

Beata Chrześcijanek¹, Antonina Młynarczyk-Kochanowska²,
Michał Strzelecki², Andrzej Klimek¹, Maciej Rachalewski³

Received: 10.06.2014

Accepted: 27.06.2014

Published: 31.07.2014

Próba zastosowania ilościowej analizy obrazów TK w różnicowaniu guzów i udarów – badanie wstępne

Examination of the application of quantitative analysis of CT brain images in ischaemic stroke and brain tumour detection – preliminary test

¹ Klinika Neurologii i Udarów Mózgu, Uniwersytet Medyczny w Łodzi

² Instytut Elektroniki, Politechnika Łódzka

³ Zakład Diagnostyki i Terapii Radiologicznej i Izotopowej, Szpital Kliniczny im. WAM w Łodzi

Adres do korespondencji: Klinika Neurologii i Udarów Mózgu, Uniwersytet Medyczny w Łodzi, ul. Żeromskiego 113, 90-549 Łódź, tel./faks: +48 42 639 35 91; Zakład Elektroniki Medycznej, Instytut Elektroniki, Politechnika Łódzka, ul. Wólczńska 211/215, budynek B9 (II piętro), 90-924 Łódź, tel.: +48 42 631 26 31, 42 631 26 46

Praca finansowana ze środków własnych

Streszczenie

Wstęp: Neuroobrazowanie jest standardowym badaniem stosowanym w diagnostyce ośrodkowego układu nerwowego (OUN). Podstawowymi narzędziami diagnostycznymi w obrazowaniu OUN są tomografia komputerowa (TK) oraz rezonans magnetyczny. W przypadku wystąpienia nagłych ogniskowych lub uogólnionych objawów neurologicznych należy w pierwszej kolejności podejrzewać udar mózgu. Obecnie badaniem pierwszego rzutu w diagnostyce neuroradiologicznej jest badanie TK. W przedstawionej pracy podjęto próbę sprawdzenia, czy jest możliwa ilościowa analiza obrazów TK, pozwalająca odróżnić zmiany rozrostowe OUN od udarów niedokrwiennych. **Materialy i metody:** Analizę oparto na porównaniu dwóch patologii OUN: udaru niedokrwiennego oraz zmiany rozrostowej. Ocenie poddano obrazy TK mózgowia, na których wyodrębniono zmianę patologiczną. Podczas kolejnych etapów pracy przeprowadzono: konwersję danych, definiowanie obszarów zainteresowania (ROI), estymację cech tekstury, selekcję cech z zastosowaniem czterech różnych metod oraz klasyfikację opartą na sztucznej sieci neuronowej. **Wyniki:** Odnotowano różną skuteczność zastosowanych metod, co dało podstawę do stwierdzenia, że ilościowa analiza wybranych cech tekstury obrazu pozwala odgraniczyć klasy przypisane do omawianych patologii, natomiast użycie sztucznych sieci neuronowych do klasyfikacji danych wskazuje na ich skuteczność i przydatność jako narzędzi stosowanych w analizie wybranych danych. **Podsumowanie:** W sytuacji gdy badanie neuroradiologiczne nie wypada jednoznacznie, a leczenie udaru i guza mózgu różnią się diametralnie, istnieje możliwość zastosowania przedstawionej analizy w celu skrócenia czasu potrzebnego do postawienia właściwej diagnozy. Przedstawione wyniki mają jednak charakter wstępny i wymagają dalszej analizy na większej grupie pacjentów.

Słowa kluczowe: udar niedokrwienny, guz, neuroobrazowanie, sztuczna sieć neuronowa, perceptron wielowarstwowy, tomografia komputerowa

Summary

Introduction: Neuroimaging is a standard examination implemented for diagnosis of various pathologies of the central nervous system. The fundamental diagnostic procedures in medical imaging of the central nervous system are computed tomography and magnetic resonance imaging. In case of a sudden focal or generalized onset of brain dysfunctions at first we should think about stroke. A very important test if stroke is suspected is computed tomography. In this paper we would like to check if it is possible to distinguish two pathologies of the cerebrum: ischaemic stroke and tumour, using quantitative analysis of selected abnormalities. **Material and methods:** Analysis is based on comparison of two pathologies (ischaemic stroke and tumour). Two sets of images were prepared. Analysis is performed to distinguish abnormalities observed on computed tomography brain images from healthy tissue. The image analysis includes data conversion, normalization of region of interest, estimation of the number of texture features, features selection based on four different methods of selection and finally classification based on artificial neural network classifier. **Results:** In the examination, different effectiveness of used methods was observed. Quantitative analysis of selected texture features allows to differentiate two classes of pathologies. Also an important observation is that the artificial neural network can be a useful tool in data classification and analysis. **Conclusions:** The performed analysis is effective but only for small number of data. That is why it still needs to be conducted on a larger set of data. It will be also necessary to repeat classification a number of times and to perform data validation in order to confirm effectiveness of the presented method. After that we can hope to get really satisfying results.

Key words: ischaemic stroke, tumour, neuroimaging, artificial neural network, multilayer perceptron, computed tomography

WSTĘP

Gdy zaczęto stosować obrazowanie m.in. mózgu za pomocą wielorzędowej tomografii komputerowej (TK), diagnostyka neurologiczna uległa całkowitemu przeobrażeniu. Można powiedzieć, że był to jeden z kroków milowych. Znalezione bowiem narzędzie badawcze, które pozwoliło skrócić czas od momentu wystąpienia objawów klinicznych do ustalenia rozpoznania (przede wszystkim w zakresie chorób naczyniowych i rozrostowych mózgowia). Obecnie TK jest badaniem pierwszego rzutu w diagnostyce neuroradiologicznej. Dzięki dużej dostępności aparatów TK można wykonać szybkie badanie praktycznie tuż po przybyciu pacjenta do szpitala. Co ważniejsze, jednofazowe badanie TK bez użycia środka kontrastowego ma niewiele przeciwwskazań medycznych i może być wykonane praktycznie u każdego chorego bez konieczności jego wcześniejszego przygotowania.

Kolejnym ważnym narzędziem diagnostycznym jest technika rezonansu magnetycznego (MRI), która umożliwia lepsze różnicowanie tkanek miękkich. Badanie MRI jest lepsze niż badanie TK w obrazowaniu udaru mózgu we wczesnej fazie (<6 h), jest również czulsze i bardziej swoiste w obrazowaniu zmian rozrostowych mózgu. Daje możliwość uzyskiwania obrazów w wielu płaszczyznach. Wielopłaszczyznowość nie tylko potwierdza zewnątrz- lub wewnątrzosiowe umiejscowienie zmiany, ale również ułatwia ocenę stosunków anatomicznych. Jednak z uwagi na niewielką dostępność aparatów MRI oraz koszt badania jest to metoda drugiego rzutu. Kolejne ograniczenie wynika z przeciwwskazań medycznych do badania

z użyciem pola magnetycznego. Dotyczą one pacjentów z: rozrusznikiem serca, neurostimulatorami, klipsami metalowymi wewnątrzczaszkowymi, pompą insulinową, wszczepionym aparatem słuchowym, metalicznym ciałem w oku oraz innymi przeciwwskazaniami.

Rozpoczynając diagnostykę nagłego połowicznego niedowładu, najbardziej liczymy się z udarem mózgu. Według Światowej Organizacji Zdrowia (WHO) udar mózgu definiowany jest jako nagłe wystąpienie ogniskowego lub globalnego zaburzenia czynności mózgu, trwającego dłużej niż 24 godziny i wynikającego głównie z przyczyn naczyniowych. Udar mózgu jest niejednorodną grupą chorób naczyń mózgowych, które dzielą się na: udary niedokrwienne (około 80%), udar krwotoczny (około 15%) oraz krwawienie podpajęczynówkowe (około 5%). W przypadku udaru niedokrwiennego w ciągu pierwszych 24 godzin czułość TK jest mała, odsetek właściwych rozpoznań szacuje się na 60%, ale wzrasta on w kolejnych dobach, sięgając praktycznie 100% po 7 dniach od wystąpienia objawów. W niektórych przypadkach wynik badania TK nie jest jednoznaczny – obraz radiologiczny nie koreluje z rozpoznaniem klinicznym. Poza tym udar jest procesem dynamicznym, w czasie którego dochodzi do odczynu zapalnego, czego efektem może być obrzęk mózgowia. Zdarza się również, że wspomniany obrzęk przyjmuje w TK obraz „palczasty” i nasuwa podejrzenie guza. Jest to szczególna postać udaru, tzw. maska nowotworowa udaru niedokrwiennego⁽¹⁻³⁾.

W przypadku wystąpienia nagłego niedowładu należy również brać pod uwagę możliwość guza mózgu. Objawy neurologiczne w tym przypadku wynikają z obecności nieprawidłowej „masy”. Są skutkiem wzmożonego ciśnienia

śródczaszkowego, będącego konsekwencją ograniczonych możliwości wzrostu nieprawidłowej tkanki w obrębie mózgowia, tworzą ponadto zespół objawów wynikających bezpośrednio z uszkodzenia określonych struktur. Obecność masy patologicznej powoduje występowanie w TK i MRI charakterystycznych objawów należących do kryteriów rozpoznania procesu rozrostowego. Zaliczamy do nich: obecność obszaru o nieprawidłowej gęstości/sygnale, obrzęk, granice guza, wzmocnienie nacieku po podaniu środka kontrastującego, przemieszczenie struktur otaczających, zmniejszanie rezerwy wewnątrzczaszkowej. Powyższy obraz badania radiologicznego może jednak występować nie tylko w przypadku procesu rozrostowego i często budzi wątpliwości⁽⁴⁾.

Jedno i drugie rozpoznanie stanowi zagrożenie życia – czas jest czynnikiem decydującym o rozpoczęciu skutecznego leczenia udaru bądź guza mózgu. Dlatego tak ważna od początku jest właściwa diagnoza. Zdarzają się sytuacje, w których wykonane badanie TK nie rozwiewa wątpliwości i proces diagnostyczny musi być kontynuowany. W takich przypadkach bardzo często powtarza się badanie TK, aby podać środek kontrastowy bądź ocenić progresję obrazu w czasie. Naraża to jednak pacjenta na kolejną dawkę promieniowania rentgenowskiego, które przecież nie jest obojętne dla organizmu. Wydłużenie procesu diagnostycznego sprawia, że pacjent nie otrzymuje właściwej terapii, co w efekcie szkodzi zdrowiu. Przedstawiona poniżej metoda ma umożliwić błyskawiczną ocenę i zróżnicowanie wyniku badania TK pomiędzy uszkodzeniem naczyniowym a procesem rozrostowym mózgowia, a przede wszystkim potwierdzić jedno z tych rozpoznań. W tym celu została przeprowadzona wstępna analiza obrazów uzyskanych w jednofazowym badaniu TK głowy u pacjentów z pewnym rozpoznaniem udaru niedokrwiennego oraz guza mózgu.

W dostępnej literaturze autorzy nie znaleźli prac dotyczących diagnostyki różnicowej guza mózgu i udaru niedokrwiennego za pomocą ilościowej analizy obrazów TK. Amutha Devi i Rajagopalan przedstawiają metodę opartą na badaniu MRI głowy w sekwencji DWI, która miała na celu potwierdzenie bądź wykluczenie udaru mózgu. Do analizy użyto sztucznej sieci neuronowej o architekturze wielowarstwowego perceptronu (*multilayer perceptron*, MLP), dla której przeprowadzono wielokrotnie proces uczenia sieci, aby dokonać prawidłowej klasyfikacji danych jako „udar” i „nie udar”. Następnie dokonano analizy na grupie 52 pacjentów, z których 25 zaklasyfikowano jako „udar”. We wszystkich przypadkach rozpoznanie zostało potwierdzone przez specjalistę radiologa⁽⁵⁾.

W innym doniesieniu Kharat i wsp. podjęli próbę klasyfikacji guzów mózgu na dwie kategorie: zmiany łagodne i złośliwe. Na podstawie obrazów MRI określono granice guza, a następnie dla tych wyodrębnionych obszarów przeprowadzono proces uczenia sztucznej sieci neuronowej. W pracy przedstawiono jedynie wstępne rezultaty. Nie podano informacji, na jakiej grupie pacjentów została

przeprowadzona analiza. Uzyskane wyniki pozwalały zakwalifikować wynik badania MRI jako guz lub prawidłowy obraz, nie rozstrzygając, czy w tym pierwszym przypadku mamy do czynienia ze zmianą łagodną czy złośliwą⁽⁶⁾.

MATERIAŁ I METODY

Przeprowadzenie analizy wymagało zebrania odpowiednich materiałów. W pracy wykorzystano obrazy uzyskane w badaniu TK opartej na technice rentgenowskiej, co umożliwiło otrzymanie obrazów (przekrojów) badanych tkanek (w tym wypadku mózgu). Przekroje są uzyskiwane w różnych projekcjach: przekrojowych – 2D oraz przestrzennych – 3D. W trakcie poniższej analizy wykorzystano obrazy mózgu 2D. Podział obrazu na przekroje pozwala na dokładniejszą analizę zmiany patologicznej dzięki wykorzystaniu parametrów tekstury obrazu. Wyniki badania TK zostały zapisane w standardzie DICOM (*Digital Imaging and Communication in Medicine*)⁽⁷⁾, a następnie przekonwertowane do formatu RAW (obejmującego tylko dane, bez informacji o parametrach obrazu oraz o pacjencie) za pomocą programu K-PACS V1.6.0⁽⁸⁾.


Analizowane obrazy podzielono na dwie grupy. Pierwsza obejmowała zmiany określone przez neurologa jako guz, w drugiej diagnozowano udary mózgu. Badania zostały przeprowadzone u 12 pacjentów; w przypadku pięciu wykryto udar, zaś u siedmiu – guz mózgu. Tabela 1 przedstawia zestawienie liczby przekrojów zawierających zmianę patologiczną uzyskanych podczas obrazowania TK przeprowadzonego dla konkretnego pacjenta. Łącznie przeanalizowano 31 przekrojów dla obrazów udarów oraz 38 przekrojów pokazujących przypadki guza.

Na każdym przekroju za pomocą programu MaZda^(9,10) neurolog wyznaczył obszary zainteresowania (*regions of interest*, ROIs)⁽¹¹⁾.

Badanie TK przeprowadzono w Uniwersyteckim Szpitalu Klinicznym im. WAM w Łodzi. Protokół badania został ustalony przez technika radiologa oraz lekarza neurologa. Obrazy poddane analizie pochodziły z badania jednofazowego (w badaniu nie zastosowano środka kontrastującego, który poprawia widoczność zmian patologicznych).

Numer pacjenta	Seria 1.: Udar	Seria 2.: Guz
1	9	4
2	6	4
3	3	10
4	6	3
5	7	6
6	-	3
7	-	8

Tabela 1. Liczba przekrojów przypadająca na pacjenta w każdej serii danych

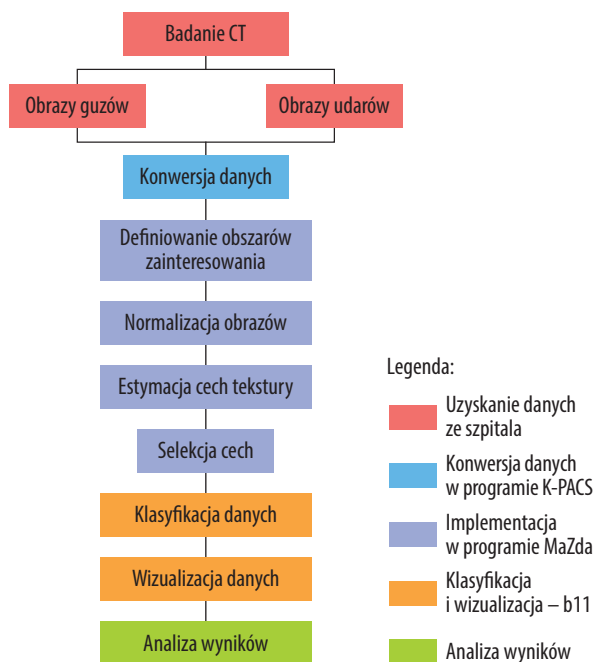


Rys. 1. Przykładowe przekroje z zaznaczonymi ROI obejmującymi dwie analizowane zmiany patologiczne: guz (A) oraz udar (B)

Na rys. 1 przedstawiono przykładowe przekroje analizowanych obrazów z zaznaczonymi obszarami zainteresowania.

Schemat blokowy przedstawiający poszczególne etapy analizy obrazów (zaznaczone różnymi kolorami) został pokazany na rys. 2.

Po konwersji obrazów do formatu RAW oraz zaznaczeniu obszarów zainteresowania zostały one poddane dalszej analizie z wykorzystaniem programu MaZda^(9,10). Rozmiar wyznaczonych ROI zależy od wielkości zmiany widocznej na poszczególnym przekroju. Program ten umożliwia wykonanie normalizacji analizowanych obrazów (co pozwala na niezależnienie wyników analiz od różnic jasności i kontrastu tych obrazów).



Rys. 2. Schemat blokowy poszczególnych etapów analizy obrazów

Zmiana patologiczna w zaznaczonym ROI charakteryzuje się określoną teksturą – złożonym rozkładem jasności, proporcjonalnym do tłumienia promieniowania rentgenowskiego dla danego obszaru mózgu. Właściwości tekstury odwzorowują rzeczywistą strukturę zmian patologicznych mózgu uwidocznionych w obrazowaniu TK. Tekstura jest opisywana ilościowo za pomocą szeregu parametrów matematycznych, które umożliwiają numeryczny opis odwzorowywanych przez nią zmian oraz ich klasyfikację. Zastawienie parametrów tekstury oraz ich opis przedstawiono we wcześniejszej pracy Zielińskiego i Strzeleckiego⁽¹²⁾. W przypadku prowadzonych analiz wyznaczono cechy z wykorzystaniem macierzy zdarzeń⁽¹⁰⁾, długości ciągów⁽¹³⁾, gradientu⁽¹⁰⁾ oraz transformacji falkowej⁽¹⁰⁾. Łącznie wyznaczono około 300 parametrów. Liczba ta jest zbyt duża do przeprowadzenia skutecznej klasyfikacji – budowa wiarygodnego klasyfikatora wymagałaby bardzo dużej liczby próbek, ponadto zwykle tylko niewielka liczba cech posiada wartość dyskryminacyjną. W celu ograniczenia liczby cech i znalezienia tych najbardziej przydatnych z punktu widzenia klasyfikacji badanych patologii zastosowano metody selekcji cech, z których jedną z bardziej skutecznych okazała się metoda wykorzystująca kryterium Fishera. Współczynnik Fishera (F) opisany jest następującym wzorem⁽¹⁴⁾:

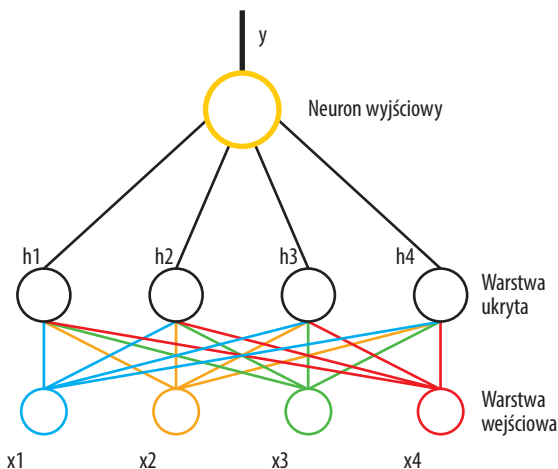
$$F = \frac{D}{V} = \frac{1}{1 - \sum_{k=1}^K P_k^2} \frac{\sum_{k=1}^K \sum_{j=1}^K P_k P_j (\mu_k - \mu_j)^2}{\sum_{k=1}^K P_k V_k}$$

Jest to iloraz wartości rozproszenia pomiędzy klasami (D) oraz wariancji wewnątrzklasowej (V) gdzie μ_j jest wartością średnią danej cechy dla klasy j, V_j – wariancją cechy dla tej klasy j oraz P_j – prawdopodobieństwem wystąpienia danej klasy, czyli stosunkiem liczby próbek reprezentujących tę klasę do liczby wszystkich próbek⁽¹⁵⁾. Im większa różnica wartości średnich cechy dla różnych klas, tym większe rozproszenie międzyklasowe i większa wartość współczynnika F. Podobnie wartość

tego współczynnika rośnie dla cech charakteryzujących się małym rozrzutem wartości (wariancją). Im większa wartość F , tym lepiej dana cecha dyskryminuje analizowane klasy. Zastosowanie tego kryterium do selekcji cech polega na wyznaczeniu współczynnika F dla każdego parametru i wyborze tych cech, dla których F ma wartości największe.

Po dokonaniu selekcji cech można przystąpić do ostatniego etapu analizy, którym jest klasyfikacja. Polega ona na przypisaniu wektorów cech opisujących teksturę obrazu zmiany patologicznej do jednej z dwóch klas obejmujących guzy i udary. Do klasyfikacji zastosowano algorytmy wykorzystujące sztuczną sieć neuronową^(14,15) oraz metodę najbliższego sąsiada (*one nearest neighbour classifier*, 1-NN)⁽¹⁵⁾.

Aby wykorzystać sztuczną sieć neuronową, należy zaprojektować jej architekturę. To na jej podstawie przeprowadzana jest klasyfikacja. Sztuczne sieci neuronowe bazują swoją budową na strukturze naturalnych neuronów. Imitują uproszczony model przetwarzania sygnału układu nerwowego. Ich zdolność uczenia znajduje zastosowanie w wielu dyscyplinach⁽¹⁶⁾. W powyższej analizie została wykorzystana sieć o architekturze wielowarstwowego perceptronu (*multilayer perceptron*, MLP). Taka sieć składa się z trzech warstw, których podstawowym elementem jest neuron. Każdy neuron sumuje dane wejściowe przemnożone przez odpowiednie współczynniki (wagi), a następnie przetwarza uzyskany wynik za pomocą funkcji swojej aktywacji (zwykle nieliniowej), uzyskując wartość na swoim wyjściu. Neuron sieci jest uproszczonym modelem rzeczywistej komórki neuronowej, dane wejściowe są sygnałem pobudzającym, sygnał ten po przetworzeniu generuje odpowiedź neuronu⁽¹⁶⁾. Kolejno, z warstwy do warstwy, obliczane są sygnały liniowej oraz nieliniowej części neuronu. Informacja będąca wyjściem dla pierwszej warstwy staje się sygnałem wejściowym dla następnej warstwy itd. Schemat budowy sieci użytej podczas analizy przedstawiono na rys. 3.



Rys. 3. Schemat jednej z sieci neuronowych wykorzystanych podczas analizy danych

Schemat przedstawia przykład jednej ze struktur sieci użytych podczas analizy klasyfikatorem ANN. W efekcie zostały zastosowane cztery różne struktury. Każda z nich różniła się liczbą neuronów w warstwie ukrytej oraz liczbą wejść. Liczba neuronów w warstwie wejściowej zależy od liczby cech (liczby elementów wektora x , równej 4 na rys. 3) poddawanych analizie. W prowadzonych badaniach wykorzystano 3 lub 4 wcześniej wyselekcjonowane cechy najlepiej dyskryminujące badane obrazy. Dane te są przesyłane do warstwy ukrytej. Zadaniem neuronów tej warstwy jest wyznaczanie granic decyzyjnych w przestrzeni cech wejściowych pomiędzy badanymi klasami. Im większa liczba tych neuronów, tym skuteczniej można różnicować złożone rozkłady cech dla poszczególnych klas. Z drugiej strony zbyt dokładne wyznaczenie granicy pomiędzy badanymi klasami ogranicza zdolność sieci do uogólniania wyników, tzn. podanie na jej wejście nowych próbek danych (nieuwzględnionych w etapie uczenia) może doprowadzić do ich błędnej klasyfikacji, gdyż sieć nauczy się dokładnego rozdzielania tylko danych ze zbioru uczącego. Z tego powodu dobór liczby neuronów warstwy ukrytej jest bardzo istotny dla przeprowadzenia poprawnej analizy danych. Zadaniem neuronu wyjściowego (y) jest podjęcie decyzji o przynależności podanego na wejście wektora cech do jednej z klas. Decyzja ta jest wypracowywana na podstawie odpowiedzi neuronów warstwy ukrytej (h_1 – h_4 na rys. 3). Dla wektora cech opisujących guz neuron wyjściowy przyjmuje wartość 0, zaś dla przypadku udaru $y = 1$.

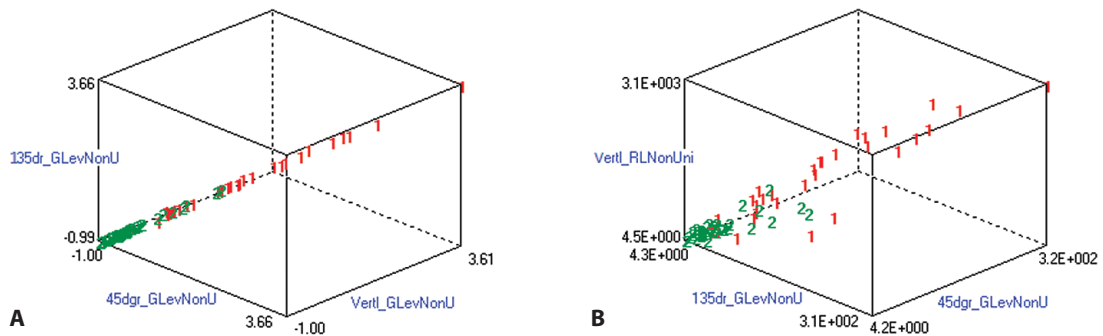
WYNIKI I OMÓWIENIE

Klasyfikacja danych została przeprowadzona dla czterech różnych metod selekcji cech przy użyciu dwóch klasyfikatorów. Analizy przeprowadzono za pomocą programu b11, który stanowi część pakietu MaZda⁽⁹⁾. Najlepsze wyniki uzyskano dla metody selekcji wykorzystującej współczynnik Fishera. W tabeli 2 zostały przedstawione wartości błędu klasyfikacji otrzymanego po analizie klasyfikatorem najbliższego sąsiedztwa.

Jak widać w tabeli 2, lepsze rezultaty uzyskuje się, gdy analiza jest przeprowadzona dla większej liczby cech. Zwiększa to dokładność klasyfikacji, zmniejszając błąd. Rozkłady cech wykorzystanych do klasyfikacji pokazano na rys. 3. Każdy element tego rysunku (cyfra 1 lub 2) reprezentuje wektor cech użytych do klasyfikacji (wyznaczone dla badanych obszarów zainteresowania,

Klasyfikator	1-NN			
Metoda selekcji	Fisher			
Liczba cech	4 cechy		3 cechy	
Błąd klasyfikacji	%	Liczbowy	%	Liczbowy
	20,29	14	26,09	18

Tabela 2. Wyniki klasyfikacji uzyskane dla klasyfikatora 1-NN



Rys. 3. Rozkłady klas guzów (jedynki) oraz udarów (dwójki) w dwóch różnych trójwymiarowych przestrzeniach cech wybranych zgodnie z kryterium Fishera

Klasyfikator	MLP							
Metoda selekcji	Kryterium Fishera							
Liczby cech/neuronów warstwy ukrytej	3/3		3/4		4/3		4/4	
Błąd klasyfikacji	%	Liczbowy	%	Liczbowy	%	Liczbowy	%	Liczbowy
Wartość minimalna	8,7	6	8,7	6	4,3	3	2,9	2
Wartość maksymalna	10,1	7	13,0	9	8,7	6	7,2	5
Wynik uśredniony	9,4	7	10,9	8	6,5	5	5,1	4

Tabela 3. Wyniki klasyfikacji uzyskane dla sztucznej sieci neuronowej (ANN)

1 reprezentuje guz, zaś 2 – udar. Rysunek pokazuje rozkład dwóch badanych klas (udarów i guzów) w różnych przestrzeniach cech wejściowych (rys. 3 A, B) wybranych zgodnie z kryterium Fishera. Można zaobserwować, że część cech, reprezentujących różne klasy, nachodzi na siebie, co uniemożliwia poprawną klasyfikację. Mniejszy błąd klasyfikacji uzyskano dla czterech cech wejściowych, jednak nawet wtedy wynosi on ponad 20%. Wynik ten pokazuje, że klasyfikator 1-NN nie zapewnia prawidłowych wyników klasyfikacji i nie może służyć jako narzędzie do różnicowania obrazów guzów i udarów.

Dlatego zbadano również klasyfikator zbudowany z wykorzystaniem sieci MLP. Klasyfikator ten umożliwia zwykle uzyskanie mniejszych błędów klasyfikacji ze względu na możliwości tworzenia obszarów decyzyjnych o złożonych kształtach, zależnych od liczby neuronów warstwy ukrytej sieci oraz funkcji aktywacji neuronów. Sieć dokonuje klasyfikacji danych w wyniku procesu uczenia, podczas którego ustalane są wartości wag połączeń pomiędzy neuronami w taki sposób, aby zminimalizować błąd klasyfikacji. Uczenie sieci przeprowadzono dla czterech różnych przypadków obejmujących różne liczby cech wejściowych oraz neuronów warstwy ukrytej⁽¹⁶⁾. Dla każdej struktury sieci proces uczenia przeprowadzono pięciokrotnie, a uzyskane wyniki klasyfikacji uśredniono. Najlepsze rezultaty otrzymano w wyniku wykorzystania czterech cech oraz czterech neuronów

w warstwie ukrytej. Uzyskane wyniki pokazano w tabeli 3, gdzie podano minimalne, maksymalne oraz średnie wartości błędu klasyfikacji uzyskane w pięciu procesach uczenia sieci. Z danych przedstawionych w tej tabeli widać, że błąd klasyfikacji maleje dla większej liczby cech oraz neuronów warstwy ukrytej. Z drugiej strony zwiększanie liczby tych elementów prowadzi do zwiększenia liczby wag sieci i w konsekwencji do utraty zdolności uogólniania wyników klasyfikacji (przy założeniu określonej liczby analizowanych przypadków). Oznacza to, że sieć bardzo poprawnie będzie analizować dane dostępne w procesie uczenia, natomiast może generować błędne wyniki w przypadku pojawienia się kolejnych, nowych przypadków zmian patologicznych mózgu. Obecna struktura sieci (cztery cechy, cztery neurony warstwy ukrytej) umożliwia zachowanie przez sieć zdolności generalizacji danych⁽¹⁶⁾. Porównując wyniki dla obu klasyfikacji, można zauważyć, że również w przypadku sieci MLP najlepsze wyniki uzyskano dla czterech cech. Z kolei wyniki klasyfikacji uzyskano zdecydowanie lepsze. Średni błąd klasyfikacji nie przekracza 7% przy ponad 20% dla klasyfikatora 1-NN. Zatem zwiększając liczbę neuronów w warstwie ukrytej, można dodatkowo zmniejszyć błąd klasyfikacji. Uzyskane wyniki pozwalają przypuszczać, że struktura sieci obejmująca cztery cechy wejściowe oraz cztery neurony w warstwie ukrytej jest optymalna z punktu widzenia prawidłowej klasyfikacji analizowanych danych.

Liczba analizowanych próbek	Wyniki klasyfikacji			
	Cztery cechy, cztery neurony		Cztery cechy, trzy neurony	
	Guz	Udar	Guz	Udar
Guz (38)	37	1	36	2
Udar (31)	1	30	2	29
Suma	38	31	38	31

Tabela 4. Zestawienie liczby próbek sklasyfikowanych jako guzy i udary

Ostatnim etapem badań była analiza wyników klasyfikacji potrzebna do stwierdzenia, czy próbki którejs klasy cechują się większym błędem klasyfikacji. Dane te zostały zestawione w tabeli 4, która pokazuje wyniki klasyfikacji dla poszczególnych klas oraz liczbę błędów popełnianych przez sieć dla każdej klasy. Pokazano, ile próbek dla danej klasy jest dyskryminowanych poprawnie dla dwóch struktur sieci zapewniających najmniejszy średni błąd klasyfikacji.

Analiza danych z tabeli 4 pokazuje, że rozkład błędów klasyfikacji dla przypadków guzów i udarów jest zbliżony, czyli proponowana metoda nie wykazuje preferencji dla lepszej oceny któregoś z przypadków.

Praca ma charakter wstępny i wymaga zastosowania walidacji sieci neuronowej (zbadania, czy równie prawidłowo będą klasyfikowane inne dane pochodzące spoza zbioru uczącego) oraz dalszej weryfikacji przy wykorzystaniu większej liczby danych (obrazów zmian patologicznych mózgu).

PODSUMOWANIE

W sytuacji gdy badanie neuroradiologiczne nie wypada jednoznacznie, a leczenie udaru i guza różnią się diametralnie, istnieje możliwość zastosowania opisanej metody w celu skrócenia czasu potrzebnego na właściwą diagnozę. Autorzy mają nadzieję, że proponowana metoda spełni ich oczekiwania w tzw. przypadkach wątpliwych. Uważają, że jest ona w stanie ograniczyć liczbę pomyłek diagnostycznych przy badaniu neuroradiologicznym. Przedstawione wyniki wymagają dalszej analizy na większej grupie pacjentów.

PIŚMIENNICTWO:

BIBLIOGRAPHY:

1. Biller J., Love B.: Choroby naczyniowe układu nerwowego. W: Bradley W.G., Daroff R.B., Fenichel G.M., Jankovic J. (red.): Neurologia w praktyce klinicznej. Zasady diagnostyki i postępowania. Tom II, Czelej, Lublin 2006: 1429–1434.
2. Ryglewicz D.: Epidemiologia udarów mózgu. W: Szczudlik A., Członkowska A., Kwieciński H., Słowik A. (red.): Udar mózgu. Wydawnictwo Uniwersytetu Jagiellońskiego, Kraków 2007: 85–95.
3. Sobotko-Waszczeniuk O., Łukasiewicz A., Pyd E. i wsp.: Differentiation of density of ischaemic brain tissue in computer tomography with respect to neurological deficit in acute and subacute period of ischaemic stroke. Pol. J. Radiol. 2009; 74: 30–36.
4. Studniarek M. (red.): Radiologia – diagnostyka obrazowa, część II. Akademia Medyczna w Gdańsku, Gdańsk 2001: 69–80.
5. Amutha Devi C., Rajagopalan S.P.: Brain stroke classification based on multi-layer perceptron using watershed segmentation and Gabor filter. J. Theor. Appl. Inf. Technol. 2013; 56: 410–416.
6. Kharat K.D., Kulkarni P.P., Nagori M.B.: Brain tumor classification using neural network based methods. International Journal of Computer Science and Informatics 2012; 1: 85–90.
7. DICOM – Imaging and Communication in Medicine. Adres: <http://medical.nema.org> [cytowany 18 września 2014 r.].
8. DICOM Viewing Software. Adres: <http://www.k-pacs.de> [cytowany 18 września 2014 r.].
9. Szczypiński P.M., Strzelecki M., Materka A., Klepaczko A.: MaZda – a software package for image texture analysis. Comput. Methods Programs Biomed. 2009; 94: 66–76.
10. Materka A.: MaZda User's Manual. Adres: www.elel.p.lodz.pl/programy/mazda/download/mazda_manual.pdf [cytowany 18 września 2014 r.].
11. Hajek M., Dezortova M., Materka A., Lerski R. (red.): Texture Analysis for Magnetic Resonance Imaging. Med4publishing, 2006.
12. Zieliński K.W., Strzelecki M.: Komputerowa analiza obrazów biomedycznych. Wstęp do morfometrii i patologii ilościowej. Wydawnictwo Naukowe PWN, Warszawa – Łódź 2002.
13. Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R. (red.): Biocybernetyka i inżynieria biomedyczna 2000. Tom 6: Sieci neuronowe. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
14. Schürmann J.: Pattern Classification. A Unified View of Statistical and Neural Approaches. John Wiley & Sons, New York 1996.
15. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe. Podstawy i zastosowania. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
16. Tadeusiewicz R., Korbicz J., Rutkowski L., Duch W.: Inżynieria biomedyczna – podstawy i zastosowania. Tom 9: Sieci neuronowe w inżynierii biomedycznej. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2013.

Szanowni Autorzy!

Uprzejmie przypominamy, że zgodnie z rozporządzeniem Ministra Zdrowia z dn. 6 października 2004 roku w sprawie sposobów dopełnienia obowiązku doskonalenia zawodowego lekarzy i lekarzy dentyistów publikacja artykułu w czasopiśmie „AKTUALNOŚCI NEUROLOGICZNE” – indeksowanego w Index Copernicus – umożliwia doliczenie 20 punktów edukacyjnych za każdy artykuł do ewidencji doskonalenia zawodowego. Podstawą weryfikacji jest notka bibliograficzna z artykułu.