



NICOLAUS COPERNICUS
UNIVERSITY
IN TORUŃ

Quality in Sport. 2026;51:68616. eISSN 2450-3118.

<https://doi.org/10.12775/QS.2026.51.68616>



Quality in Sport. eISSN 2450-3118

Journal Home Page

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

JAWOROWSKA, Julia, OSIŃSKI, Damian, KAWA, Zuzanna, KASPRZAK, Maria, JĘDRZEJEWSKA, Aleksandra, JURECZKO, Aleksandra, KLECZAJ, Klaudia, LEVADNA, Valentyna, BABIARZ, Gabriela and KANARSZCZUK, Julia. Machine learning capabilities in headache diagnosis. Quality in Sport. 2026;51:68616. eISSN 2450-3118. <https://doi.org/10.12775/QS.2026.51.68616>

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: 26.01.2026. Revised: 12.02.2026. Accepted: 12.02.2026. Published: 20.02.2026.

Możliwości uczenia maszynowego w diagnostyce bólów głowy

Machine learning capabilities in headache diagnosis

Autorzy:

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 Racławickie 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 Racławickie 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 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 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

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 Racławickie 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 Racławickie 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 Racławickie 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: Bóle głowy możemy podzielić na pierwotne i wtórne. Do pierwotnych należą: migrena, napięciowy ból głowy oraz klasterowy ból głowy - trójdzielno-autonomiczny. Wtórne bóle głowy są objawem innych chorób, często zagrażających życiu, na przykład chorób naczyniowych mózgu. W diagnostyce coraz częściej pomocna lekarzom jest sztuczna inteligencja (AI), która dzięki zastosowaniu uczenia maszynowego jest w stanie samodzielnie rozpoznać, a nawet sklasyfikować bóle głowy.

Cel pracy: Przegląd literatury naukowej i podsumowanie obecnych możliwości uczenia maszynowego w diagnostyce bólów głowy.

Materiały i metody: Dokonano przeglądu literatury dostępnej w bazach PubMed i Google Scholar. Używano następujących słów kluczowych: "Machine learning headache", "Machine learning headache diagnosis", "Artificial intelligence and headache". Wybrane artykuły znajdują się w przedziale czasowym 2020-2025.

Wyniki: Uczenie maszynowe (ML) najczęściej wykorzystywane jest w klasyfikacji bólów głowy z użyciem dokumentacji medycznej pacjenta lub badań obrazowych z dokładnością nawet do 90%. Na podstawie funkcjonalnego rezonansu magnetycznego (fMRI) możliwe jest rozpoznawanie pierwotnych bólów głowy i ich klasyfikowanie. Dodatkowo dzięki AI osoby, które nie specjalizują się w bólach głowy, mogą łatwiej diagnozować i leczyć pacjentów

cierpiących na tę chorobę. AI umożliwia także przewidywanie wystąpienia bólu głowy i odróżnianie bólów pierwotnych głowy od wtórnych.

Wnioski: Rozwój uczenia maszynowego w zakresie diagnostyki bólów głowy wymaga prowadzenia dodatkowych badań i zgromadzenia większej ilości danych oraz ich weryfikacji w praktyce klinicznej.

Słowa kluczowe: ból głowy pierwotny, ból głowy wtórny, uczenie maszynowe, sztuczna inteligencja, funkcjonalny rezonans magnetyczny, migrena, klasyfikacja migreny, klasyfikacja bólów głowy

Abstract

Introduction: Headaches can be divided into primary and secondary types. Primary headaches include migraine, tension-type headache, and cluster headache - trigeminal-autonomic cephalalgia. Secondary headaches are symptoms of other illnesses, often life-threatening, such as cerebrovascular diseases. In diagnosis, artificial intelligence (AI) is increasingly helpful to physicians, as it can independently recognize and even classify headaches using machine learning.

Research objective: Review of scientific literature and summary of current machine learning capabilities in headache diagnosis.

Materials and Methods: A literature review was conducted using PubMed and Google Scholar databases. The following keywords were used: "Machine learning headache", "Machine learning headache diagnosis", "Artificial intelligence and headache". Selected articles are in the time frame of 2020-2025.

Results: Machine learning (ML) is most often used in classifying headaches using a patient's medical records or imaging tests with an accuracy of up to 90%. Based on functional magnetic resonance imaging (fMRI), it is possible to identify primary headaches and classify them. Additionally, thanks to AI, people who do not specialize in headaches can more easily diagnose and treat patients suffering from this disease. AI also enables predicting the occurrence of a headache and distinguishing between primary and secondary headaches.

Conclusions: The development of machine learning in the field of headache diagnosis requires additional research, gathering more data, and verifying it in clinical practice.

Keywords: primary headache, secondary headache, machine learning, artificial intelligence, functional magnetic resonance imaging, migraine, migraine classification, headache classification

Wprowadzenie

Bóle głowy, szczególnie te o charakterze przewlekłym, są jednym z najczęstszych schorzeń neurologicznych, które znacząco obniżają jakość życia pacjentów na całym świecie. Diagnostyka tych dolegliwości, obejmująca różne typy bólów głowy, takie jak migrena, bóle głowy typu napięciowego czy klasterowe bóle głowy, bywa wyzwaniem nawet dla doświadczonych specjalistów. Tradycyjne metody oceny, opierające się na wywiadzie lekarskim i podstawowych technikach obrazowania, często nie są wystarczająco precyzyjne, by umożliwić skuteczne różnicowanie i leczenie. W związku z tym nowoczesne technologie, takie jak uczenie maszynowe, otwierają nowe możliwości diagnostyczne i terapeutyczne.

Uczenie maszynowe, będące częścią sztucznej inteligencji, oferuje zaawansowane narzędzia analizy danych, które mogą znacząco usprawnić proces diagnozowania bólów głowy.

Algorytmy te, poprzez analizę zbiorów danych pochodzących z różnych źródeł, takich jak np. funkcjonalny rezonans magnetyczny (fMRI), elektroencefalografia (EEG), kwestionariusze kliniczne oraz urządzenia noszone na ciele, potrafią rozpoznawać wzorce, które są charakterystyczne dla różnych schorzeń (1-10, 14-17, 20, 21). Umożliwia to automatyczne rozróżnianie różnych typów bólów głowy, przewidywanie wystąpienia ataków migreny oraz lepsze zrozumienie mechanizmów neurofizjologicznych leżących u podstaw tych dolegliwości.

Wyniki

1. Metody obrazowania mózgu w diagnostyce bólów głowy

1.1. Funkcjonalny rezonans magnetyczny (fMRI) – podstawy technologii

fMRI służy do diagnozowania chorób poprzez znajdowanie zmian funkcjonalnych zanim spowodują one patologiczne zmiany wykrywalne tradycyjnymi metodami rezonansu magnetycznego (MRI). Do metod fMRI zaliczamy: obrazowanie dyfuzyjne, obrazowanie tensora dyfuzji, obrazowanie perfuzyjne, spektroskopię rezonansu magnetycznego i techniki lokalizacji funkcji kory mózgowej (głównie wykorzystujące efekty zależne od poziomu tlenu we krwi (BOLD)). Metoda BOLD-fMRI służy do obrazowania metabolizmu i aktywności mózgu, a także zmian w lokalnym krążeniu krwi w mózgu. (11,12)

1.2. Zastosowanie fMRI w diagnostyce pierwotnych bólów głowy

1.2.1. Diagnostyka migreny

W migrenie dochodzi do aktywacji i uwrażliwienia szlaku bólu trójdzielno-naczyniowego. Dowiedziono, że w ciągu 48 godzin przed pojawieniem się bólu głowy dochodzi do aktywacji podwzgórza, dzięki czemu może być to uznane za potencjalny zwiastun wystąpienia migreny. (13)

Z danych fMRI w czasie spoczynku (rs-fMRI) u pacjentów z migreną zostały wyodrębnione następujące cechy: amplituda fluktuacji niskiej częstotliwości, jednorodność regionalna oraz siła regionalnej łączności funkcjonalnej. (14) Następnie zostały one zmapowane na obrazy funkcjonalne i zostało zastosowane podejście głębokiego uczenia oparte na głębokiej sieci

konwolucyjnej (CNN). Na podstawie powyższych danych sieć CNN potrafiła odróżnić pacjentów z migreną od zdrowych pacjentów oraz wyodrębnić dwa podtypy migreny (z aurą i bez aury) z dokładnością ponad 90%. Sieć CNN oparta na Inception osiągnęła najwyższy wskaźnik rozpoznawania wynoszący 99,25% z obszarem pod krzywą (AUC) wynoszącym 0,99 przy rozróżnianiu zdrowych pacjentów i pacjentów z migreną. (1) Dokładność klasyfikacji pacjentów z migreną przy użyciu klasyfikatorów sieci neuronowych (NN) i maszyny wektorów nośnych (SVM) wynosiła odpowiednio 92,86% i 87%. (15)

1.2.2. Diagnostyka bólu głowy typu napięciowego

Zgodnie ze spoczynkową łącznością funkcjonalną (rs-FC) między lewym ciałem migdałowatym a obustronnym ciałem modzelowatym/klinem, AUC, czułość i swoistość w odróżnianiu migreny od bólu głowy typu napięciowego (TTH) wynosiły 0,822, 78,3% i 81,8%; między lewym ciałem migdałowatym a lewym zakrętem Heschla, AUC, czułość i swoistość w odróżnianiu migreny od TTH wynosiły 0,868, 82,6% i 81,8%; między lewym ciałem migdałowatym a prawym zakrętem Heschla, AUC, czułość i swoistość w odróżnianiu migreny od napadowego bólu głowy wyniosły odpowiednio 0,830, 78,3% i 86,4%. (16) Należy jednak podkreślić, że liczba badań oraz wielkość próby była ograniczona. (1)

1.2.3. Diagnostyka klasterowego bólu głowy

Zgromadzono dane kliniczne oraz MRI o charakterze funkcjonalnym i strukturalnym od osób z migreną, klasterowymi bólami głowy oraz zdrowych osób kontrolnych. Zastosowano algorytmy analizujące niezależne składniki oraz SVM do analizy klasyfikacyjnej, co pozwoliło, przy użyciu nadzorowanego uczenia maszynowego i multimodalnego obrazowania, na osiągnięcie 89% dokładności w odróżnianiu osób z migreną od grupy kontrolnej oraz 98% skuteczności w rozróżnianiu klasterowych bólów głowy od grupy kontrolnej. Skuteczność klasyfikacji między pacjentami z migreną a klasterowymi bólami głowy wyniosła 99%, dzięki połączeniu modeli klasyfikacji MRI. Dwustronne sieci funkcjonalne podwzgórza oraz istoty szarej okołowodociągowej (PAG) okazały się kluczowe w klasyfikacji między migrenami a klasterowymi bólami głowy względem grupy kontrolnej. Badanie wykazało, że osoby z klasterowymi bólami głowy, w przeciwieństwie do pacjentów migrenowych, charakteryzowały się obniżoną łącznością funkcjonalną pomiędzy lewym wzgórzem a

obszarami korowymi odpowiadającymi za interocepcję i integrację sensoryczną, co było najistotniejszą cechą różnicującą w fMRI. (17)

Włączenie metod uczenia maszynowego, takich jak SVM i CNN, znacząco poprawia dokładność klasyfikacji, co sugeruje przyszły kierunek badań nad inteligentnymi narzędziami wspierającymi diagnostykę bólów głowy.

2. Różnicowanie specyficznych typów bólów głowy

2.1. Odróżnianie migreny od bólu głowy pourazowego

Ból głowy pourazowy i migrena często objawiają się podobnie. (18,19) Aby ułatwić rozróżnianie tych dwóch jednostek chorobowych, opracowano modele klasyfikacyjne. Użyto do tego danych klinicznych, pomiarów struktury mózgu oraz łączności funkcjonalnej (fc) za pomocą MRI.

W badaniu wzięły udział 34 osoby z migreną i 48 osób z przewlekłym pourazowym bólem głowy spowodowanym łagodnym uszkodzeniem mózgu. Model klasyfikacji oparty na danych z kwestionariusza klinicznego, cechach obrazowania strukturalnego i cechach łączności funkcjonalnej może odróżnić osoby z przewlekłym pourazowym bólem głowy od osób z migreną z dokładnością 87,8%. Dzięki uwzględnieniu danych łączności funkcjonalnej model zwiększył swoją dokładność z 78%. (2) Stworzony model oparty na kombinacji danych klinicznych, strukturalnych oraz funkcjonalnych osiągnął wysoką dokładność, co wskazuje na jego potencjał w odróżnianiu tych dwóch jednostek chorobowych i wspomaganiu decyzji klinicznych. Niezbędne są dalsze badania na większych próbach, aby potwierdzić jego skuteczność i zwiększyć wiarygodność zastosowań klinicznych.

3. Algorytmy uczenia maszynowego w klasyfikacji migreny

Algorytmy uczenia maszynowego są bardzo przydatne w zadaniach, takich jak: klasyfikacja tekstu, rozpoznawanie mowy oraz wiele automatycznych klasyfikacji i przewidywań zaburzeń zdrowotnych. Zbadano, jak różne algorytmy uczenia maszynowego radzą sobie z klasyfikacją migren. Wykorzystano algorytmy takie jak: maszyny wektorów nośnych, K-najbliższych

sąsiadów, lasu losowego, drzewa decyzyjnego oraz głębokiej sieci neuronowej. Modele te były trenowane na publicznie dostępnych danych oraz na rozszerzonych danych. Najwyższą dokładność - 99,66% osiągnął model DNN pracujący na rozszerzonych danych. (4) Podkreśla to potencjał, jaki ma uczenie maszynowe w klasyfikacji migreny.

4. Wsparcie diagnostyczne dla lekarzy niebędących specjalistami

4.1. Rozwój modelu diagnostycznego AI

Przeprowadzono badanie składające się z dwóch faz. W fazie 1 stworzono model diagnostyczny AI oparty na retrospektywnym badaniu 4000 pacjentów, z czego 2800 stanowiły zestawy danych szkoleniowych, a 1200 testowych. Pacjenci byli zdiagnozowani przez czterech specjalistów od bólów głowy. Model stworzono przy użyciu zestawów danych kwestionariusza 2800 pacjentów z wstępnym przetwarzaniem, dostrajaniem hiperparametrów i walidacją krzyżową. Kolejnym krokiem było testowanie jego wydajności przy użyciu zestawu danych testowych 1200 chorych, który nie był przetwarzany w produkcji modelu.

W fazie 2 była sprawdzana skuteczność modelu na podstawie danych 50 nowych pacjentów. Na początku 5 niespecjalizujących się w bólach głowy lekarzy samodzielnie zdiagnozowało bóle głowy u 50 pacjentów, a później ponownie je diagnozowało za pomocą AI. Prawdą podstawową była diagnoza postawiona przez 4 osoby specjalizujące się w zakresie bólów głowy.

4.2. Ocena skuteczności modelu

Kolejnym krokiem była ocena zgodności diagnoz specjalistów i niespecjalistów z pomocą AI oraz bez AI. Wartości kappa interpretowano przy użyciu zaleceń Cohena jako „brak zgodności” dla $kappa \leq 0$, „brak lub niewielka zgodność” dla $kappa = 0,01-0,20$, „dobra zgodność” dla

kappa = 0,21–0,40, „umiarkowana zgodność" dla kappa = 0,41–0,60, „znaczna zgodność" dla kappa = 0,61–0,80 i „prawie idealna zgodność" dla kappa = 0,81–1,00.

Zgodność diagnostyczna przy użyciu współczynnika kappa Cohena między 5 lekarzami niebędącymi specjalistami bez AI wahała się od 0,023 do 0,362, co oznacza niewielką zgodność. Przy użyciu AI wzrosła do 0,606–0,874, co sugeruje znaczną zgodność. Współczynnik kappa między AI a prawdą podstawową specjalistów wynosił 0,815. (5)

4.3. Walidacja zewnętrzna modelu

Wykorzystując prospektywnie zebrane dane od 59 pacjentów, model ten został zewnętrznie zwalidowany. 56 pacjentów cierpiało na migrenę lub bóle głowy spowodowane nadużywaniem leków, a 3 osoby miały bóle głowy typu napięciowego. Nikt nie cierpiał na kłasterowe ani inne bóle głowy. Osiągnięto wysoką wydajność diagnostyczną dla pacjentów z migreną oraz z polekowym bólem głowy. Czulość, swoistość, precyzja i wartości F dla migreny wynosiły odpowiednio 98,21%, 66,67%, 98,21% i 98,21%. Dokładność i kappa dla prawdy podstawowej wynosiły odpowiednio 94,92% i 0,65 (95%CI 0,21–1,00).

2 pacjentów AI zdiagnozowało inaczej niż specjalista od bólu głowy. Model ten ma bardzo podobne możliwości diagnostyczne jak osoby specjalizujące się w bólach głowy, dzięki temu może być przydatnym narzędziem diagnostycznym i może rozwiązać problem niezdiagnozowanych bólów głowy. Przykładowo pacjent za pomocą smartfona mógłby zostać zdiagnozowany przez AI i zorientować się, że cierpi na migrenę, dzięki czemu udałby się do lekarza zamiast próbować samodzielnie nieskutecznie leczyć się środkami przeciwbólowymi. (6)

5. Elektroencefalografia (EEG) w diagnostyce migreny

Przeprowadzono badanie sprawdzające, czy przy użyciu uczenia maszynowego i elektroencefalogramu (EEG) można rozróżnić pacjentów z przewlekłą migreną od zdrowych osób kontrolnych. W badaniu wzięło udział 80 osób: 40 z nich cierpiało na przewlekłą migrenę, a 40 stanowiły zdrowe osoby kontrolne. Rejestrowano wywołaną aktywność EEG podczas niebolesnej, bolesnej i powtarzającej się bolesnej stymulacji elektrycznej.

Wywołane oscylacje somatosensoryczne dominowały w paśmie alfa. U pacjentów z przewlekłą migreną zauważono dłuższą latencję (bezbolesne i powtarzające się bolesne) i zwiększoną moc (bezbolesne i powtarzające się bolesne). U zdrowych osób kontrolnych wystąpiły wzrosty alfa.

Zauważono także, że u zdrowych osób kontrolnych występowało przyzwyczajenie do mocy bodźców bólowych i modulacja częstotliwości. Natomiast u osób z przewlekłą migreną tego nie zaobserwowano. (7) Uwidocznilo to zaburzenia przetwarzania bólu u osób z migreną, na podstawie których modele AI z wysoką skutecznością mogą różnicować pacjentów z przewlekłą migreną od zdrowych osób kontrolnych.

6. Przewidywanie wystąpienia bólu głowy

6.1. Źródła danych predykcyjnych

Chociaż czynniki powodujące bóle głowy od dawna przyciągają uwagę naukowców, w ostatnich latach do ich przewidywania zaczęto stosować modele uczenia maszynowego. Modele te bazują na trzech głównych grupach czynników predykcyjnych: (I) dane raportowane przez pacjentów, obejmujące między innymi czynniki wyzwalające, stan bólu i objawy ostrzegawcze; (II) pomiary fizjologiczne rejestrowane przez urządzenia noszone na ciele; oraz (III) dane zewnętrzne.

6.2. Modele predykcyjne oparte na danych z urządzeń noszonych

Wykazano, że kombinacja danych z dziennika bólów głowy i informacji pochodzących z urządzeń noszonych na ciele pozwala na prognozowanie bólów głowy u osób cierpiących na migrenę. Model predykcyjny został zbudowany na podstawie danych samodzielnie zgłaszanych przez pacjentów, w tym objawów ostrzegawczych oraz pomiarów temperatury skóry, zmienności rytmu serca i napięcia mięśni szyi, które rejestrowano za pomocą urządzenia do biofeedbacku. Najlepszy uzyskany model osiągnął umiarkowaną wartość AUC wynoszącą 0,62. Choć wydajność była niska, pokazuje to realność zastosowania AI do prognozowania, szczególnie że ocena przeprowadzona była na niezależnej grupie testowej.

Dodatkowo, dwa inne badania wykazały możliwość przewidywania ataków migreny na podstawie danych z czujników noszonych na ciele w ujęciu indywidualnym. Oba miały jednak ograniczenia, takie jak niewielka liczba uczestników i brak szerokiej walidacji zewnętrznej. (20,21) W pierwszym z nich wzięło udział siedem osób, osiągając średnią dokładność na

poziomie 84,1% na osobę, ale jedynie 47,4% w przypadku ogólnej dokładności niezależnej od użytkownika. W drugim badaniu wzięły udział 2 osoby, uzyskując wyniki F1 od 0,57 do 0,95 w 47-minutowym oknie czasowym. (3)

6.3. Modele uwzględniające czynniki środowiskowe

Z kolei japońskie badanie połączyło dane z dziennika bólów głowy z informacjami meteorologicznymi, tworząc modele głębokiego uczenia do prognozowania bólów głowy. Model ten, oceniany na niezależnym zbiorze danych obejmującym 2844 użytkowników, osiągnął wartość R^2 na poziomie 0,537. (9)

Inne badanie zostało przeprowadzone na 18 pacjentach z migreną, którzy wpisywali dane do dziennika bólu głowy i samodzielnie przeprowadzali biofeedback. Tworząc model uwzględniono 295 dni. Najlepszy okazał się model lasu losowego, który osiągnął wartość AUC 0,62. (10)

Uczenie maszynowe jest obiecującym narzędziem w przewidywaniu bólów głowy, w tym ataków migrenowych. Modele te potrafią analizować złożone dane, co pozwala na przewidywanie wystąpienia bólu z wyprzedzeniem. Choć uzyskane modele wykazały pewien poziom skuteczności, ich wydajność nie jest jeszcze na tyle wysoka, aby były w pełni niezawodne. To wskazuje na potrzebę dalszych badań i doskonalenia metod predykcji.

7. Różnicowanie bólów głowy pierwotnych i wtórnych

W retrospektywnym badaniu wykorzystano dane z lat 1993–2021 pochodzące od 121 241 pacjentów, którzy zgłaszali się z bólem głowy, aby opracować predykcyjny model oparty na uczeniu maszynowym do rozróżniania bólów głowy pierwotnych i wtórnych. Model predykcyjny ML został zbudowany przy użyciu regresji logistycznej i lasu losowego, analizując dziesięć standardowych parametrów morfologii krwi, 19 wskaźników utworzonych z tych parametrów, a także dane demograficzne i kliniczne pacjentów.

Wydajność modelu była oceniana za pomocą krzyżowo zweryfikowanych metryk. Końcowy model, zbudowany metodą lasu losowego, wykazał umiarkowaną skuteczność (zrównoważona dokładność: 0,7405). Czułość i swoistość wyniosły odpowiednio 58% i 90%, przy wskaźniku fałszywie ujemnych wyników (bóle wtórne błędnie przewidziane jako pierwotne) na poziomie 10% i wskaźniku fałszywie dodatnich wyników (bóle pierwotne błędnie przewidziane jako

wtórne) wynoszącym 42%. (8) Model ten, oparty na uczeniu maszynowym, może być przydatnym, oszczędzającym czas i zasoby narzędziem wspierającym kliniczną ocenę pacjentów zgłaszających się z bólem głowy.

Wnioski

Możliwość wykorzystania uczenia maszynowego w diagnostyce bólów głowy jest obiecująca zarówno dla lekarzy, jak i dla całego systemu medycznego. Analiza danych z fMRI, EEG (7) oraz wsparcie algorytmów sztucznej inteligencji pozwala lekarzom osiągać wyższą dokładność diagnostyczną, szybciej różnicować rodzaje bólów głowy (2,17), a także przewidywać ich występowanie.

Algorytmy CNN i SVM są skuteczne w rozróżnianiu różnych rodzajów bólu głowy (np. migreny, bólu napięciowego i klastrowego) z wysoką dokładnością – nawet do 99%, co może zapobiec błędnym diagnozom i skutkować bardziej precyzyjnym leczeniem. (1,15) Modele oparte na analizie fMRI mogą wyodrębniać podtypy migreny (z aurą lub bez), co umożliwia bardziej indywidualne podejście terapeutyczne. (4)

AI wspomaga również rozróżnianie bólów pierwotnych od wtórnych, co ma ogromne znaczenie w wykluczeniu przypadków zagrażających życiu, a następnie skierowaniu pacjentów na odpowiednią terapię. (8) Modele AI pomagają lekarzom bez specjalistycznej wiedzy osiągnąć wyższą zgodność diagnostyczną, co zostało wykazane przez wzrost współczynnika kappa z 0,023–0,362 do 0,606–0,874 w badaniach. W związku z tym zastosowanie AI może wspierać lekarzy w miejscach, gdzie brakuje specjalistów. (5)

Modele prognozujące, które analizują dane z dzienników pacjentów oraz informacje z urządzeń noszonych, pozwalają przewidywać nadchodzące ataki migreny lub inne bóle głowy, co daje pacjentom czas na wprowadzenie środków zapobiegawczych lub przyjęcie odpowiednich leków. Możliwość przewidywania ataków jest szczególnie cenna dla pacjentów cierpiących na przewlekłą migrenę i może poprawić ich jakość życia. (3)

Jest nadzieja, że sztuczna inteligencja zmniejszy obciążenie lekarzy, skróci czas leczenia pacjentów, a także poprawi jakość postępowania diagnostyczno-leczniczego. Istnieją jednak pewne ograniczenia, ponieważ ilość dostępnych danych jest niewielka, a skuteczność modeli

ML zależy od dużej liczby wysokiej jakości danych. W wielu badaniach próby są niewielkie, co zmniejsza możliwość generalizacji wyników i wiarygodność modelu.

Wysokie wskaźniki dokładności w warunkach eksperymentalnych często nie przekładają się na rzeczywiste warunki kliniczne, co świadczy o potrzebie walidacji klinicznej z udziałem dużych, zróżnicowanych grup pacjentów, aby mogły być bezpiecznie i skutecznie stosowane w praktyce. Ponadto występują również wyzwania natury etycznej i prawnej, bowiem odpowiedzialność za decyzje podejmowane z pomocą ML może być trudna do określenia, zwłaszcza w sytuacjach, gdy algorytm popełni błąd. Wymaga to jasnych regulacji prawnych i standardów odpowiedzialności w medycynie. Te ograniczenia wskazują, że choć ML ma potencjał w diagnostyce bólów głowy, jego wdrożenie wymaga dalszych badań, walidacji i odpowiedniego dostosowania do praktycznych warunków klinicznych.

Oświadczenia

Wkład autorów: 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.

Wkład poszczególnych autorów:

Conceptualization: Julia Jaworowska

Methodology: Damian Osiński

Writing – rough preparations: Gabriela Babiarz, Klaudia Kleczaj, Valentyna Levadna

Writing - review and editing: Zuzanna Kawa, Julia Kanarszczuk

Project administration: Maria Kasprzak, Aleksandra Jędrzejewska, Aleksandra Jureczko

References

1. Li ML, Zhang F, Chen YY, Luo HY, Quan ZW, Wang YF, Huang LT, Wang JH. A state-of-the-art review of functional magnetic resonance imaging technique integrated with advanced statistical modeling and machine learning for primary headache diagnosis. *Front Hum Neurosci*. 2023 Sep 1;17:1256415. doi: 10.3389/fnhum.2023.1256415. PMID: 37746052; PMCID: PMC10513061.
2. Dumkrieger G, Chong CD, Ross K, Berisha V, Schwedt TJ. The value of brain MRI functional connectivity data in a machine learning classifier for distinguishing migraine from persistent post-traumatic headache. *Front Pain Res (Lausanne)*. 2023 Jan 9;3:1012831. doi: 10.3389/fpain.2022.1012831. PMID: 36700144; PMCID: PMC9869115.
3. Stubberud A, Langseth H, Nachev P, Matharu MS, Tronvik E. Artificial intelligence and headache. *Cephalalgia*. 2024 Aug;44(8):3331024241268290. doi: 10.1177/03331024241268290. PMID: 39099427.
4. Khan L, Shahreen M, Qazi A, Jamil Ahmed Shah S, Hussain S, Chang HT. Migraine headache (MH) classification using machine learning methods with data augmentation. *Sci Rep*. 2024 Mar 2;14(1):5180. doi: 10.1038/s41598-024-55874-0. PMID: 38431729; PMCID: PMC10908834.
5. Katsuki M, Shimazu T, Kikui S, Danno D, Miyahara J, Takeshima R, Takeshima E, Shimazu Y, Nakashima T, Matsuo M, Takeshima T. Developing an artificial intelligence-based headache diagnostic model and its utility for non-specialists' diagnostic accuracy. *Cephalalgia*. 2023 May;43(5):3331024231156925. doi: 10.1177/03331024231156925. PMID: 37072919.
6. Okada M, Katsuki M, Shimazu T, Takeshima T, Mitsufuji T, Ito Y, Ohbayashi K, Imai N, Miyahara J, Matsumori Y, Nakazato Y, Fujita K, Hoshino E, Yamamoto T. Preliminary External Validation Results of the Artificial Intelligence-Based Headache Diagnostic Model: A Multicenter Prospective Observational Study. *Life (Basel)*. 2024 Jun 11;14(6):744. doi: 10.3390/life14060744. PMID: 38929727; PMCID: PMC11204521.
7. Hsiao FJ, Chen WT, Wang YF, Chen SP, Lai KL, Coppola G, Wang SJ. Identification of patients with chronic migraine by using sensory-evoked oscillations from the

electroencephalogram classifier. *Cephalalgia*. 2023 May;43(5):3331024231176074. doi: 10.1177/03331024231176074. PMID: 37194198.

8. Yang F, Meng T, Torben-Nielsen B, Magnus C, Liu C, Dejean E. A machine learning approach to support triaging of primary versus secondary headache patients using complete blood count. *PLoS One*. 2023 Mar 6;18(3):e0282237. doi: 10.1371/journal.pone.0282237. PMID: 36877693; PMCID: PMC9987784.

9. Katsuki M, Tatsumoto M, Kimoto K, Iiyama T, Tajima M, Munakata T, Miyamoto T, Shimazu T. Investigating the effects of weather on headache occurrence using a smartphone application and artificial intelligence: A retrospective observational cross-sectional study. *Headache*. 2023 May;63(5):585-600. doi: 10.1111/head.14482. Epub 2023 Feb 28. PMID: 36853848.

10. Stubberud A, Ingvaldsen SH, Brenner E, Winnberg I, Olsen A, Gravidahl GB, Matharu MS, Nachev P, Tronvik E. Forecasting migraine with machine learning based on mobile phone diary and wearable data. *Cephalalgia*. 2023 May;43(5):3331024231169244. doi: 10.1177/03331024231169244. PMID: 37096352.

11. Ogawa S, Lee TM, Kay AR, Tank DW. Brain magnetic resonance imaging with contrast dependent on blood oxygenation. *Proc Natl Acad Sci U S A*. 1990 Dec;87(24):9868-72. doi: 10.1073/pnas.87.24.9868. PMID: 2124706; PMCID: PMC55275.

12. Sun H, He Y, Cao H. Functional magnetic resonance imaging research in China. *CNS Neurosci Ther*. 2021 Nov;27(11):1259-1267. doi: 10.1111/cns.13725. Epub 2021 Sep 7. PMID: 34492160; PMCID: PMC8504522.

13. Schulte LH, Mehnert J, May A. Longitudinal Neuroimaging over 30 Days: Temporal Characteristics of Migraine. *Ann Neurol*. 2020 Apr;87(4):646-651. doi: 10.1002/ana.25697. Epub 2020 Feb 18. PMID: 32031707.

14. Yang H, Zhang J, Liu Q, Wang Y. Multimodal MRI-based classification of migraine: using deep learning convolutional neural network. *Biomed Eng Online*. 2018 Oct 11;17(1):138. doi: 10.1186/s12938-018-0587-0. PMID: 30314437; PMCID: PMC6186044.

15. Jorge-Hernandez F, Garcia Chimeno Y, Garcia-Zapirain B, Cabrera Zubizarreta A, Gomez Beldarrain MA, Fernandez-Ruanova B. Graph theory for feature extraction and

classification: a migraine pathology case study. *Biomed Mater Eng.* 2014;24(6):2979-86. doi: 10.3233/BME-141118. PMID: 25227005.

16. Wang Y, Wang Y, Bu L, Wang S, Xie X, Lin F, Xiao Z. Functional Connectivity Features of Resting-State Functional Magnetic Resonance Imaging May Distinguish Migraine From Tension-Type Headache. *Front Neurosci.* 2022 Apr 26;16:851111. doi: 10.3389/fnins.2022.851111. PMID: 35557602; PMCID: PMC9087040.

17. Messina R, Sudre CH, Wei DY, Filippi M, Ourselin S, Goadsby PJ. Biomarkers of Migraine and Cluster Headache: Differences and Similarities. *Ann Neurol.* 2023 Apr;93(4):729-742. doi: 10.1002/ana.26583. Epub 2023 Jan 4. PMID: 36565271.

18. Erickson JC. Treatment outcomes of chronic post-traumatic headaches after mild head trauma in US soldiers: an observational study. *Headache.* 2011 Jun;51(6):932-44. doi: 10.1111/j.1526-4610.2011.01909.x. Epub 2011 May 17. PMID: 21592097.

19. Theeler B, Lucas S, Riechers RG 2nd, Ruff RL. Post-traumatic headaches in civilians and military personnel: a comparative, clinical review. *Headache.* 2013 Jun;53(6):881-900. doi: 10.1111/head.12123. PMID: 23721236.

20. Siirtola P, Koskimäki H, Mönttinen H, Röning J. Using Sleep Time Data from Wearable Sensors for Early Detection of Migraine Attacks. *Sensors (Basel).* 2018 Apr 28;18(5):1374. doi: 10.3390/s18051374. PMID: 29710791; PMCID: PMC5981434.

21. Pagán J, De Orbe MI, Gago A, Sobrado M, Risco-Martín JL, Mora JV, Moya JM, Ayala JL. Robust and Accurate Modeling Approaches for Migraine Per-Patient Prediction from Ambulatory Data. *Sensors* 2015, 15, 15419-15442. doi: 10.3390/s150715419