


Dostępne online www.sciencedirect.com**SciVerse ScienceDirect**journal homepage: www.elsevier.com/locate/otpol**Praca poglądowa/Review****Go może uzyskać otolaryngolog, stosując sztuczne sieci neuronowe?***How can an otolaryngologist benefit from artificial neural networks?*

Joanna Szaleniec^{1,*}, Jacek Składzień¹, Ryszard Tadeusiewicz², Krzysztof Oleś¹,
Marcin Konior¹, Robert Przeklasa¹

¹ Klinika Otolaryngologii UJ CM w Krakowie, Poland

Kierownik: prof. dr hab. Jacek Składzień

² Katedra Automatyki AGH, Kraków, Poland

Kierownik: prof. zw. dr hab. inż. Ryszard Tadeusiewicz

INFORMACJE O ARTYKULE

Historia artykułu:

Otrzymano: 24.02.2011

Zaakceptowano: 12.12.2011

Dostępne online: 23.06.2012

Słowa kluczowe:

- sztuczne sieci neuronowe
- otolaryngologia
- sztuczna inteligencja
- analiza danych medycznych
- analiza przeżycia

Keywords:

- Artificial neural networks
- Otolaryngology
- Artificial intelligence
- Medical data analysis
- Survival analysis

A B S T R A C T

Artificial neural networks are informatic systems that have unique computational capabilities. The principle of their functioning is based on the rules of data processing in the brain. This article discusses the most important features of the artificial neural networks with reference to their applications in otolaryngology. The cited studies concern the fields of rhinology, audiology, phoniatrics, vestibulology, oncology, sleep apnea and salivary gland diseases. The authors also refer to their own experience with predictive neural models designed in the Department of Otolaryngology of the Jagiellonian University Medical College in Krakow. The applications of artificial neural networks in clinical diagnosis, automated signal interpretation and outcome prediction are presented. Moreover, the article explains how the artificial neural networks work and how the otolaryngologists can use them in their clinical practice and research.

© 2012 Polish Otorhinolaryngology - Head and Neck Surgery Society. Published by Elsevier Urban & Partner Sp. z o.o. All rights reserved.

* Adres do korespondencji: Joanna Szaleniec, Katedra i Klinika Otolaryngologii UJ CM, ul. Śniadeckich 2, 31-531 Kraków. Tel.: +48 124247900. Adres email: asiat@agh.edu.pl (J. Szaleniec).

Wstęp

Fascynujące możliwości ludzkiego umysłu od lat inspirowały informatyków do tworzenia narzędzi obliczeniowych, mogących przynajmniej w pewnych aspektach naśladować inteligentne zachowania człowieka. Dążenia te w latach 50. ubiegłego wieku dały początek badaniom dotyczącym tak zwanej sztucznej inteligencji, zdefiniowanej przez jednego z jej pionierów Johna McCarthy'ego jako „konstruowanie maszyn, o których działaniu dałoby się powiedzieć, że są podobne do ludzkich przejawów inteligencji” [1]. Próby odwzorowania przez maszynę struktury i zasad działania mózgu doprowadziły do stworzenia tzw. sztucznych sieci neuronowych (*artificial neural networks*) (Ryc. 1). Są to systemy informatyczne o unikatowych możliwościach obliczeniowych, cieszące się wciąż rosnącym zainteresowaniem i (jak się zdaje) mające tyłuż żarliwych zwolenników, co zagroziło przeciwników. Historia zastosowań sieci neuronowych obfituje bowiem w spektakularne sukcesy, ale obok nich nie brakuje bolesnych rozczarowań i porażek.

W prezentowanym artykule omówione zostaną podstawowe właściwości i zasady tworzenia modeli neuronowych, przy czym treści te prezentowane będą głównie w oparciu o prace badawcze dotyczące ich zastosowań w otolaryngologii. Wyboru prezentowanych zagadnień dokonano w taki sposób, aby zasygnalizować możliwie szeroki zakres ich aplikacji w różnych dziedzinach otolaryngologii. Cytowane prace dotyczą ryнологii [2], audiologii [3–12], foniatrii [13–16], westybulologii [17], onkologii [18–22], diagnostyki i terapii zespołu bezdechu sennego [23–25] oraz schorzeń gruczołów ślinowych [26].

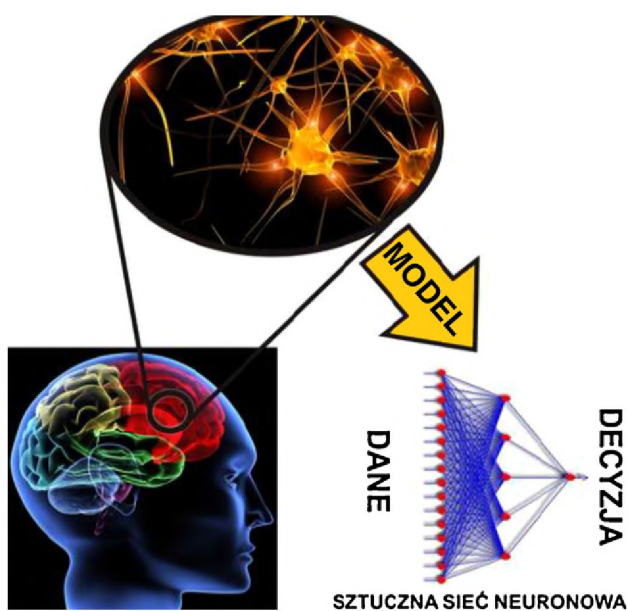
Odwolano się przy tym również do doświadczeń Kliniki Otolaryngologii UJ CM w Krakowie w zakresie budowania predykcyjnych modeli neuronowych [12]. Artykuł nie ma

stanowiąc wyczerpującego przeglądu piśmiennictwa dotyczącego wykorzystania sztucznych sieci neuronowych w laryngologii, gdyż literatura przedmiotu jest obecnie niezwykle szeroka i jej szczegółowe omówienie przekraczałoby znacząco ramy niniejszej publikacji. Zamiast tego niniejszy artykuł powinien dać Czytelnikom ogólny ogłąd przedstawianej tu problematyki, pokazujący, jak formułowane są zadania, które następnie rozwiązywane są przy użyciu sieci neuronowych, w jaki sposób stosuje się te sieci, korzystając w szczególności z możliwości ich uczenia, a także, co się osiąga z pomocą sieci neuronowych i jak można wykorzystywać uzyskiwane wyniki.

Ogląd taki może być użyteczny przy podejmowaniu przez Czytelników decyzji o ewentualnym zastosowaniu sztucznych sieci neuronowych przy rozwiązywaniu kolejnych problemów związanych z otolaryngologią, gdzie narzędzie to zdecydowanie jeszcze „nie powiedziało ostatniego słowa”.

Na czym polegają unikatowe możliwości sztucznych sieci neuronowych?

Rosnąca popularność sztucznych sieci neuronowych w rozmaitych dziedzinach (w tym również w medycynie) wynika z faktu, że systemy te posiadają pewne wyjątkowe właściwości, odróżniające ich funkcjonowanie w sposób zasadniczy od działania typowego programu komputerowego. Wykorzystując tradycyjny program, komputer potrafi jedynie bardzo szybko wykonać serię kolejnych operacji przetwarzania danych, opierając się na sekwencji sprecyzowanych przez programistę poleceń. Stosując tę metodę, komputer może wyliczyć rozwiązanie dowolnie skomplikowanego zadania, pod warunkiem że twórca programu znał metodę tego rozwiązania. Typowy system komputerowy działa więc według zadanego algorytmu i jest kategorycznie uzależniony od tego, czy potrafimy taki algorytm zbudować. Tymczasem sieć neuronowa jest w stanie samodzielnie odkryć zasadę rozwiązywania stawianych jej zadań, nawet jeśli sam programista tej reguły nie zna. W przeciwieństwie do tradycyjnego oprogramowania komputera, sieć neuronowa ma zdolność uczenia się na podstawie przykładów i uogólniania zdobytej wiedzy na nowe, podobne przypadki. Jak łatwo zauważyć, ten sposób uczenia sieci neuronowej jest podobny do procesu zdobywania doświadczenia przez człowieka. Szkolący się lekarz w procesie swojej edukacji nie bazuje jedynie na „instrukcjach” zaczerpniętych z książek, ale stykając się z kolejnymi chorymi, uczy się podejmowania właściwych decyzji na podstawie złożonych przesłanek, niekiedy w sposób nie do końca uświadomiony. Opisane powyżej właściwości sieci neuronowych pozwalają więc na ich praktyczne zastosowanie do rozwiązywania takich zagadnień, w przypadku których człowiek bazuje na swoim doświadczeniu i intuicji. Sieć ma także możliwość gromadzenia i uogólniania wiedzy pozyskiwanej poprzez obserwację czynności najbardziej doświadczonych lekarzy, może więc służyć jako narzędzie do agregacji i koncentracji doświadczeń wielu najlepszych praktyków.



Ryc. 1 – Biologiczna inspiracja sztucznych sieci neuronowych

Fig. 1 – Biological inspiration of artificial neural networks

Przykłady wykorzystania sztucznych sieci neuronowych w otolaryngologii

Wspomaganie diagnostyki klinicznej

Podjęcie decyzji diagnostycznych na podstawie badania przedmiotowego i podmiotowego oraz ewentualnie wyników badań dodatkowych wymaga na ogół ogromnej wiedzy i doświadczenia. Rzadko udaje się sformułować proste reguły, według których na podstawie danych klinicznych należy wyciągać ostateczne wnioski. Zwykle takie proste reguły nie istnieją, ponieważ istota diagnostyki lekarskiej jest z samej swojej natury bardzo skomplikowana. Dodatkowa trudność wiąże się także z procesem werbalizacji tych reguł. Specjalista nie zawsze zdaje sobie sprawę z tego, że jego przez lata wypracowany sposób działania opiera się na regułach, które stosuje podświadomie, czy też odwołuje się do intuicji, czy wręcz do geniuszu, czyli rzeczy absolutnie niedających się sformalizować. Wielu badaczy usiłowało odpowiedzieć na pytanie, czy złożony proces intelektualny, jakiego dokonuje specjalista, stawiając rozpoznanie choroby, można przynajmniej w pewnych aspektach odtworzyć za pomocą metod informatycznych. Większość takich prób algorytmizacji, odwołujących się do reguł logiki i obliczeń numerycznych, po prostu zawiodła. Jednak ostatnio okazuje się, że dzięki wykorzystaniu sieci neuronowych możliwe jest stworzenie narzędzi skutecznie wspomagających specjalistyczną diagnostykę. Wskażmy kilka przykładów.

W roku 2009 objęto ochroną patentową narzędzie wykorzystujące sztuczne sieci neuronowe, służące do diagnozowania chorób alergicznych górnych dróg oddechowych (w szczególności schorzeń nosa i zatok przynosowych) [2]. Autor opatentowanej metody podkreśla, że ze względu na wzrastającą częstość występowania schorzeń alergicznych, dostęp do specjalistów staje się coraz trudniejszy, a czas oczekiwania na konsultację i niezbędną diagnostykę znacząco się wydłuża. Dane dotyczą Wielkiej Brytanii, ale są powody by przypuszczać, że wspomniana prawidłowość daje się także obserwować w Polsce. Z tego względu niezbędne jest wdrożenie systemu, który pozwoliłby skrócić do minimum czas oczekiwania na wynik konsultacji oraz ograniczyć liczbę wykonywanych badań. W cytowanym badaniu opracowano kilka modeli neuronowych, które są w stanie zaproponować wstępne rozpoznanie schorzenia na podstawie wywiadu (objawy kliniczne, czynniki wywołujące zaostrzenia choroby, zażywane leki itd.), wyników skórnych testów punktowych dla wybranych alergenów oraz poziomu specyficznych IgE.

Uczenie budowanych modeli neuronowych polegało na przedstawieniu im danych kilkudziesięciu pacjentów wraz z prawidłowymi rozpoznaniem postawionymi przez doświadczonego lekarza. Po zakończeniu uczenia przetestowano działanie modeli w odniesieniu do innej grupy pacjentów, cierpiących na te same schorzenia. Wykazano, że wstępne diagnozy podawane przez sieć neuronową były zgodne z rozpoznaniem postawionymi przez specjalistę. Zdaniem autora, dzięki zastosowaniu sieci neuronowych wstępną diagnostykę schorzeń nosa i zatok przynosowych może przeprowadzić przeszkolona pielęgniarka. W efekcie

powinna obniżyć się liczba niepotrzebnych konsultacji specjalistycznych, wskutek czego lekarz specjalista będzie mógł efektywniej wykorzystać swój czas i wiedzę, zajmując się przypadkami rzeczywiście wymagającymi jego interwencji.

Zastosowanie sztucznych sieci neuronowych do wspomaganie diagnostyki omawia również praca Juholi i wsp. [6], w której zadaniem modelu było określenie przyczyn zawrotów głowy na podstawie objawów klinicznych. Na podstawie danych dotyczących częstości występowania i czasu trwania zawrotów głowy oraz czasu trwania niedosłuchu, a także przebytych urazów głowy, sieć samoczynnie dokonywała wstępnej klasyfikacji, w większości przypadków prawidłowo wyróżniając grupy pacjentów cierpiących z powodu łagodnych położeniowych zawrotów głowy, choroby Meniere'a, *neuritis vestibularis* i nerwiaka nerwu przedsionkowego. Niestety w odniesieniu do rzadko występujących przyczyn zawrotów głowy nie uzyskano prawidłowych ich klasyfikacji ze względu na zbyt małą liczbę przypadków prezentowanych sieci w trakcie jej uczenia.

Interesującą propozycję wykorzystania sieci neuronowych w diagnostyce bezdechu sennego przedstawili el-Solh i wsp. [25]. Autorzy tej pracy stworzyli system pozwalający przewidywać wartość wskaźnika AHI (wskaźnik bezdech/spytanie oddechu) bez wykonywania polisomnografii, a jedynie na podstawie danych klinicznych i pomiarów antropometrycznych pacjenta. Biorąc pod uwagę fakt, jak kosztowne i jak uciążliwe dla pacjenta jest badanie polisomnograficzne – zastosowanie tego neuronowego modelu wydaje się bardzo interesującą alternatywą dla procedur diagnostycznych stosowanych obecnie.

Automatyczna interpretacja sygnałów medycznych

Jednym z klasycznych zadań, w których sieci neuronowe niejednokrotnie wykazywały przewagę nad innymi metodami, jest rozpoznawanie obrazów (lub szerzej – rozpoznawanie wzorców; *pattern recognition*). Często cytowany przykład to automatyczne rozpoznawanie znaków alfanumerycznych (drukowanych lub pisanych ręcznie liter i cyfr). Liczba prac opisujących takie właśnie zastosowanie sieci neuronowej z pewnością przekroczyła już kilka setek, a wciąż przybywają nowe, bo zastosowanie to jest efektywne i łatwe do oceny, a zasoby danych potrzebnych do uczenia i egzaminowania sieci są łatwe do pozyskania lub niezbyt trudne do samodzielnego wytworzenia. Znacznie bardziej złożonym zadaniem jest rozpoznawanie ludzi na podstawie obrazów ich twarzy (na przykład dla potrzeb identyfikowania osób posiadających określone uprawnienia w systemie komputerowym szpitala). Uproszczoną wersję tego typu systemu stanowi sieć, której powierza się odróżnianie twarzy męskich od kobiecych. Mimo że człowiek radzi sobie z tym zadaniem bez najmniejszego kłopotu, sformułowanie ogólnych zasad, według których takiej klasyfikacji miałaby dokonywać maszyna, następcza ogromnych trudności. W tej sytuacji oczywiste wydaje się zastosowanie sieci neuronowych, które mają zdolność samodzielnego formułowania zasad klasyfikacji na podstawie przykładów.

W medycynie niezwykle często mamy do czynienia z sytuacjami poszukiwania metody rozpoznawania

i klasyfikacji wzorców, między innymi w celu automatycznej interpretacji różnego rodzaju sygnałów medycznych.

Sygnałem, którego rozumienie (z przyczyn oczywistych dla każdego laryngologa) wymaga dużego doświadczenia i wprawy, są między innymi słuchowe potencjały wywołane pnia mózgu. Zasady interpretacji wyniku badania ABR trudno opisać regułami matematycznymi ze względu na różnorodność obrazu uzyskiwanych krzywych. Liczne prace wykazują jednak, że sztuczne sieci neuronowe, które nie wymagają znajomości zasad klasyfikacji *a priori*, mogą służyć jako skuteczne narzędzie do automatycznej klasyfikacji tych sygnałów [7–10]. Zasadniczy problem, jaki się przy tym pojawia, polega na tym, że sieć neuronowa, oceniając przebieg sygnału ABR uzyskanego dla pewnego określonego poziomu bodźca akustycznego wywołującego badaną odpowiedź – jest w gorszej sytuacji niż lekarz, z którym usiłuje konkurować. Powodem tego jest fakt, że lekarz ogląda całą sekwencję zapisów ABR, zaczynających się od bodźca akustycznego tak silnego, że zdecydowanie wywołuje on reakcję pnia mózgu, aż do bodźców tak słabych, że upewnienie się, iż mózg zareagował na ten sygnał, nastęrcza dużych trudności. Na podstawie obserwacji takiej sekwencji przebiegów (a nie pojedynczego sygnału) można łatwiej ustalić, czy fala V występuje w rozważanym przebiegu ABR – czy już nie. Sieć obserwująca pojedynczy przebieg ABR i podejmująca próbę jego klasyfikacji napotyka w tym miejscu na znacznie większą trudność. Dlatego Izvorski i wsp. [7] przedstawili koncepcję kontekstowego rozpoznawania przebiegów ABR, co okazało się rozwiązaniem nader skutecznym.

W dziedzinie audiologii sztuczne sieci neuronowe znalazły ponadto zastosowanie między innymi do automatycznej klasyfikacji sygnałów otoemisji akustycznych wywołanych trzaskiem (TEOEA). W badaniach tych sieć wykorzystana została do odróżniania wyników fizjologicznych od patologicznych w ramach przesiewowych badań słuchu u noworodków [4]. Z kolei Ziavra i wsp. [3] wykorzystali produkty zniekształceń nieliniowych ślimaka (DPOEA) jako podstawę dla automatycznego rozpoznawania niedosłuchu pochodzenia ślimakowego. Tutaj także rola sieci polega na przypisaniu jej funkcji uczącego się klasyfikatora.

Próby zastosowania modeli neuronowych nie ominęły również westybulologii, gdzie podjęto próbę diagnozowania schorzeń układu równowagi na podstawie wyników badania posturograficznego [17].

W podobnym do opisanych powyżej celu wykorzystano modele neuronowe w diagnostyce i leczeniu bezdechu sennego. Norman i wsp. [23] opisali metodę rozpoznawania epizodów zapadania się dróg oddechowych podczas oddychania na podstawie analizy krzywych przepływu powietrza w czasie. Wykorzystanie sztucznej sieci neuronowej do odróżniania oddechów prawidłowych od nieprawidłowych stwarza możliwość wyeliminowania żmudnego manualnego zliczania incydentów bezdechu w czasie snu. Z kolei rozpoznawanie poprzedzającej bezdech wibracji ściany gardła, przedstawione przez Behbehaniego [24], może stanowić podstawę dla automatycznej regulacji ciśnienia generowanego przez aparat CPAP.

Odmiernym problemem, w którego rozwiązaniu znalazły także zastosowanie sztuczne sieci neuronowe, jest próba odwzorowania (na podstawie analizy akustycznej sygnału

mowy) percepcyjnej oceny głosu dokonywanej przez specjalistę. Liczne badania wykazały, że znalezienie prostej korelacji pomiędzy parametrami fizycznymi opisującymi sygnał mowy a percepcyjną oceną jakości głosu pacjenta nastęrcza znacznych trudności. Trudności te pojawiają się przy każdej próbie obiektywizacji oceny mowy patologicznej, ponieważ zależność między akustyczną charakterystyką sygnału a jego subiektywnym odbiorem przez słuchacza ma najprawdopodobniej wieloczynnikowy i nieliniowy charakter. Jak zaznaczono powyżej, w zagadnieniach tego rodzaju sztuczne sieci neuronowe często wykazują przewagę nad innymi metodami, ponieważ neurony są z zasady nieliniowymi przetwornikami sygnałów, zaś wprowadzenie w sieci zależności wieloczynnikowych sprowadza się do tego, że sieć posiada wiele wejść, których sygnały są ze sobą rozmaicie kombinowane w kolejnych warstwach tych neuronów.

Wychodząc z omówionych wyżej przesłanek, Schoenweiler i wsp. oraz Linder i wsp. [13, 14] opracowali modele służące do rozpoznawania dysfonii na podstawie analizy akustycznej sygnału mowy, cechujące się specyficznością do 93,9% i czułością do 63%. Zdaniem autorów, narzędzia te mogą znaleźć zastosowanie w badaniach przesiewowych, monitorowaniu, dokumentowaniu i wstępnej ocenie zaburzeń głosu, co zwiększy dostępność diagnostyki, ograniczonej dotychczas do wysokospecjalistycznych centrów medycznych, a także dla potrzeb medycyny sądowej.

Badania prowadzone z wykorzystaniem sieci neuronowych w analizie mowy patologicznej mogą dotyczyć różnych metod rejestracji tego sygnału. Na przykład publikacja Ritchingsa i wsp. [15] omawia możliwość dokonania oceny jakości głosu w oparciu o badanie elektrogłottograficzne.

Również w Klinice Otolaryngologii w Krakowie w ramach działalności Studenckiego Koła Naukowego tworzone modele neuronowe z powodzeniem realizujące zadanie odróżniania mowy fizjologicznej od patologicznej na podstawie analizy akustycznej sygnału mowy [16].

Interesujące propozycje wykorzystania sieci neuronowych do klasyfikacji sygnałów biochemicznych przedstawił Kuzmanovski i wsp. [26] (oznaczanie składu kamieni śliniankowych na podstawie spektroskopii w podczerwieni) oraz van Staveren i wsp. [21] (ocena stopnia dysplazji w śluzówce jamy ustnej w oparciu o widma autofluorescencji tkankowej).

Sieci neuronowe dają także nowe możliwości wspomaganie terapii. Przykładem jest wykorzystanie sieci neuronowych w protezowaniu słuchu, co przedstawili Arsten i wsp. [5]. Autorzy zaproponowali metodę automatycznego wstępnego doboru aparatu słuchowego bazującą na kształcie krzywej audiometrycznej. Urządzeniem wspomagającym w tym przypadku pracę terapeuty i protetyka była właśnie sieć neuronowa traktowana jako system doradczy.

Prognozowanie przebiegu choroby i wyników leczenia

Odrębną grupą zadań, gdzie sieci neuronowe wielokrotnie wykazały swoją użyteczność, jest przewidywanie przyszłych wydarzeń na podstawie faktów z przeszłości. Jak się okazuje, modele neuronowe mogą znajdować zastosowanie nie tylko w przewidywaniu pogody, kursów giełdowych lub zapotrzebowania miasta na energię elektryczną, ale również w prognozowaniu przebiegu choroby i wyników leczenia.

Badania dotyczące zastosowań sieci neuronowych do prognozowania przeżycia najczęściej dotyczą chorób nowotworowych. Przewaga sztucznej inteligencji nad klasycznymi metodami statystycznymi, takimi jak model proporcjonalnego hazardu Coxa lub regresja logistyczna, jest wciąż kwestią dyskusyjną. W pracy Jonesa i wsp. [18], dotyczącej predykcji przeżycia w grupie chorych z rakiem płaskonabłonkowym krtani, dokonano porównania wyników uzyskanych przez sztuczne sieci neuronowe z modelem Coxa i wykresem Kaplana-Meiera. Przewidywania oparto na danych dotyczących: wieku i płci pacjentów, ich sprawności w skali ECOG, lokalizacji guza, jego cech histopatologicznych i stopnia zaawansowania klinicznego choroby. Wykazano, że model neuronowy może zapewniać wyniki jakościowo podobne do tradycyjnych metod statystycznych, jednak w przewidywaniu przeżycia wykazuje większą wrażliwość na różnice wieku chorych i stopień zaawansowania węzłowego nowotworu.

Porównania skuteczności sztucznych sieci neuronowych z regresją logistyczną dokonali z kolei Bryce i wsp. [19]. Praca ich dotyczyła przewidywania przeżycia 2-letniego pacjentów z zaawansowanymi nowotworami głowy i szyi, leczonych radioterapią lub radiochemioterapią. Celem pracy było opracowanie metody pozwalającej już przed rozpoczęciem leczenia zidentyfikować pacjentów, u których sama tylko radioterapia nie daje szans przeżycia i wskazane jest dodatkowe zastosowanie chemioterapii. Klasyfikacji dokonano w oparciu o kilkanaście cech klinicznych, w tym: lokalizację i zaawansowanie nowotworu, wiek i płeć pacjenta, jego stan ogólny, choroby towarzyszące i dane dotyczące morfologii krwi. Badania wykazały, że w analizowanym przypadku sztuczne sieci neuronowe trafniej przewidują przeżycie niż regresja logistyczna. Podobne zagadnienie omawia praca [20], w której sztuczną sieć neuronową wykorzystano do przewidywania tolerancji chemioradioterapii u chorych z nowotworami głowy i szyi.

Przewagę modeli neuronowych nad regresją logistyczną w prognozowaniu przebiegu choroby nowotworowej wykazano również w pracy Dobrosia i wsp. [22], w której przewidywano obecność przerzutów raka krtani do węzłów chłonnych, uzyskując 96% poprawnych predykcji.

W Klinice Otolaryngologii UJ CM w Krakowie prowadzone są obecnie prace mające na celu stworzenie modeli neuronowych prognozujących poprawę słuchu po leczeniu operacyjnym chorych z przewlekłym zapaleniem ucha środkowego [12].

Jak działa sztuczna sieć neuronowa?


Podane powyżej przykłady ilustrują szeroki zakres zastosowań, w których sieci neuronowe okazują się równie skuteczne lub skuteczniejsze niż dotychczas wykorzystywane narzędzia matematyczne i informatyczne. Omówione przykłady dowodzą, że najistotniejszymi cechami wyróżniającymi sieci neuronowe jest ich zdolność do uczenia się, a także do modelowania złożonych zjawisk i wielowymiarowych zależności. Poniżej wyjaśnimy pokrótce, w jaki sposób powyższe zdolności są osiągnane.

Sztuczna sieć neuronowa jest systemem informatycznym przetwarzającym dane w podobny sposób, jak układ nerwowy człowieka lub zwierzęcia [27]. W naturalnym (biologicznym)

układzie nerwowym podstawowym elementem przetwarzającym informacje jest komórka nerwowa. Biologiczny neuron otrzymuje sygnały wejściowe poprzez dendryty od innych komórek nerwowych bądź od receptorów. Sygnały te są modyfikowane na poziomie synaps, które mogą mieć charakter pobudzający lub hamujący. Zmodyfikowane przez synapsy sygnały sumują się i pod ich wpływem neuron generuje sygnał wyjściowy, przekazywany aksonem do kolejnych elementów układu nerwowego lub do efektorów. Ta oczywista dla każdego lekarza, prosta zasada działania „naturalnej” sieci neuronowej, znajduje swoje odzwierciedlenie w sztucznej sieci neuronowej, stanowiącej bardzo uproszczony model układu nerwowego.

Podstawowe elementy modelu, jakim jest sieć neuronowa – tzw. sztuczne neurony – odbierają sygnały wejściowe, które następnie na poziomie sztucznych synaps ulegają modyfikacji (poprzez przemnożenie wartości tych sygnałów przez odpowiednie współczynniki, tzw. wagi). Zmodyfikowane w ten sposób sygnały wejściowe sumują się, a następnie wewnątrz neuronu podlegają kolejnym przekształceniom matematycznym. Ostatecznie sztuczny neuron generuje sygnał wyjściowy (Ryc. 2).

W obrębie sieci neurony najczęściej ułożone są w warstwy. Zadaniem pierwszej z nich – warstwy wejściowej – jest wprowadzenie sygnałów wejściowych do sieci. Jest to zazwyczaj zestaw liczb lub danych jakościowych (takich jak na przykład płeć pacjenta albo lokalizacja guza) podawanych przez użytkownika, charakteryzujących zadawane sieci „pytanie”. Funkcję neuronu warstwy wejściowej można porównać z komórką nerwową odbierającą sygnał bezpośrednio z receptora, taką jak na przykład I neuron drogi słuchowej. Kolejne warstwy – tzw. warstwy ukryte – mają za zadanie przetwarzanie danych. W biologicznym układzie nerwowym (np. w obrębie drogi słuchowej) komórek kolejno przetwarzających sygnał jest bardzo wiele, podczas gdy w znacznie prostszej sztucznej sieci neuronowej na ogół



Ryc. 2 – Porównanie sztucznego neuronu z neuronem biologicznym

Fig. 2 – The comparison of biological and artificial neuron

wykorzystuje się jedną, rzadziej dwie tak zwane warstwy ukryte. Nazwa tych warstw bierze się stąd, że pracy neuronów ulokowanych w tych warstwach nie widać z zewnątrz – ani od strony wejścia do sieci, ani od jej wyjścia. Ostatnia warstwa – wyjściowa – to neurony generujące (w postaci liczbowej) „odpowiedź” sieci.

Na czym polega uczenie sieci neuronowej?

Najczęściej wykorzystywaną formą trenowania sieci neuronowej jest tzw. „uczenie z nauczycielem”. Metodę tę wykorzystano w większości cytowanych powyżej prac. Zilustrujemy ją na przykładzie publikacji dotyczącej przesiewowych badań słuchu u noworodków [4].

W pierwszym etapie tworzenia modeli neuronowych zaprezentowano sieci wyniki testów (TEOEA) około tysiąca noworodków oraz ich klasyfikację dokonaną przez eksperta. Proces uczenia polegał na stopniowym dokonywaniu takich zmian wag w „synapsach” sieci, aby w efekcie uzyskać odpowiedzi zgodne z diagnozami stawianymi przez specjalistę.

W drugim etapie przetestowano działanie wytrenowanej sieci w odniesieniu do innej grupy, również liczącej około 1000 noworodków, i porównano odpowiedzi sieci z oceną eksperta. W ten sposób potwierdzono, że sieć nie tylko dopasowała się do zbioru uczącego, ale również posiada zdolność do generalizacji zdobytej wiedzy (tj. potrafi uzyskiwać prawidłowe rozwiązania dla nowych przypadków, których nie „widziała” w trakcie procesu uczenia). Swoistość uzyskanych modeli diagnostycznych sięgała aż 99,4%, natomiast czułość 87,3%.

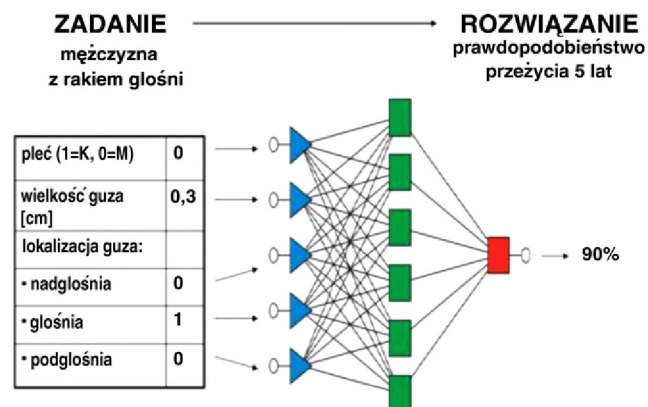
Nieco rzadziej w zastosowaniach medycznych wykorzystywana jest metoda „uczenia bez nauczyciela”, gdzie sieć neuronowa nie dysponuje w ogóle prawidłowymi rozwiązaniami zadanego problemu, ale samoczynnie dopasowuje swoje parametry do struktury danych, dokonując w ten sposób ich klasyfikacji. Przykłady takiego zastosowania sieci w odniesieniu do pacjentów z otosklerozą można znaleźć w publikacji dotyczącej badań przeprowadzonych na Uniwersytecie Medycznym w Łodzi [11], natomiast do klasyfikacji danych otoneurologicznych w omówionej wcześniej pracy [6].

Jak wykorzystać sztuczne sieci neuronowe w pracy klinicznej lub badawczej?

Obecnie na rynku dostępne są programy komputerowe pozwalające korzystać ze sztucznych sieci neuronowych nie tylko osobom mającym wykształcenie informatyczne, ale również specjalistom z innych dziedzin (w tym także lekarzom). Podstawową wiedzę na ten temat można uzyskać zarówno z materiałów szkoleniowych dostarczanych przez twórców oprogramowania, jak i z podręczników adresowanych do osób nie mających wykształcenia informatycznego [28]. Przed przystąpieniem do pracy z sieciami neuronowymi warto jednak rozważyć, czy są one odpowiednim narzędziem do rozwiązania analizowanego problemu badawczego. W przypadku zagadnień, gdzie charakter zależności między danymi wejściowymi i wyjściowymi jest znany i daje się łatwo opisać matematycznie, nie należy oczekiwać przewagi modeli neuronowych nad innymi metodami.

Sieci neuronowe mogą zapewnić dobrą zgodność zachowania neuronowego modelu i modelowanego zjawiska (co może być podstawą diagnozy albo prognozy), ale to w najmniejszym stopniu nie ułatwia zrozumienia natury modelowanego zjawiska. Przeciwnie, ze względu na złożoność procesu przetwarzania danych w obrębie sieci w zasadzie nie ma możliwości jednoznacznego wnioskowania na temat wpływu poszczególnych danych wejściowych na ostateczną odpowiedź sieci. Nieuzasadnione byłoby na przykład wnioskowanie, że poziom hemoglobiny wpływa na przeżycie 2-letnie pacjentów z nowotworami głowy i szyi wyłącznie na podstawie faktu wykorzystania tej właśnie zmiennej przez prawidłowo funkcjonujący neuronowy model prognostyczny [19]. Modele neuronowe nie mogą zatem służyć do analizowania czy wyjaśniania charakteru obserwowanych zależności, a to oznacza, że ich stosowanie wzbogaca możliwości praktycznych działań, ale nie wzbogaca wiedzy.

Korzystanie z sieci neuronowych wymaga odpowiedniego formułowania problemów, które chcemy za ich pomocą rozwiązać. W szczególności trzeba dokładnie zdefiniować, co w rozważanym problemie można uznać za dane wejściowe oraz czym są oczekiwane od sieci dane wyjściowe (niosące rozwiązanie sformułowanego problemu). Zadania stawiane sieci neuronowej należy ponadto odpowiednio zakodować, tj. przedstawić wszystkie dane w formie liczbowej, tak aby mogły być wykorzystane jako sygnały wejściowe. Zmienne ilościowe (takie jak wiek, rozmiar guza w cm) są *a priori* wyrażone liczbowo [19], w niektórych przypadkach wskazana jest jedynie ich normalizacja. Każda z takich zmiennych wymaga jednego neuronu wejściowego. Również zmienne przyjmujące tylko jedną z dwóch możliwych wartości można w prosty sposób przedstawić w sposób liczbowy (np. płeć: 1 – kobieta, 0 – mężczyzna; wiek: 1 – powyżej 60 lat, 0 – poniżej 60 lat itp. [18]). Zmienne jakościowe przyjmujące więcej wartości należy zakodować metodą 1 z N, wykorzystując większą liczbę neuronów wejściowych dla jednej zmiennej. Na przykład dla określenia lokalizacji guza krtani potrzebne mogą być 3 neurony, z których każdy odpowiada jednej lokalizacji. Przykładowo dla raka nadgłośnia kodowanie przewiduje następujące rozłożenie sygnałów na tych trzech neuronach: 1 – na neuronie pierwszym, 0 – na neuronie drugim, 0 – na neuronie trzecim. Podobnie dla raka głośnia odpowiedni kod wygląda tak: 0-1-0, a dla raka podgłośnia 0-0-1 (Ryc. 3).



Ryc. 3 – Przykład sztucznej sieci neuronowej
Fig. 3 – An example of an artificial neural network

W podobny sposób należy zakodować oczekiwaną odpowiedź sieci. W tym wypadku użytkownik musi wybrać jedną z dwóch opcji. Sieć neuronowa może dostarczać odpowiedzi o charakterze pewnej decyzji, na przykład może sygnalizować, czy dany przypadek należy do pewnej klasy. Przykładem może tu być następujące kodowanie: 0 – pacjent nie uzyskał zadowalającej poprawy słuchu po operacji, 1 – pacjent uzyskał zadowalającą poprawę słuchu [12]. Przy takim postawieniu zadania mamy do czynienia z tzw. siecią klasyfikacyjną.

Jeżeli natomiast sieć ma dostarczać odpowiedzi w postaci konkretnej liczby (np. jaka będzie wartość rezerwy ślimakowej po operacji), nazywa się ją siecią regresyjną.

Kwestią wymagającą dużej uwagi i doświadczenia jest właściwy wybór zmiennych wejściowych. Im jest ich więcej, tym większa liczba przypadków uczących jest wymagana, aby prawidłowo wytrenować sieć. Szacuje się, że zbiór uczący powinien zawierać liczbę przypadków kilkukrotnie przekraczającą liczbę połączeń w sieci, a liczba połączeń rośnie z kwadratem liczby zmiennych wejściowych, ponieważ połączenia wewnątrz sieci realizowane są na zasadzie „każdy z każdym”. Oznacza to, że podwojenie liczby zmiennych wejściowych będzie wymagało cztery razy liczniejszego zbioru uczącego, a trzykrotnie więcej zmiennych wejściowych spowoduje zapotrzebowanie na dziewięciokrotnie liczniejszy zbiór uczący. Przykładem bardzo dużej sieci można znaleźć w pracy van Staverena i wsp. [21], gdzie widmo autofluorescencji tkankowej zakodowano, wykorzystując 175 neuronów wejściowych, a cała sieć zawierała 50 000 połączeń. Autorzy przyznają, że właściwa liczba widm niezbędnych do wyszkolenia sieci powinna wynosić około 500 000, podczas gdy w badaniach dysponowano zbiorem jedynie... 28 przypadków. Z kolei skutecznie działające, objęte ochroną patentową modele neuronowe do diagnozowania schorzeń górnych dróg oddechowych [2] funkcjonują w oparciu o zaledwie 9 starannie wyselekcjonowanych zmiennych wejściowych.

Niemniej istotne jest właściwe wyselekcjonowanie zbioru przypadków uczących oraz zbioru testowego. Obydwie grupy powinny być reprezentatywne dla całej populacji. Często zdarza się, że sieć neuronowa doskonale radzi sobie ze znajdowaniem prawidłowych rozwiązań dla zbioru uczącego, jednak jej odpowiedzi dla nowych przypadków są zupełnie niezadowalające. Oznacza to, że sieć nie nabyła zdolności do generalizacji wiedzy nabytej w procesie uczenia. Z tego względu, raportując wyniki uzyskiwane przez sieć (na przykład czułość i swoistość diagnozy), należy podawać wyłącznie dane uzyskane dla zbioru testowego [29].

Podsumowanie

Sztuczne sieci neuronowe są skutecznymi narzędziami, pozwalającymi odwzorować złożone zależności pomiędzy starannie wybranymi przyczynami i dobrze zdefiniowanymi skutkami. Ich popularność w ciągu ostatnich lat wzrosła tak bardzo, że obecnie trudno jest znaleźć dziedzinę, w której nie próbowano jeszcze wykorzystać ich możliwości. W otolaryngologii pozwalają one między innymi na zautomatyzowanie pewnych aspektów diagnostyki, których przeprowadzenie przez człowieka jest żmudne lub wymaga znacznego doświad-

czenia. Narzędzia te również wspomagają terapię, a także umożliwiają przewidywanie wyników leczenia. Modele prognozujące efekty terapii dają szansę jej optymalizacji, gdyż dzięki możliwości przewidywania z wyprzedzeniem skutków podjętych działań leczniczych można wybrać ten wariant postępowania leczniczego, który gwarantuje najlepszy skutek. Zastosowanie sieci neuronowych jest łatwe, ponieważ obecnie oprogramowanie pozwalające korzystać ze sztucznych sieci neuronowych jest dostępne dla każdego badacza i klinicysty zarówno w postaci pakietów firmowych, jak i łatwo dostępnych programów możliwych do pozyskania za darmo z Internetu (na przykład ze strony <http://home.agh.edu.pl/~tad>). Co więcej, obszerne piśmiennictwo dotyczące tej dziedziny może stać się inspiracją dla ich nowych użytecznych zastosowań klinicznych.

Wkład autorów/Authors' contributions

Według kolejności.

Konflikt interesu/Conflict of interest

Nie występuje.

PIŚMIENNICTWO/REFERENCES

- [1] Rutkowski L, Siekmann J, Tadeusiewicz R, Zadeh LA, editors. *Artificial Intelligence and Soft Computing Lecture Notes in Artificial Intelligence*, Vol. 3070. Berlin-Heidelberg-New York: Springer-Verlag; 2004.
- [2] Williams PE. Method and Apparatus for Diagnosing an Allergy of the Upper Respiratory Tract Using a Neural Network. PCT/GB2008/002383(15.01.2009).
- [3] Ziaavra N, Kastanioudakis I, Trikalinos TA, Skevas A, Ioannidis JPA. Diagnosis of sensorineuronal hearing loss with neural networks versus logistic regression modeling of distortion product otoacoustic emissions. *Audiol Neurootol* 2004;9:81-87.
- [4] Buller G, Lutman ME. Automatic classification of transiently evoked otoacoustic emissions using an artificial neural network. *Br J Audiol* 1998;32(Aug (4)):235-247.
- [5] Arnsten O, Koren H, Strom T. Hearing-aid preselection through a neural network. *Scand Audiol* 1996;25(4):259-262.
- [6] Juhola M, Laurikkala J, Viikki K, Kentala E, Pyykko I. Classification of patients on the basis of otoneurological data by using Kohonen networks. *Acta Otolaryngol Suppl* 2001;545:50-52.
- [7] Izvorski A, Tadeusiewicz R, Paślowski A. The Utilization of Context Signals in the Analysis of ABR Potentials by Application of Neural Networks. In: Lopez de Mantras R, Plaza E, editors. *Machine Learning ECML 2000, Lecture Notes in Computer Science*, (Lecture Notes in Artificial Intelligence), nr 1810. Berlin-Heidelberg-New York: Springer Verlag; 2000. p. 195-202.
- [8] Izvorski A, Tadeusiewicz R, Paślowski A. Processing and Classification of Auditory Brainstem Response Signals. In: Mastorakis N, editor. *Advances in Neural Networks and Applications*. WSEAS Press; 2001. ISBN 960-8052-26-2, p. 189-194.
- [9] Strzelczyk P, Wochlik I, Tadeusiewicz R, Izvorski A, Bułka J. Telemedical System in Evaluation of Auditory Brainstem

- Responses and Support of Diagnosis. In: Nguyen NT, Le MT, Swiatek J, editors. *Intelligent Information and Database Systems, Part 2*. Berlin, Heidelberg, New York: Springer Verlag, LNAI 5990; 2010. p. 21-28.
- [10] Davey R, McCullagh P, Lightbody G, McAllister G. Auditory brainstem response classification: A hybrid model using time and frequency features. *Artif Intell in Med* 2007;40:1-14.
- [11] Kaczmarczyk D, Durko M, Kruk A. Przykładowe zastosowanie sztucznej sieci neuronowej Kohonena w otolaryngologii. *Pol Merkur Lekarski* 2005;19(111):383-387.
- [12] Szaleniec J, Wiatr M, Szaleniec M, Składzień J, Tomik J, Stręk P, Tadeusiewicz R, Przeklasa R. Przydatność sieci neuronowych w prognozowaniu pooperacyjnej poprawy słuchu u chorych z przewlekłym zapaleniem ucha środkowego. *Przegląd Lekarski* 2009;66(11):924-929.
- [13] Schoenweiler R, Hess M, Wuebbelt P, Ptok M. Novel approach to acoustical voice analysis using artificial neural networks. *Journal of the Association for Research in Otolaryngology* 2000;01:270-282.
- [14] Linder R, Albers AE, Hess M, Poepl SJ, Schoenweiler R. Artificial neural network-based classification to screen for dysphonia using psychoacoustic scaling of acoustic voice features. *J Voice* 2006;22(2):155-163.
- [15] Ritchings RT, McGillion M, Moore CJ. Pathological voice quality assesment using artificial neural networks. *Medical Engineering and Physics* 2002;24:561-564.
- [16] Szaleniec J. Zastosowanie sieci neuronowych w różnicowaniu mowy patologicznej od fizjologicznej. *Przegląd Lekarski* 2005;62(Suppl).
- [17] Krafczyk S, Tietze S, Swoboda W, Valkovic P, Brandt T. Artificial neural network: A new diagnostic posturographic tool for disorders of stance. *Clinical Neurophysiology* 2006;117:1692-1698.
- [18] Jones AS, Taktak AGF, Helliwell TR, Fenton JE, Birchall MA, Husband DJ, Fisher AC. An artificial neural network improves prediction of observed survival in patients with laryngeal squamous carcinoma. *Eur Arch Otorhinolaryngol* 2006;263:541-547.
- [19] Bryce TJ, Dewhirst MW, Floyd CE, Hars V, Brizel D. Artificial neural network model of survival in patients treated with irradiation with and without concurrent chemotherapy for advanced carcinoma of the head and neck. *Int J Radiation Oncology Biol Phys* 1998;41(2):339-345.
- [20] Drago GP, Setti E, Licitra L, Liberati D. Forecasting the performance status of head and neck cancer patient treatment by an interval arithmetic pruned perceptron. *IEEE Trans Biomed Eng* 2002;49(8):782-787.
- [21] van Staveren HJ, van Veen RLP, Speelman OC, Witjes MJH, Star WM, Roodenburg JLN. Classification of clinical auto fluorescence spectra of oral leukoplakia using an artificial neural network: a pilot study. *Oral Oncology* 2000;36:286-293.
- [22] Dobroś W, Izworski A, Gil K, Lech T. Skuteczność sztucznych sieci neuronowych w przewidywaniu przerzutów do regionalnych węzłów chłonnych. *Otolaryngol Pol* 2001;55(1):43-45.
- [23] Norman RG, Rapoport DM, Ayappa I. Detection of flow limitation in obstructive sleep apnea with an artificial neural network. *Physiol Meas* 2887; 28: 1089-1100.
- [24] Behbehani K, Lopez F, Yen FC, Lucas EA, Burk JR, Axe JP, Kamangar F. Pharyngeal wall vibration detection using an artificial neural network. *Med Biol Eng Comput* 1997;35:193-198.
- [25] el-Solh AA, Mador MJ, Ten-Brock E, Schucard DW, Abul-Khoudoud M, Grant BJ. Validity of neural network in sleep apnea. *Sleep* 1999;22(1):105-111.
- [26] Kuzmanovski I, Ristova M, Soptrajanov B, Stefov V, Popovski V. Determination of the composition of sialoliths composed of carbonate apatite and albumin using artificial neural networks. *Talanta* 2004;62:813-817.
- [27] Tadeusiewicz R. *Sieci neuronowe*. Warszawa: Akademicka Oficyna Wydawnicza; 1995.
- [28] Tadeusiewicz R, Gąciarz T, Borowik B, Leper B. *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*, Wydawnictwo Polskiej Akademii Umiejętności, Kraków 2007.
- [29] Dreiseitl S, Ohno-Machado L. Logistic regression and artificial neural network classification models: a methodology review. *J Biomed Inform* 2002;35:352-359.