

Zastosowanie sztucznej inteligencji w diagnostyce otoneurologicznej – przegląd wybranych publikacji

Application of artificial intelligence in the otoneurology diagnostic process – an overview

Anna Krupa^{1,A-F}, Magdalena Sosna-Duranowska^{2,3,A-F},
Miłosz Borkowski^{4,D-F}, Natalia Czajka^{1,E-G}, Piotr H. Skarżyński^{1,5,6,E-G}

¹ Instytut Fizjologii i Patologii Słuchu, Światowe Centrum Słuchu, Zakład Teleaudiologii i Badań Przesiewowych, Warszawa/Kajetany

² Instytut Fizjologii i Patologii Słuchu, Zakład Otoneurologii, Warszawa/Kajetany

³ Instytut Fizjologii i Patologii Słuchu, Klinika Oto-Ryno-Laryngochirurgii, Warszawa/Kajetany

⁴ Uniwersytet Warszawski, Wydział Biologii, Warszawa

⁵ Warszawski Uniwersytet Medyczny, II Wydział Lekarski, Zakład Niewydolności Serca i Rehabilitacji Kardiologicznej, Warszawa

⁶ Instytut Narządów Zmysłów, Kajetany

Wkład autorów:

- A Projekt badania
- B Gromadzenie danych
- C Analiza danych
- D Interpretacja danych
- E Przygotowanie pracy
- F Przegląd literatury
- G Gromadzenie funduszy

Streszczenie

Wprowadzenie: Nowoczesne technologie, tj. sztuczna inteligencja (AI), w niezwykłym tempie stają się elementem wspomagającym opiniowanie w zakresie diagnostyki dysfunkcji błędnika. Według naukowców sztuczna inteligencja szybko analizuje obszerne dane dzięki zastosowaniu algorytmów, a w rezultacie wyniki są szczegółowe i precyzyjne.

Materiał i metody: W przeglądzie zawierają się wybrane publikacje z lat 2015–2021 dostępne w bazach: PubMed, Science Direct oraz Web of Science, dotyczące zastosowania uczenia maszynowego w diagnostyce częstych zaburzeń narządu przedsionkowego.

Wnioski: Z klinicznego punktu widzenia ze względu na liczne czynniki, które wpływają na odczucie zawrotów głowy i zaburzenia postawy, wprowadzenie sztucznej inteligencji do samodzielnej oceny funkcji narządu przedsionkowego nie jest jeszcze możliwe. W niniejszej pracy wskazuje się na potrzebę analizowania obiektywnych badań diagnostycznych zarówno przez uczenie maszynowe, jak i lekarza, co łącznie staje się istotnym elementem w pracy klinicznej.

Słowa kluczowe: narząd przedsionkowy • zawroty głowy • sztuczna inteligencja • uczenie maszynowe • badania diagnostyczne

Abstract

Introduction: Modern technologies, i.e. artificial intelligence (AI), are rapidly becoming an element supporting the assessment of the diagnosis of vestibular dysfunction. According to the researchers, artificial intelligence quickly analyzes large amounts of data through algorithms making the conclusions detailed and precise.

Material and methods: The selected review includes groundbreaking publications from a database such as PubMed, Science Direct and Web of Science in 2015–2021, related to the use of machine learning in the diagnostic process of the most popular vestibular disorders.

Conclusions: From a clinical point of view, due to numerous factors that influence the feeling of dizziness and maintaining posture, it is not yet possible to apply artificial intelligence to the self-assessment of vestibular functions. The study indicates that the results of objective diagnostic tests analyzed by machine learning and the ENT may become an important element of clinical practice.

Key words: vestibular • vertigo • artificial intelligence • machine learning • diagnostic procedure

Adres autora: Anna Krupa, Zakład Teleaudiologii i Badań Przesiewowych, Światowe Centrum Słuchu, Instytut Fizjologii i Patologii Słuchu, ul. Mokra 17, Kajetany, 05-830 Nadarzyn, e-mail: a.krupa@ifps.org.pl

Wykaz skrótów

Skrót	Rozwinięcie skrótu	Odpowiednik w języku polskim
ABC Scale	<i>Activities-Specific Balance Confidence Scale</i>	–
AI	artificial intelligence	sztuczna inteligencja
BPPV	benign paroxysmal positional vertigo	łagodne napadowe położeniowe zawroty głowy
CI	cochlear implant	implant ślimakowy
DHI	<i>Dizziness Handicap Inventory</i>	–
EEV	<i>European Evaluation of Vertigo (scale)</i>	–
ENG	electronystagmography	elektronystagmografia
ML	machine learning	uczenie maszynowe
SVV	subjective visual vertical	subiektywna wizualizacja pionowa
VADL	<i>Vestibular Disorders Activities of Daily Living Scale</i>	–
VEMP	vestibular evoked myogenic potential	przedsionkowe miogenne potencjały wywołane
VNG	videonystagmography	wideonystagmografia

Wprowadzenie

Postawa ciała zależy od wielu bodźców sensorycznych i jest zapewniona przez spójność analizy informacji pochodzących z receptorów czucia głębokiego, narządu wzroku, mięśni, centralnego i obwodowego narządu przedsionkowego (błędnika) oraz licznych połączeń centralnego układu nerwowego. Zaburzenie percepcji sygnałów powoduje poczucie niestabilności lub wywołuje zawroty głowy [1].

Według najnowszych danych epidemiologicznych zawroty głowy i zaburzenia równowagi dotyczą 15–20% populacji dorosłych [2]. Przyczyna zaburzeń może być zlokalizowana w obwodowym narządzie przedsionkowym, który jest częścią ucha wewnętrznego, lub części ośrodkowej narządu przedsionkowego (jądra przedsionkowe, ośrodki korowe mózgu), narządzie wzroku lub w receptorach czucia głębokiego [1,2].

Dysfunkcje w obrębie narządu przedsionkowego mogą pojawiać się na skutek fizjologicznego starzenia się organizmu i przemian metabolicznych, przyjmowanych leków lub z przyczyn autoimmunologicznych, chorób metabolicznych, sercowo-naczyniowych, neurodegeneracyjnych oraz patologii błędnika [1]. Niezamierzona ingerencja chirurgiczna w obrębie narządu przedsionkowego, tj. stapedotomia, wszczępienie implantu ślimakowego (CI) w przypadku częściowej lub całkowitej głuchoty czuciowo-nerwowej, może również mieć wpływ na zachowanie czynności błędnika [3,4].

Otoneurologia skupia się na diagnostyce i leczeniu zawrotów głowy przy wykorzystaniu subiektywnych i obiektywnych badań diagnostycznych angażujących błędnik, narząd wzroku oraz postawę ciała [1]. Doniesienia naukowe z ostatnich lat wskazują na dynamiczny rozwój wiedzy z zakresu diagnostyki błędnika wykonywanej z zastosowaniem sztucznej inteligencji (ang. *artificial intelligence*, AI) – systemu, który działa na podstawie uczenia maszynowego

(ang. *machine learning*, ML) prowadzącego do zautomatyzowania procesów dedukcji [5]. Obecnie w medycynie korzysta się z systemów ekspertowych, które na podstawie bazy wiedzy i modułu wyjaśniającego umożliwiają wnioskowanie – rozpoznanie konkretnej jednostki chorobowej [6].

Ogólnie mówiąc, uczenie maszynowe przebiega wieloetapowo, poczynając od zbierania danych i ich przygotowania, poprzez skalowanie (metodą normalizacji, standaryzacji) lub uporządkowanie kolejności, po uzyskanie spójnej bazy danych. Przygotowane zbiory mogą być elementem treningu algorytmu (czyli wstępnej weryfikacji poprawności danych) lub mogą być bezpośrednio podporządkowane istniejącemu modelowi uczenia maszynowego. Rezultatem działania modelu jest predykcja wystąpienia jakiejś cechy lub zjawiska [5].

Cel pracy

Celem pracy jest przedstawienie najważniejszych osiągnięć zastosowania AI w badaniach klinicznych dotyczących narządu przedsionkowego.

Materiał i metody

Niniejsza praca zawiera przegląd anglojęzycznych publikacji dostępnych w bazach: PubMed, Scopus i Web of Science, datowanych od 2015 do 2021 r., obejmujących zastosowanie AI i ML w diagnostyce dysfunkcji narządu przedsionkowego z wykorzystaniem badań stosowanych w codziennej praktyce klinicznej. Do selekcji artykułów w bazach zastosowano następujące słowa kluczowe: zawroty głowy, zaburzenia równowagi, zaburzenia przedsionkowe, sztuczna inteligencja i uczenie maszynowe. Z badania wyłączono: prezentacje konferencyjne, artykuły publikowane przed rokiem 2015, badania na zwierzętach, badania eksperymentalne, przeglądy literatury oraz badania oparte na etiologii pozapredsiionkowej. Do niniejszego przeglądu ostatecznie włączono 15 publikacji (tabela 1).

Tabela 1. Schemat procesu selekcji publikacji do przeglądu piśmiennictwa
Table 1. The scheme of selection of publications used in the literature review

Selekcja publikacji	Dane liczbowe
Ogólna liczba artykułów dostępnych w bazach: PubMed, Scopus, Web of Science	383
Artykuły wykluczone z przeglądu literatury ¹	166
Artykuły rozpatrywane pod kątem analizy ²	217
Artykuły odrzucone	202
Publikacje wybrane do przeglądu	15
Podział badań ³ :	
kwestionariusz (DHI)	1
próba kaloryczna	2
fotel obrotowy	1
SVV	2
MRI	7
SOT	1
VEMP	1
sekwencjonowanie microRNA	1
język kliniczny	1

¹ Zastosowano kryterium wyłączenia, tj. badania na zwierzętach, przeglądy literatury, badania na oparte na diagnostyce pozaprzedsionkowej, oraz usunięto duplikujące się publikacje.

² Zastosowano kryterium czasu publikacji artykułów oraz kryteria włączenia i wyłączenia z badania opisane w metodach.

³ W pracach naukowych Priesol i in. (2015) oraz Visscher i in. (2020) porównywano różnorodne badania instrumentalne, m.in. próby kaloryczne, próba fotela obrotowego oraz VNG, VEMP, SOT.

Wyniki i dyskusja

Wstępna diagnoza otoneurologiczna

W procesie diagnostyki zawrotów głowy klinicysta posługuje się unikalnym wzorcem językowym, który precyzyjnie opisuje dolegliwości: rodzaj, częstotliwość, czas trwania zawrotów głowy, nasilenie oraz zauważalne bodźce wywołujące lub intensyfikujące opisane dolegliwości [1,7]. Dodatkowo stosowane są kwestionariusze dotyczące klasyfikacji objawów, np. *Vertigo Symptom Scale* (VSS) i *European Evaluation of Vertigo* (EEV), lub wpływu choroby na jakość życia pacjenta, np. *Dizziness Handicap Inventory* (DHI), *Activities-Specific Balance Confidence Scale* (ABC), *Vestibular Disorders Activities of Daily Living Scale* (VADL). Celem pytań kwestionariuszowych jest przypisanie dolegliwości do jednostki chorobowej i dalsza weryfikacja na podstawie badań diagnostycznych [8]. W tym zakresie AI pozwala na pogrupowanie objawów i przypisanie ich do często występujących jednostek chorobowych, tj. łagodne położeniowe zawroty głowy (BPPV), zawroty głowy pochodzenia centralnego, psychogenne zawroty głowy, zapalenie nerwu przedsionkowego lub migrena przedsionkowa [1]. Analiza objawów przedsionkowych i właściwe ukierunkowanie na określone zaburzenia znacznie wspomaga decyzje kliniczne oraz ułatwia diagnostykę w warunkach ambulatoryjnych [8].

Ponadto zastosowanie walidacji krzyżowej w przypadku diagnozowania więcej niż jednej jednostki chorobowej znacznie poprawia moc predykcyjną. W celu zwiększenia dokładności w praktyce klinicznej można stworzyć bardziej

kompleksowy model, który będzie uwzględniał trzy symptomy i więcej jako wskaźniki konkretnego zaburzenia równowagi [7]. Posłużenie się algorytmem w procesie wstępnej diagnozowania zaburzenia oszczędza czas konsultacji, algorytm wskazuje także obiektywne badania, na które należy skierować pacjenta celem dalszej ewaluacji.

Z badania Masankaran i in. (2018) wynika, że istnieje potrzeba ścisłej współpracy specjalistów z zakresu medycyny oraz zastosowania uczenia maszynowego, aby właściwie dobrać narzędzia kliniczne do rozpoznania zaburzeń przedsionkowych [9]. W jednej z prac zastosowano kwestionariusz DHI do oceny dysfunkcyjnych kanałów półkolistych u pacjentów z BPPV [9]. Kwestionariuszem DHI bada się uciążliwość zawrotów głowy w podskalach: emocjonalnej, fizycznej oraz funkcjonalnej, lecz nie można zweryfikować klinicznie strony uszkodzenia, ani zmian patofizjologicznych w kanale półkolistym [8]. Podsumowując, każda metoda ML jest nieprzydatna, jeśli naukowcy nie mają podstawowej wiedzy o zastosowaniu narzędzi klinicznych.

Umiejętność postawienia właściwej diagnozy otolaryngologicznej wymaga połączenia: doświadczenia pochodzącego z wielu lat praktyki klinicznej, umiejętności precyzyjnej interpretacji wyników badań i określenia stadium zaburzenia. Kobotyzacja – wspólne działanie specjalisty i sztucznej inteligencji – niewątpliwie przynosi korzyści zarówno dla pacjenta, jak i dla personelu medycznego ze względu na uzyskanie szybkiej i trafnej oceny zmysłu równowagi. Wstępna diagnoza pozwala podjąć pierwsze decyzje odnośnie leczenia, stanowi zatem o rozpoczęciu zdrowienia pacjenta i ma wpływ na poprawę jakości życia [8].

Analiza badań diagnostycznych

W diagnostyce otoneurologicznej wykonuje się m.in. badania elektrofizjologiczne, korzystając z urządzeń stymulujących lub hamujących narząd przedsionkowy. W związku z budową anatomiczną oraz fizjologią obwodowego narządu przedsionkowego wymagane są różnorodne bodźce stymulujące, aby możliwe było pobudzenie określonych receptorów w części narządów otolitowych lub kanałów półkolistych [1]. Podczas badań stosuje się takie bodźce jak: harmoniczne sinusoidalne akceleracje, przyspieszenia kątowe, bodźce kaloryczne rejestrowane przez elektronystagmografię (ENG) lub wideonystagmografię (VNG), bodźce wizualne, dźwięki o wysokim poziomie natężenia inicjujące ruch endolimfy, wywoływanie konfliktów sensorycznych, test prędkości kroku (ang. *velocity step test*), test stabilizacji wzrokowej. Skomputeryzowane wyniki testów są przedstawiane głównie w formie grafów, tabel oraz wykresów, w których definiuje się rozpiętość zakresu normy na podstawie licznych analiz i naukowych opracowań [10].

Mimo stosowania zaawansowanych narzędzi klinicznych wyniki badań wciąż są interpretowane przez lekarza. Jednak prowadzone badania naukowe dowodzą, że uczenie maszynowe analizuje wyniki badań, m.in. prób kalorycznych oraz próby fotela obrotowego, korzystając z ich matematycznych wartości, klasyfikując wyniki na jedno- lub obustronne z zachowaną normą lub przekroczeniem jej wartości [1].

Uczenie maszynowe można wykorzystać jako narzędzie do podsumowania najważniejszych parametrów, co ułatwia interpretację ogólnych wyników. Z uwagi na długie oczekiwanie na interpretację wyników przez specjalistę to działanie na pewno się skraca czas konsultacji oraz w trafny sposób przedstawia stan rzeczywisty. Algorytm ML uwzględni dużo większą liczbę parametrów, wykraczając pod względem analizy poza zakres ludzkich możliwości czasowych i analitycznych, a w związku z tym rozszerza zakres dokładności obliczeń realizowanych w niedługim czasie.

Biorąc pod uwagę przyszłość badań diagnostycznych w otoneurologii, już jesteśmy w stanie sprawdzić trafność większości ze stosowanych dotychczas testów i opracowane normy, ponieważ to, co wcześniej badał człowiek i uznał za właściwe, uczenie maszynowe obecnie może dokładnie zweryfikować. W dzisiejszych czasach badania, które osiągają wysoką specyficzność i czułość, określa się złotym standardem i rekomenduje w diagnostyce celem wykrywania zmian patofizjologicznych [1].

W celu wykrycia jednostronnego uszkodzenia części przedsionkowej układu równowagi zaleca się wykonanie prób kalorycznych z rejestracją ENG/VNG. Jednak już w 2015 r. badania z zastosowaniem AI sprawdziły wartość testu fotela obrotowego w porównaniu z wykonywanym dotychczas standardowym testem w diagnostyce pacjentów z zaburzeniem obwodowym [11]. W badaniach tych wyniki testu fotela obrotowego osiągnęły lepszą niż VNG czułość oraz swoistość, co stało się przedmiotem licznych dyskusji na temat poprawności zastosowanego modelu uczenia maszynowego ze względu na sprzeczność

przytoczonych wyników z dotychczasową wiedzą diagnostyczną [11]. W kolejnych latach nie podjęto dalszych badań w tej kwestii.

Po analizie z zastosowaniem uczenia maszynowego można otrzymać szereg informacji zawierających dodatkowe czynniki, których człowiek do tej pory nie był w stanie uwzględnić lub skorelować. W efekcie nowy zakres złotego standardu może zmienić oblicze otoneurologii. Z uwagi na liczne przypadki ponownych wizyt oraz złożoność przypadków warto zaproponować kobotyzację w celu ewaluacji aktualnych wyników z uwzględnieniem innych czynników medycznych, które analizuje specjalista, m.in. przyjmowane leki (ototoksyczne), zaburzenia innych układów, obraz rezonansu magnetycznego (ang. *magnetic resonance imaging*, MRI), jakość życia pacjenta. Wybranie takiego procesu ułatwia całą procedurę kliniczną z zachowaniem bezpieczeństwa zdrowia pacjenta.

Nieprawidłowa percepcja i analiza otaczających nas bodźców sensorycznych, zmian przyspieszania liniowego, kąтового, jakim poddane jest nasze ciało, może objawiać się niestabilnością posturalną oraz odczuciem zawrotów głowy. W zaawansowanych klinikach otoneurologicznych są już dostępne narzędzia bazujące na wirtualnej rzeczywistości, jak np. subiektywna wizualizacja pionowa (ang. *subjective visual vertical*, SVV), która w rutynowym panelu diagnostycznym służy do weryfikacji: choroby Ménière'a, łagodnych położeniowych zawrotów głowy (BPPV) oraz zapalenia błędniaka. Diagnostyka może wkraczać w kompetencje neurologów i badanie to zalecane jest pacjentom diagnozowanym w kierunku stwardnienia rozsianego lub hipotonii ortostatycznej. SVV jest szybkim, nieinwazyjnym badaniem, w którym pacjent udziela odpowiedzi, naciskając przycisk, tak aby widzianą w okularach strzałkę ustawić w pozycji wertykalnej, podczas gdy ciało pacjenta najpierw jest ustawione w pozycji pionowej, a następnie przechylane na boki o 30° i 45°.

Badania przeprowadzone przez Chiarovano i wsp. (2018) dowiodły, że istnieje bardzo wysoka korelacja między stroną odchylenia w SVV a chorym uchem u pacjentów z chorobą Ménière'a. Ponadto rozpoczęto prace nad sposobem dokładnej oceny SVV w warunkach klinicznych oraz wszędzie tam, gdzie możliwe jest zastosowanie aplikacji telefonicznej; wstępne wyniki okazały się zgodne z przewidywaniami – stwierdzono wysoki poziom zgodności. Te osiągnięcia potwierdzają możliwość zastosowania SVV jako szybkiego i dokładnego badania diagnostycznego [12].

Oprócz tego u pacjentów w ostrym stadium objawowym obwodowych i centralnych zaburzeń równowagi w badaniach nad SVV zastosowano uczenie maszynowe, aby porównać ocenę symptomów z klasycznym przebiegiem diagnostycznym [13]. Wyniki tych badań wykazały, że nielinowe metody uczenia maszynowego przypisują właściwe wagi dla poszczególnych objawów klinicznych, dzięki czemu możliwości różnicowania zaburzeń obwodowych lub centralnych są bardziej skuteczne niż proponowane w standardowej ocenie otoneurologicznej [13,14].

Opisane badanie, mimo że jest jednym z najnowszych odkryć technicznych w dziedzinie otoneurologii, można

wdrożyć do codziennej praktyki poza oddziałami otoneurologicznymi – wszędzie tam, gdzie znajdują się pacjenci wymagający szybkiej weryfikacji zaburzeń obwodowych i ośrodkowych związanych z zaburzeniami postawy i wywołujących zawroty głowy.

Analiza obrazowania biomedycznego

W praktyce klinicznej często konieczne jest zastosowanie obrazowania biomedycznego do weryfikacji zmian patofizjologicznych w obrębie błędnika oraz ośrodkowego układu nerwowego. Otoneurolog kieruje na badanie MRI pacjentów z podejrzeniem choroby Ménière'a (wodniaka błędnika) zlokalizowanej w uchu wewnętrznym celem wykluczenia guzów kąta mostowo-mózdkowego lub przy podejrzeniu zmian strukturalnych w centralnym układzie nerwowym, a dalsze patologie są diagnozowane przez neurologa [1].

Wodniak błędnika charakteryzuje się specyficznymi objawami, takimi jak: zawroty głowy, uczucie pełności i szum w uchu oraz znaczne pogorszenie słyszenia, które pojawiają się nagle i znacznie obniżają jakość życia. Metody instrumentalne tylko częściowo oceniają funkcje narządu przedsionkowego i w początkowej fazie choroby są niespecyficzne, ponieważ upośledzenie czynnościowe układu przedsionkowego jest niskie [15].

Choroba cechuje się charakterystycznym obrazem MRI – wydłużeniem woreczka (wzrost powyżej 1,5–1,6 mm), niewidoczność przewodu i woreczka endolimfatycznego lub zmniejszona ilość płynu w wodociągu ślimaka. Badanie MRI z kontrastem okazało się istotne w diagnostyce choroby Ménière'a, ponieważ wprowadzony dożylnie kontrast dyfunduje do perylimfy, a nie endolimfy, dzięki czemu można zaobserwować zmiany patofizjologiczne w postaci: powiększonego woreczka względem łagiewki, powiększonej przestrzeni endolimfatycznej i zajęcia minimum 33% przedsionka lub zwiększenia przemieszczenia błony Reissnera [16–18].

Wykraczając poza zakres wstępnej diagnostyki, obrazowanie biomedyczne ma istotną wartość w klasyfikacji stopnia zaawansowania choroby oraz weryfikuje możliwości dalszego leczenia farmakologicznego lub operacyjnego, dlatego precyzja wykonania oraz analizy badań w znacznym stopniu przekłada się na jakość życia pacjenta.

Cho i wsp. (2020) zastosowali AI w celu diagnostyki choroby Ménière'a w obrazowaniu MRI ucha wewnętrznego z dożylnym kontrastem na bazie gadolinium. W dalszym etapie porównywano stosunek wielkości worka endolimfatycznego do pozostałych struktur błędnika. Jak dotąd wartości zmian objętości były weryfikowane przez radiologa, a następnie uporządkowane przez otoneurologa w podskalach, aby ocenić stopień zaawansowania choroby i ustalić dalsze postępowanie farmakologiczne lub chirurgiczne. W przeprowadzonym eksperymencie wyniki badań zostały przeanalizowane przez radiologa, neuroradiologa oraz model INHEARIT. Wyniki okazały się wysoce spójne, a współczynnik korelacji wewnątrzklasowej wynosił 0,971. Zautomatyzowane pomiary współczynnika przerosu worka endolimfatycznego wykazują się wysoką celnością. Ponadto, ze względu na coraz większe wykorzystanie

badania MRI z kontrastem w praktyce medycznej, z kontrastem, mogą być dodatkową wartością w kolejnych badaniach klinicznych [19].

AI jest stosowana z dużym powodzeniem w radiologii, a poza badaniem objętości worka endolimfatycznego za pomocą tej metody można określić wielkość guza nerwu przedsionkowo-ślimakowego, który ma charakter pierwotny i niezłośliwy [1].

W ostatnich latach dynamicznie rozwijała się wiedza z zakresu obliczania objętości guza nerwu przedsionkowo-słuchowego. Shapey i wsp. (2019) zaproponowali metodę wykrywania małych guzów polegającą na obliczaniu ich objętości przez konwekcyjne sieci neuronowe na podstawie zdjęć ceT1 oraz htT2. Wyniki analizy były zgodne z obserwacjami naukowców i stanowiło to pierwszy krok do zastosowania automatyzacji analizy obrazu [20].

Badania kontynuowali George-Jones i wsp. (2020). Dowiedli, że istnieje możliwość wykrywania innych guzów postawy czaszki za pomocą analizy obrazów z rezonansów różnego typu przy osiągnięciu wysokiej czułości i specyficzności. Jak wskazuje praca naukowa George-Jones i wsp., wprowadzanie AI do badań diagnostycznych zaburzeń przedsionkowych wiąże się z pewnymi ograniczeniami [21]. Jednym z nich jest uczenie maszynowe oparte na treningu z naukowcem. W efekcie maszyna nie osiągnie lepszych wyników od badacza, nawet przy najlepszej wydolności, jednak zapewni wysoką efektywność na podstawie dotychczas wypracowanych umiejętności.

W tym samym roku Lee i wsp. (2021) zaproponowali kompleksową metodę segmentacji opartą na głębokim uczeniu się z wykorzystaniem wieloparametrycznych obrazów rezonansu magnetycznego. Zaprezentowany algorytm umożliwi nie tylko automatyzację analizy, w której dokładność modelu AI przekroczyła 99% przy pomiarze objętości guza, lecz także opisanie kierunku progresji, regresji lub pseudoregresji guza po radioterapii [22].

Wyniki badań z ostatnich lat są spójne w przypadku określania korelacji między zmianą objętości i charakterystyką obrazów [20–22]. Biorąc pod uwagę aspekt kliniczny, wielkość guza stanowi o zaawansowaniu choroby i nasileniu objawów, a więc jest to decydujący aspekt przed podjęciem leczenia chirurgicznego. Ponadto opracowano system ML do przewidywania u pacjentów z nerwiakiem wyników zachowania słyszenia, których średnia dokładność wynosi 62–90% w zależności od przyjętej metody [23]. Efekty podjętego leczenia będą zweryfikowane przez analizę badań przy użyciu AI, na podstawie której można przewidzieć odpowiedź na leczenie (regresja, pseudoregresja) [22].

MicroRNA i uczenie maszynowe

MikroRNA (miRNA) to drobne sekwencje RNA biorące udział w regulacji ekspresji genów. Działanie tej frakcji niekodującego RNA polega na hamowaniu translacji mRNA, co odgrywa znaczącą rolę w patogenezie licznych schorzeń. W ostatnich latach podjęto próby wykorzystania miRNA jako biomarkerów do wykrywania konkretnych zmian patofizjologicznych. Zapoczątkowane

w 2019 r. badania nad znalezieniem przyczyny otosklerozy opierały się na wyodrębnieniu miRNA z perylimfy (płyn wypełniający przestrzeń między ścianą błędnika kostnego i ścianą błędnika błoniastego) jako aktywnego materiału zaangażowanego w przebieg choroby [24]. Wyniki badań pokazały wysoką identyfikację genów wykazujących zróżnicowany poziom ekspresji u osób z otosklerozą i wskazały dalszą potrzebę próbkowania przychłonki w celu określenia ścieżek regulacji, które są związane ze wzrostem ekspresji miRNA w przebiegu różnych chorób audiologicznych [24].

Najnowsze badania przeprowadzone przez Shew i wsp. (2021) w celu identyfikacji choroby Ménière'a były skoncentrowane nie tylko na ocenie audiologicznej i obrazie MRI, lecz także na próbie znalezienia przyczyny choroby na poziomie molekularnym [25]. W związku z tym posłużono się najnowszą technologią profilowania ekspresji mikroRNA przychłonki, pobranej podczas operacji i służącej jako odpowiednik „płynnej biopsji” [25]. Z płynu wyizolowano totalne RNA, a następnie wyodrębniono miRNA, aby zbadać jego ekspresję [25]. Profile zostały porównane w 3 grupach: 1) pacjentów z chorobą Ménière'a, 2) pacjentów z otosklerozą przebiegającą głównie z niedosłuchem przewodzeniowym, 3) pacjentów z czuciowo-nerwową utratą słuchu zakwalifikowanych do wszczepienia implantu ślimakowego (CI) [25].

Do oceny wyników badania zastosowano nowatorską metodę analizy profilu ekspresji miRNA, tzw. uczenie maszynowe, które zawierało 4 rodzaje modeli klasyfikacji. W rezultacie 2 rodzaje zaburzeń – niedosłuch przewodzeniowy spowodowany otosklerozą i choroba Ménière'a – były zidentyfikowane ze 100-procentową dokładnością przez wszystkie modele ML [25]. Modele dotyczące wodniaka błędnika wykazały unikalne cechy¹ w porównaniu do modeli dotyczących otosklerozy, co świadczy o tym, że istnieje możliwość zbudowania modeli predykcyjnych także dla choroby Ménière'a [25]. Porównanie modeli dotyczących wodniaka błędnika i modeli dotyczących utraty słuchu czuciowo-nerwowej prezentuje się nieco gorzej i wyniki obydwu prób nie przekroczyły wartości 66%, co może wynikać z faktu, że podczas choroby błędnika dochodzi również do tego typu niedosłuchu [25].

Niemniej prace nad miRNA z wykorzystaniem ML powinny być kontynuowane ze względu na potencjalne wykorzystanie tej frakcji RNA jako biomarkera licznych chorób. Związane jest to m.in. z możliwością znalezienia

etiologii choroby, jej wczesnego rozpoznania i wdrożenia interwencji.

Wnioski

Przed podjęciem badań z zastosowaniem AI w klinice otoneurologii należy przeprowadzić konsultacje ze specjalistami dziedzin (neurologii, okulistyki, fizjoterapii) w celu wybrania właściwych narzędzi i metod badawczych [26]. Jak wynika z dotychczasowych obserwacji i badań zastosowanie sztucznej inteligencji wpływa korzystnie na proces diagnostyczny w otoneurologii. Natomiast zastosowanie AI jest trudniejsze w przypadku określania etiologii zawrotów głowy oraz zaburzeń równowagi ze względu na złożoną naturę tych schorzeń.

Podczas wywiadu podmiotowego specjalista określa charakter zawrotów głowy, biorąc pod uwagę zarówno wpływ czynników inicjujących lub nasilających objawy przedsionkowe, jak i objawy towarzyszące, choroby współistniejące, stosowane leki. AI nie jest rozważana w tym zakresie, ponieważ wymaga dominacji czynnika ludzkiego, dlatego wykorzystywana jest przede wszystkim w badaniach obiektywnych. Mimo to z badania Visscher i wsp. (2020) wynika, że zautomatyzowana diagnostyka, bazująca na standardowych testach: VNG, VEMP, SOT, nie przynosi jednoznacznych wyników weryfikujących zaburzenie obwodowe lub ośrodkowe [27]. W przyszłych badaniach warto podjąć kolejne kroki celem takiego poszerzenia zastosowania uczenia maszynowego oraz wirtualnej rzeczywistości, aby metody te mogły być stosowane w rehabilitacji pacjentów oraz monitorowaniu jej efektów.

W ostatnich latach badania nad objętością guza nerwu przedsionkowo-ślimakowego uzyskują wysoką precyzję – automatycznej analizy obrazu MRI. Freund i wsp. (2020) wykazali potrzebę dalszych obserwacji dotyczących odpowiedzi na leczenie chirurgiczne i farmakologiczne u pacjentów z guzem nerwu przedsionkowo-ślimakowego, ponieważ na podstawie wyników dotychczasowych badań nie jest możliwe określenie prawdopodobieństwa regresji [28].

Ponadto w najnowszych badaniach nie pojawiły się informacje o zastosowaniu algorytmów celem weryfikacji zaburzeń przedsionkowych u dzieci. Wciąż istnieje potrzeba zbadania dziecka, jednak dostępne narzędzia diagnostyczne mają opracowane parametry i normy tylko dla dorosłych. Przy pomocy uczenia maszynowego możliwe jest opracowanie zakresów norm dla pacjentów pediatrycznych.

Publikacja powstała w związku z realizacją projektu „Utrzymanie Mobilnej Kapsuły Badań Zmysłów – urzędnictwa do badań przesiewowo-diagnostycznych zmysłów” dotyczącego utrzymania specjalnej infrastruktury informatycznej, dofinansowane na podstawie decyzji nr 2/E-523/SPUB/SN/2020 przez Ministerstwo Nauki i Szkolnictwa Wyższego.

¹ Na każdym etapie diagnostyki choroby Ménière'a wykazano charakterystyczne cechy: a) pod względem audiologicznym – zgodnie z przyjętym konsensusem Barány Society (2015 r.) dotyczącym choroby Ménière'a wykazano wystąpienie objawów definiujących tę chorobę; b) w obrazie MRI – widocznie zwiększona objętość struktur przedsionka; c) pod względem molekularnym – wyniki badań wykazały na zaburzoną homeostazę, która jest charakterystyczna tylko dla tej choroby błędnika.

Piśmiennictwo

1. Zarys otoneurologii. Narożny W, Skarżyński H (red.). Warszawa: Medical Education; 2018.

2. Hain TC. Epidemiology of Dizziness, 2021; https://dizziness-and-balance.com/disorders/dizzy_epi.html [dostęp: 21.07.2021].

3. Skarżyński H, Mrówka M, Młotkowska-Klimek P, Sitarz L, Wysocki J, Skarżyńska B. Stapedotomia w zaawansowanej otosklerozie i tympanosklerozie. *Audiofonologia*, 2003; XXIV: 44–51.
4. Sosna-Duranowska M, Tacikowska G, Gos E, Krupa A, Skarżyński PH, Skarżyński H. Vestibular function after cochlear implantation in partial deafness treatment. *Front Neurol*, 2021; 12.
5. Rutkowski L. *Metody i techniki sztucznej inteligencji*. Warszawa: Wydawnictwo Naukowe PWN; 2021.
6. Polska Akademia Nauk. *Biocybernetyka i inżynieria biomedyczna 2000*, t. 6: Sieci neuronowe. Duch W, Korbicz J, Rutkowski L, Tadeusiewicz R (red.), Warszawa: Akademicka Oficyna Wydawnicza Exit; 2000.
7. Luo J, Erbe C, Friendland DR. Unique clinical language patterns among expert vestibular providers can predict vestibular diagnoses. *Otol Neurotol*, 2018; 39(9): 1163–71.
8. Gos E, Ratajczak A, Tacikowska G, Sosna M, Piłka A, Skarżyński PH. Kwestionariusz przesiewowy do oceny zawrotów głowy i zaburzeń równowagi. *Now Audiofonol*, 2020; 8(2): 37–42.
9. Masankaran L, Viyanon W, Mahasithiwat V. Classification of benign paroxysmal positioning vertigo types from *Dizziness Handicap Inventory* using machine learning techniques. 2018 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS); 2018, 209–14.
10. *Handbook of Clinical Audiology*. Sixth edition. Katz J, Medwetsky L, Burkard R, Hood L (red.). Philadelphia: Lippincott Williams & Wilkins; 2009, 983.
11. Priesol AJ, Cao M, Brodley CE, Lewis RF. Clinical vestibular testing assessed with machine-learning algorithms. *JAMA*, 2015; 141(4): 364–72.
12. Elodie C, Mcgarvie L, Szmulewicz D, MacDougall H. Subjective visual vertical in virtual reality (Curator SVV): validation and normative data. *Virtual Reality*, 2018; 22: 315–20.
13. Ahmadi S-A, Vivar G, Frei J, Nowoshilow S, Bardins S, Brandt T i wsp. Towards computerized diagnosis of neurological stance disorders: data mining and machine learning of posturography and sway. *J Neurol*, 2019; 266 (Suppl. 1): 108–17.
14. Ahmadi S-A, Vivar G, Navab N, Möhwalder K, Maier A, Hadzhikolev H i wsp. Modern machine-learning can support diagnostic differentiation of central and peripheral acute vestibular disorders. *J Neurol*, 2020; 267 (Suppl. 1): 143–52.
15. Ciorba A, Skarżyński PH, Corazzi V, Bianchini C, Aimoni C, Hatzopoulos S. Assessment tools for use in patients with Ménière disease: An update. *Med Sci Monit*, 2017; 23: 6144–9.
16. Park JJ-H, Shen A, Keil S, Kraemer N, Westhofen M. Radiological findings of the cochlear aqueduct in patients with Ménière's disease using high-resolution CT and high-resolution MRI. *Eur Arch Otorhinolaryngol*, 2014; 271(12): 3325–31.
17. Kobayashi M, Fukaya T, Noda M. The endolymphatic sac in patients with Ménière's disease: correlation between the MRI and the surgical findings. *Acta Otolaryngol*, 2000; 120(8): 955–9.
18. Simon F, Guichard J-P, Kania R, Franc J, Herman P, Hautefort C. Saccular measurements in routine MRI can predict hydrops in Ménière's disease. *Eur Arch Otorhinolaryngol*, 2017; 274(12): 4113–20.
19. Cho YS, Cho K, Park CJ, Chung MJ, Kim JH, Kim K i wsp. Automated measurement of hydrops ratio from MRI in patients with Ménière's disease using CNN-based segmentation. *Scientific Reports*, 2020; 10(1): 7003.
20. Shapley J, Wang G, Dorent R, Dimitriadis A, Li W, Paddick I i wsp. An artificial intelligence framework for automatic segmentation and volumetry of vestibular schwannomas from contrast-enhanced T1-weighted and high-resolution T2-weighted MRI. *J Neurosurg*, 2019; 1–9.
21. George-Jones NA, Wang K, Wang J, Hunter JB. Automated detection of vestibular schwannoma growth using a two-dimensional U-Net Convolutional Neural Network. *Laryngoscope*, 2021; 131(2): E619–24.
22. Lee C, Lee W-K, Wu C-C, Lu C-F, Yang H-C, Chen Y-W i wsp. Applying artificial intelligence to longitudinal imaging analysis of vestibular schwannoma following radiosurgery. *Scientific Reports*, 2021; 11(1): 3106.
23. Cha D, Shin SH, Kim SH, Choi JY, Moon IS. Machine learning approach for prediction of hearing preservation in vestibular schwannoma surgery. *Sci Rep*, 2020; 10(1): 7136.
24. Wichova H, Shew M, Staecker H. Utility of perilymph microRNA sampling for identification of active gene expression pathways in otosclerosis. *Otol Neurotol*, 2019; 40: 710–9.
25. Shew M, Wichova H, Bur A, Koestler DC, Peter MS, Warnecke A i wsp. MicroRNA profiling as a methodology to diagnose Ménière's disease: Potential application of machine learning. *Otolaryngol Head Neck Surg*, 2021; 164(2): 399–406.
26. Visscher RMS, Feddermann-Demont N, Romano F, Straumann D, Bertolini G. Artificial intelligence for understanding concussion: Retrospective cluster analysis on the balance and vestibular diagnostic data of concussion patients. *PLoS One*, 2019; 14(4): e0214525.
27. Freund W, Weber F, Schneider D, Mayer U, Scheithauer M, Beer WM. Vestibular Nerve Atrophy After Vestibular Neuritis - Results from a Prospective High-Resolution MRI Study. *RoFo*, 2020; 192(9): 854–61.

