doi: 10.1146/annurev-clinpsy-032816-045037. Epub 2018 Jan 29. PMID: 29401044.
 30. Zhao X, Kang J, Svetnik V, Warden D, Wilcock G, David Smith A, Savage MJ, Laterza OF. A Machine Learning Approach to Identify a Circulating MicroRNA Signature for Alzheimer Disease. *J Appl Lab Med.* 2020 Jan 1;5(1):15-28. doi: 10.1373/jalm.2019.029595. PMID: 31811079.
 31. Trakadis YJ, Sardaar S, Chen A, Fulginiti V, Krishnan A. Machine learning in schizophrenia genomics, a case-control study using 5,090 exomes. *Am J Med Genet B Neuropsychiatr Genet.* 2019 Mar;180(2):103-112. doi: 10.1002/ajmg.b.32638. Epub 2018 Apr 28. PMID: 29704323.