



NICOLAUS COPERNICUS
UNIVERSITY
IN TORUŃ



Quality in Sport. eISSN 2450-3118.

Journal Home Page

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

KLECZAJ Klaudia, JAWORSKA Julia, OSIŃSKI Damian, KAWA Zuzanna, KASPRZAK Maria, JĘDRZEJEWSKA Aleksandra, JURECZKO Aleksandra, STARCZEWSKI Łukasz, BABIARZ Gabriela, KANARSZCZUK Julia. The Use of Machine Learning as a Diagnostic and Monitoring Tool for Bipolar Disorder. Quality in Sport. 2026;54:70482. eISSN 2450-3118. <https://doi.org/10.12775/QS.2026.54.70482>

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: 01.04.2026. Revised: 04.04.2026. Accepted: 04.04.2026. Published: 13.04.2026.

The Use of Machine Learning as a Diagnostic and Monitoring Tool for Bipolar Disorder

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

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

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

Lukasz 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

Gabriela Babiaryz

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

E-mail gabrielakarolina.babiaryz@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: Bipolar disorder (BD) is a disorder in which patients experience alternating episodes of depression, mania or hypomania, and sometimes mixed episodes. BD is associated with serious comorbidities and a shorter average life expectancy. Both diagnosis and treatment are long-term processes, often requiring prophylaxis for many years. Early diagnosis and rapid intervention may help extend life expectancy through the use of artificial intelligence.

Aim of the study: The aim of this study is to summarize the current state of knowledge regarding the use of machine learning as a tool supporting diagnosis and monitoring the course of bipolar disorder.

Materials and methods: A review of literature available in the PubMed and Google Scholar databases was conducted. The literature used in the article comes from the years 2019–2024. The following keywords were used: bipolar disorder, machine learning, artificial intelligence, diagnosis and treatment of bipolar disorder.

Results: Artificial intelligence plays an important role in the diagnosis and monitoring of patients with BD, supporting differential diagnosis, prediction of relapses, and personalization of treatment. Analyses based on EEG signals and brain imaging suggest that AI may distinguish individuals with BD from healthy individuals, although more consistent research results are needed. AI in psychiatry also faces limitations such as difficulties in accessing large, high-quality datasets and insufficient physician training.

Conclusions: Recent studies demonstrate that artificial intelligence techniques may be effective in the diagnosis and monitoring of bipolar disorder, although machine learning still requires further improvement.

Keywords: bipolar disorder, machine learning, artificial intelligence, diagnosis of bipolar disorder, treatment of bipolar disorder.

Abstrakt

Wprowadzenie: Choroba afektywna dwubiegunowa (ChAD) jest zaburzeniem, w którym pacjenci doświadczają naprzemiennych epizodów depresji, manii lub hipomanii, a czasami także epizodów mieszanych. ChAD wiąże się z poważnymi chorobami współistniejącymi oraz krótszą średnią długością życia. Zarówno diagnostyka, jak i leczenie są procesami długoterminowymi, często wymagającymi wieloletniej profilaktyki. Wczesna diagnoza oraz szybka interwencja mogą pomóc w wydłużeniu średniej długości życia dzięki wykorzystaniu sztucznej inteligencji.

Cel pracy: Celem pracy jest podsumowanie aktualnego stanu wiedzy dotyczącego wykorzystania uczenia maszynowego jako narzędzia wspierającego diagnostykę oraz monitorowanie przebiegu choroby afektywnej dwubiegunowej.

Materiały i metody: Przeprowadzono przegląd literatury dostępnej w bazach danych PubMed oraz Google Scholar. Wykorzystana literatura pochodzi z lat 2019–2024. Zastosowano

następujące słowa kluczowe: bipolar disorder, machine learning, artificial intelligence, diagnosis and treatment of bipolar disorder.

Wyniki: Sztuczna inteligencja odgrywa istotną rolę w diagnostyce oraz monitorowaniu pacjentów z ChAD, wspierając diagnostykę różnicową, przewidywanie nawrotów oraz personalizację leczenia. Analizy oparte na sygnałach EEG oraz obrazowaniu mózgu sugerują, że AI może odróżniać osoby z ChAD od osób zdrowych, jednak potrzebne są bardziej spójne wyniki badań. Zastosowanie AI w psychiatrii napotyka również ograniczenia, takie jak trudności w dostępie do dużych, wysokiej jakości zbiorów danych oraz niewystarczające przeszkolenie lekarzy.

Wnioski: Najnowsze badania wskazują, że techniki sztucznej inteligencji mogą być skuteczne w diagnostyce oraz monitorowaniu choroby afektywnej dwubiegunowej, jednak uczenie maszynowe nadal wymaga dalszego rozwoju.

Słowa kluczowe: choroba afektywna dwubiegunowa, uczenie maszynowe, sztuczna inteligencja, diagnostyka choroby afektywnej dwubiegunowej, leczenie choroby afektywnej dwubiegunowej.

I. Wprowadzenie

Choroba afektywna dwubiegunowa to przewlekłe a także nawracające zaburzenie psychiczne, które charakteryzuje się występowaniem epizodów manii i depresji, także epizodów hipomaniakalnych lub mieszanych [1,19]. ChAD dotyczy około 1% populacji [2]. Patogeneza choroby jest nieznana ale istnieją procesy, które mogą być powiązane z rozwojem choroby, m.in. zaburzenie układu monoaminergicznego w mózgu [3]. Zaburzenie to można podzielić na ChAD typu I oznaczające epizod maniakalny, w którym pacjent jest nadmiernie pobudzony i radosny często nieadekwatnie do sytuacji a nastrój może niespodziewanie zmienić się w drażliwość czy agresję oraz ChAD typu II będący epizodem depresyjnym a także inne rzadsze rodzaje choroby [3]. Istotne jest wczesne rozpoznanie choroby i rozpoczęcie leczenia aby zapewnić lepszą jakość życia pacjentów [4].

Na przestrzeni ostatnich lat psychiatria oprócz tradycyjnych metod diagnostycznych korzysta ze wsparcia sztucznej inteligencji w celu monitorowania pacjenta a także wczesnego wykrycia choroby [5,18]. Klasyfikacja zaburzeń psychicznych nierzadko jest wyzwaniem dla lekarzy

a uczenie maszynowe przyczynia się ułatwienia procesu kategoryzacji [6]. Zastosowania sztucznej inteligencji należy traktować jako narzędzie wspierające praktykę kliniczną [7].

II. Cel pracy: Celem pracy jest podsumowanie obecnego stanu wiedzy na temat możliwości zastosowania uczenia maszynowego jako narzędzia wspomagającego diagnostykę oraz monitorowanie przebiegu choroby afektywnej dwubiegunowej.

III. Materiały i metody: Dokonano przeglądu literatury dostępnej w bazach PudMed oraz Google Scholar. Literatura użyta w artykule pochodzi z lat 2019-2024. Używano następujących słów kluczowych: bipolar disorder, machine learning, artificial intelligence, diagnosis of bipolar disorder, treatment of bipolar disorder

IV. Wyniki

IV a. Podstawy teoretyczne

Sztuczna inteligencja w ciągu ostatnich kilkunastu lat znacząco wspiera tradycyjną praktykę kliniczną [6]. Aplikacje oparte na uczeniu maszynowym (ML) ostatnio przyciągnęły uwagę badaczy medycznych ze względu na ich potencjał we wczesnym wykrywaniu, diagnozowaniu, różnicowaniu diagnostycznym, prognozowaniu oraz leczeniu złożonych chorób w różnych obszarach medycyny [9].

Uczenie maszynowe jest formą analizy danych, która umożliwia tworzenie modeli analitycznych pomagających podejmować decyzję kliniczne dotyczące każdego pacjenta [8,21].

Gałęzią ML jest deep learning. Algorytmy głębokiego uczenia (DL) wyróżniają się w analizie bardzo skomplikowanych danych. Zdolność algorytmów do samodzielnego uczenia się ważnych cech bezpośrednio z surowych danych, czyli automatycznego wyodrębniania istotnych informacji, sprawia, że sieci DNN są bardzo przydatne w medycynie [10]. W medycynie sieci neuronowe służą do analizy i łączenia dużych zbiorów danych o pacjentach, co może wspierać tworzenie narzędzi diagnostycznych pomagających w rozpoznawaniu chorób. Dzięki nim lekarze mogą podejmować bardziej precyzyjne decyzje. Sieci neuronowe są również wykorzystywane do analizy obrazów medycznych [11].

IV b. Sztuczna inteligencja w diagnostyce choroby afektywnej dwubiegunowej

Chorobę afektywną dwubiegunową rozpoznaje się dotychczas na podstawie objawów klinicznych, które są subiektywnie zgłaszane przez pacjenta. Stwarza to ryzyko błędnej diagnozy czy złych wyników leczenia [20]. Algorytmy uczenia maszynowego rozpoznają różne wzorce w zbiorach danych aby na tej podstawie móc prognozować i przewidywać rozwój choroby czy też powikłania. Modele te mogą pomóc zrozumieć skomplikowane przyczyny ChAD [2]. Coraz więcej badań potwierdza obecność zmian neurologicznych w ChAD [12].

Neuroobrazowanie i analizy elektrofizjologiczne, wykazały różnice w budowie i funkcjonowaniu mózgu u osób z ChAD w porównaniu do zdrowych osób. EEG to nieinwazyjna i skuteczna metoda rejestracji aktywności elektrycznej mózgu, która pomaga diagnozować zaburzenia psychiczne, takie jak depresja, ChAD, stany lękowe, schizofrenia i problemy ze snem. W przypadkach tych zaburzeń, zwłaszcza depresji i ChAD, wzrost kortyzolu zakłóca pracę neuronów, co wpływa na działanie mózgu i zmienia wzorce aktywności. Wahania napięcia powstające w wyniku prądu jonowego w neuronach mogą być przydatne w diagnozowaniu tych schorzeń. Na przykład w badaniach EEG zaobserwowano nietypowe zmiany w falach alfa oraz problemy ze wzrokiem i słuchem w stanie spoczynku u pacjentów z ChAD. Z kolei badania neuroobrazowe wykazały nieprawidłową objętość istoty szarej oraz zaburzenia w obszarach czołowych mózgu i układzie limbicznym. W ostatnich latach duże zainteresowanie wzbudziły techniki uczenia maszynowego w automatycznej diagnozie zaburzeń psychicznych, takich jak ChAD, które wykorzystują biomarkery z EEG oraz obrazowania MRI/fMRI [13].

Uczenie maszynowe może wspierać rozróżnienie między ChAD a schizofrenią lub ciężkim zaburzeniem depresyjnym podczas pierwszego epizodu psychozy lub depresji. Metody oparte na uczeniu maszynowym pozwalają także przewidywać efekty leczenia na podstawie wyników badań neuroobrazowych lub elektrofizjologicznych [2].

IV c. Klasyfikacja pacjentów

W jednym z badań użyto EEG w celu zbadania nieprawidłowości u młodzieży z nowo rozpoznaną ChAD podczas ostrych epizodów hipomaniakalnych i depresyjnych a także opracowaną metodę maszynową diagnozy tego zaburzenia. Porównano moc widmową i entropię u 21 nastolatków z ChAD (11 w epizodzie hipomanii i 10 w epizodzie depresji) oraz 18 zdrowych nastolatków. Wyniki pokazały, że nastolatkowie z ChAD mieli wyższą moc

widmową we wszystkich pasmach częstotliwości, szczególnie w obszarach czołowo-centralnych, skroniowych i ciemieniowych po prawej stronie. Entropia widmowa była także wyższa w pasmach delta, alfa i gamma dla ChAD. Wysoka dokładność wynosząca 95,8% została osiągnięta przy analizie różnic w paśmie alfa u młodzieży z ChAD. W stanie depresyjnym zaobserwowano większą moc widmową i entropię w niskich częstotliwościach (delta i theta) w porównaniu z hipomanią. Wnioski sugerują, że objawy ChAD, takie jak nieuwaga, mogą być związane z podwyższoną mocą w paśmie alfa, co wskazuje na dysfunkcję wzgórza. Oscylacje alfa w EEG są głównym źródłem nieprawidłowości w ChAD. Dodatkowo, spowolnienie fal EEG w epizodach depresyjnych wiąże się z zahamowaniem aktywności elektrycznej i pogorszeniem funkcji poznawczych [15].

Inne badania pozwoliły na klasyfikację pacjentów z ChAD i osób zdrowych za pomocą technik uczenia maszynowego oraz MRI. Dokładność klasyfikacji wahała się od 55,9% do 100%. Wykorzystywano różne metody obrazowania, takie jak DTI (obrazowanie tensora dyfuzji), strukturalne i funkcjonalne MRI. Analizy obejmowały zarówno cechy istoty szarej, jak i białej, a w większości badań do klasyfikacji ChAD użyto cech związanych z obiegiem sygnałów w mózgu. W badaniach MRI najczęściej stosowano metodę K-krotnej walidacji krzyżowej, a najpopularniejszym klasyfikatorem była maszyna wektorów nośnych (SVM). Badania strukturalne MRI osiągały dokładność od 55,9% do 88,1%, funkcjonalne MRI w stanie spoczynku miały dokładność od 61,7% do 82,22% a badania funkcjonalne MRI związane z zadaniami osiągały 59,72% i 83,5% dokładności. DTI uzyskało dokładność od 78,12% do 100%. Ponadto, jedno z badań zastosowało głębokie uczenie do klasyfikacji ChAD przy użyciu strukturalnych danych MRI, osiągając bardzo wysoką dokładność – 99,72% [2].

IV d. Ograniczenia

Większość badań EEG i niektóre badania MRI opierają się na małych próbach, co znacząco ogranicza możliwość uogólnienia wyników. Badania wskazują, że małe grupy badanych mogą sztucznie zawyżać dokładność raportowaną w modelach uczenia maszynowego. W wielu pracach nie podano, czy pacjenci z ChAD byli w fazie depresji, manii/hipomanii (typ I lub II) czy w okresie remisji [16]. Wiadomo jednak, że różne epizody ChAD wiążą się z odmiennymi wzorcami nieprawidłowości w mózgu, co może wpływać na wyniki badań oraz ich wiarygodność. Z tego powodu potrzebne są wielośrodkowe badania z większymi grupami pacjentów, prowadzone w kontrolowanych warunkach – najlepiej na osobach z pierwszym epizodem ChAD, które wcześniej nie były leczone, aby uniknąć zakłóceń wynikających

z przebiegu choroby lub stosowania leków. Istotny jest również fakt, że połowa z badań odnosiła się wyłącznie do wskaźnika dokładności a druga połowa zastosowała także wskaźniki czułości i specyficzności. Kolejny aspekt dotyczy tego że większość publikacji w tej dziedzinie koncentruje się na klasyfikacji z podziałem na dwie grupy, jednak w psychiatrii zwykle mamy do czynienia ze znacznie bardziej złożonymi zaburzeniami. Dodatkowo, badania wskazują, że wielu lekarzy nie posiada odpowiedniego przeszkolenia w zakresie korzystania z technik AI, co stanowi kolejną przeszkodę w ich pełnym wykorzystaniu [17]. Wykorzystanie uczenia maszynowego w diagnozowaniu i leczeniu ChAD rodzi wiele etycznych dylematów. Jako że uczenie maszynowe pozostaje obszarem badań, musi być stosowane z uwzględnieniem zasad etyki, ponieważ nie ma jeszcze ustalonych standardów określających, kiedy użycie programów komputerowych jest etycznie dopuszczalne [2] .

V. Wnioski

Sztuczna inteligencja odgrywa znaczącą rolę w diagnostyce i monitorowaniu pacjentów z chorobą afektywną dwubiegunową. Wsparcie w diagnostyce różnicowej, przewidywanie nawrotów, skrócenie czasu diagnozy czy lepsza personalizacja leczenia to znaczące zalety uczenia maszynowego. Uczenie maszynowe oparte na sygnałach EEG i obrazach mózgu pokazuje, że ta metoda może pomóc w rozróżnieniu osób z ChAD od osób zdrowych. Mimo obiecujących wyników badań są one nieco sprzeczne aby móc polegać w większości na tej metodzie diagnozowanie pacjentów. AI w psychiatrii wymaga dużych zbiorów danych do analizy, jednak dostępność i jakość danych bywa ograniczona. To sprawia, że modele AI mogą nie być wystarczająco precyzyjne lub skuteczne w diagnozowaniu lub przewidywaniu przebiegu choroby. Badania pokazują również, że wielu lekarzy nie posiada odpowiedniego szkolenia w zakresie korzystania z technologii sztucznej inteligencji, co ogranicza możliwość jej pełnego wykorzystania w praktyce medycznej. Włączenie uczenia maszynowego do diagnozowania i leczenia ChAD wiąże się też z wieloma dylematami etycznymi. Obecnie brakuje jasno określonych standardów, które definiowałyby, w jakich sytuacjach korzystanie z programów komputerowych jest etycznie uzasadnione i bezpieczne. Sztuczna inteligencja w psychiatrii otwiera nowe możliwości spojrzenia na złożone zaburzenia psychiczne, łącząc technologię z opieką nad pacjentem. Dzięki AI psychiatra zyskuje narzędzie, które może wychwytywać subtelne wzorce w danych i wspierać dokładniejsze diagnozy oraz bardziej dopasowane terapie. Mimo że wyzwala to potencjał szybszej i bardziej spersonalizowanej

opieki, AI w psychiatrii wymaga odpowiedzialnego i etycznego podejścia, by nie zatracić najważniejszego elementu leczenia – relacji człowieka z człowiekiem.

Wkład poszczególnych autorów:

Conceptualization: Klaudia Kleczaj

Methodology: Julia Jaworowska

Software: Zuzanna Kawa

Check: Aleksandra Jureczko

Formal analysis: Damian Osiński

Investigation: Aleksandra Jędrzejewska

Resources: Łukasz Starczewski

Data curation: Damian Osiński

Writing - rough preparation: Maria Kasprzak

Writing - review and editing: Gabriela Babiarcz

Visualization: Julia Kanarszczuk

Supervision: Klaudia Kleczaj

Project administration: Maria Kasprzak

Oświadczenia:

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] Brietzke E, Cerqueira RO, Soares CN, Kapczinski F. Is bipolar disorder associated with premature aging? *Trends Psychiatry Psychother.* 2019 Oct-Dec;41(4):315-317. doi: 10.1590/2237-6089-2019-0038. PMID: 31967192.
- [2] Campos-Ugaz WA, Palacios Garay JP, Rivera-Lozada O, Alarcón Diaz MA, Fuster-Guillén D, Tejada Arana AA. An Overview of Bipolar Disorder Diagnosis Using Machine Learning Approaches: Clinical Opportunities and Challenges. *Iran J Psychiatry.* 2023 Apr;18(2):237-247. doi: 10.18502/ijps.v18i2.12372. PMID: 37383968; PMCID: PMC10293694.
- [3] McIntyre RS, Berk M, Brietzke E, Goldstein BI, López-Jaramillo C, Kessing LV, Malhi GS, Nierenberg AA, Rosenblat JD, Majeed A, Vieta E, Vinberg M, Young AH, Mansur RB. Bipolar disorders. *Lancet.* 2020 Dec 5;396(10265):1841-1856. doi: 10.1016/S0140-6736(20)31544-0. PMID: 33278937.
- [4] Birner A, Mairinger M, Elst C, et al. Machine-based learning of multidimensional data in bipolar disorder – pilot results. *Bipolar Disord.* 2024; 26: 364-375. doi:10.1111/bdi.13426
- [5] Tursini K, Le Cam S, Schwan R, Gross G, Angioi-Duprez K, Conart JB, Remy I, Bernardin F, Laprévotte V, Knobloch E, Ricaud T, Rahnema A, Louis-Dorr V, Schwitzer T. Visual electrophysiology and neuropsychology in bipolar disorders: A review on current state and perspectives. *Neurosci Biobehav Rev.* 2022 Sep;140:104764. doi: 10.1016/j.neubiorev.2022.104764. Epub 2022 Jul 2. PMID: 35792276.
- [6] Nielsen AN, Barch DM, Petersen SE, Schlaggar BL, Greene DJ. Machine Learning With Neuroimaging: Evaluating Its Applications in Psychiatry. *Biol Psychiatry Cogn Neurosci Neuroimaging.* 2020 Aug;5(8):791-798. doi: 10.1016/j.bpsc.2019.11.007. Epub 2019 Nov 27. PMID: 31982357; PMCID: PMC8746222.
- [7] Le Glaz A, Haralambous Y, Kim-DuFor DH, Lenca P, Billot R, Ryan TC, Marsh J, DeVlyder J, Walter M, Berrouiguet S, Lemey C. Machine Learning and Natural Language

- Processing in Mental Health: Systematic Review. *J Med Internet Res*. 2021 May 4;23(5):e15708. doi: 10.2196/15708. PMID: 33944788; PMCID: PMC8132982.
- [8] Rotenberg LS, Borges-Júnior RG, Lafer B, Salvini R, Dias RDS. Exploring machine learning to predict depressive relapses of bipolar disorder patients. *J Affect Disord*. 2021 Dec 1;295:681-687. doi: 10.1016/j.jad.2021.08.127. Epub 2021 Sep 2. PMID: 34509784.
- [9] Amanollahi M, Jameie M, Looha MA, A Basti F, Cattarinussi G, Moghaddam HS, Di Camillo F, Akhondzadeh S, Pigoni A, Sambataro F, Brambilla P, Delvecchio G. Machine learning applied to the prediction of relapse, hospitalization, and suicide in bipolar disorder using neuroimaging and clinical data: A systematic review. *J Affect Disord*. 2024 Sep 15;361:778-797. doi: 10.1016/j.jad.2024.06.061. Epub 2024 Jun 21. PMID: 38908556.
- [10] Durstewitz D, Koppe G, Meyer-Lindenberg A. Deep neural networks in psychiatry. *Mol Psychiatry*. 2019 Nov;24(11):1583-1598. doi: 10.1038/s41380-019-0365-9. Epub 2019 Feb 15. PMID: 30770893.
- [11] Koppe G, Meyer-Lindenberg A, Durstewitz D. Deep learning for small and big data in psychiatry. *Neuropsychopharmacology*. 2021 Jan;46(1):176-190. doi: 10.1038/s41386-020-0767-z. Epub 2020 Jul 15. PMID: 32668442; PMCID: PMC7689428.
- [12] Giridharan, V.V., Sayana, P., Pinjari, O.F. *et al.* Postmortem evidence of brain inflammatory markers in bipolar disorder: a systematic review. *Mol Psychiatry* 25, 94–113 (2020). <https://doi.org/10.1038/s41380-019-0448-7>
- [13] Yasin S, Hussain SA, Aslan S, Raza I, Muzammel M, Othmani A. EEG based Major Depressive disorder and Bipolar disorder detection using Neural Networks:A review. *Comput Methods Programs Biomed*. 2021;202:106007. doi: 10.1016/j.cmpb.2021.106007.
- [14] Lei Y, Belkacem AN, Wang X, Sha S, Wang C, Chen C. A convolutional neural network-based diagnostic method using resting-state electroencephalograph signals for major depressive and bipolar disorders. *Biomed Signal Process Control*. 2022;72:103370.
- [15] Khaleghi A, Mohammadi MR, Moeini M, Zarafshan H, Fadaei Fooladi M. Abnormalities of Alpha Activity in Frontocentral Region of the Brain as a Biomarker to Diagnose Adolescents With Bipolar Disorder. *Clinical EEG and Neuroscience*. 2019;50(5):311-318. doi:10.1177/1550059418824824
- [16] Schwarz E, Doan NT, Pergola G, Westlye LT, Kaufmann T, Wolfers T, Brecheisen R, Quarto T, Ing AJ, Di Carlo P, Gurholt TP, Harms RL, Noirhomme Q, Moberget T, Agartz I, Andreassen OA, Bellani M, Bertolino A, Blasi G, Brambilla P, Buitelaar JK, Cervenka S, Flyckt L, Frangou S, Franke B, Hall J, Heslenfeld DJ, Kirsch P, McIntosh AM, Nöthen MM, Papassotiropoulos A, de Quervain DJ, Rietschel M, Schumann G, Tost H, Witt SH, Zink M,

Meyer-Lindenberg A; IMAGEMEND Consortium, Karolinska Schizophrenia Project (KaSP) Consortium. Reproducible grey matter patterns index a multivariate, global alteration of brain structure in schizophrenia and bipolar disorder. *Transl Psychiatry*. 2019 Jan 17;9(1):12. doi: 10.1038/s41398-018-0225-4. PMID: 30664633; PMCID: PMC6341112.

[17] 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.

[18] Jan Z, Ai-Ansari N, Mousa O, Abd-Alrazaq A, Ahmed A, Alam T, Househ M. The Role of Machine Learning in Diagnosing Bipolar Disorder: Scoping Review. *J Med Internet Res*. 2021 Nov 19;23(11):e29749. doi: 10.2196/29749. PMID: 34806996; PMCID: PMC8663682.

[19] Lane NM, Smith DJ. Bipolar disorder: Diagnosis, treatment and future directions. *J R Coll Physicians Edinb*. 2023 Sep;53(3):192-196. doi: 10.1177/14782715231197577. Epub 2023 Aug 30. PMID: 37649414.

[20] Ikäheimonen A, Luong N, Baryshnikov I, Darst R, Heikkilä R, Holmen J, Martikkala A, Riihimäki K, Saleva O, Isometsä E, Aledavood T. Predicting and Monitoring Symptoms in Patients Diagnosed With Depression Using Smartphone Data: Observational Study. *J Med Internet Res*. 2024 Dec 3;26:e56874. doi: 10.2196/56874. PMID: 39626241; PMCID: PMC11653032.

[21] Claude LA, Houenou J, Duchesnay E, Favre P. Will machine learning applied to neuroimaging in bipolar disorder help the clinician? A critical review and methodological suggestions. *Bipolar Disord*. 2020 Jun;22(4):334-355. doi: 10.1111/bdi.12895. Epub 2020 Mar 20. PMID: 32108409.