



Zastosowanie sieci neuronowej do optymalizacji czasu analizy obrazów MR na podstawie krzywych czasów relaksacji T1 i T2 wycinka guza prostaty

The use of a neural network to optimize the time of MR image analysis based on the T1 and T2 relaxation time curves of prostate tumor section

David Aebisher¹, Adrian Truszkiewicz¹, Michał Osuchowski², Łukasz Wojtas³, Klaudia Dynarowicz⁴, Dorota Bartusik-Aebisher⁵

¹Zakład Fotomedycyny i Chemii Fizycznej, Kolegium Nauk Medycznych, Uniwersytet Rzeszowski, Al. mjr. W. Kopisto 2a, 35-959 Rzeszów, atruszkiewicz@ur.edu.pl

²Uniwersytecki Szpital Kliniczny im. Fryderyka Chopina w Rzeszowie, ul. Fryderyka Szopena 2, 35-055 Rzeszów

³Kliniczny Szpital Wojewódzki nr 2 im. św. Jadwigi Królowej w Rzeszowie, ul. Lwowska 60, 35-301 Rzeszów

⁴Przyrodniczo-Medyczne Centrum Badań Innowacyjnych, Kolegium Nauk Medycznych, Uniwersytet Rzeszowski, ul. Warzywna 1A, 35-310 Rzeszów

⁵Zakład Biochemii i Chemii Ogólnej, Instytut Nauk Medycznych, Kolegium Nauk Medycznych, Uniwersytet Rzeszowski, ul. Warzywna 1A, 35-310 Rzeszów

Streszczenie

Abstract

Sztuczne sieci neuronowe stanowią jedną z najszybciej rozwijających się metod przetwarzania danych. W diagnostyce obrazowej znajdują one zastosowania do analiz obrazów uzyskiwanych w różnych systemach diagnostycznych. Rezonans magnetyczny wydaje się być najbardziej obiecującym źródłem danych ze względu na różnorodność uzyskiwanych obrazów. W niniejszej pracy została zaprezentowana metoda analizy i segmentacji obrazu na podstawie kształtu funkcji opisującej zależności intensywności sygnału od czasów repetycji (TR) oraz czasu echa (TE). W pierwszym przypadku krzywa opisywała zmienność sygnału dla określania czasu relaksacji podłużnej (T1), natomiast w drugim krzywa odpowiadała relaksacji poprzecznej (T2). W pierwszej części pracy zaprezentowano wyniki analizy obrazu fantomu składającego się z trzech probówek zawierających różne wodne roztwory CuSO_4 . Druga część to próba zastosowania metody do badania wycinków tkanek nowotworowych prostaty. Do analiz wykorzystano pakiet programowy MATLAB (prod. *The MathWorks*). Zaimplementowano w nim zarówno odczyt danych bezpośrednio z plików DICOM, jak również zaproponowaną sieć neuronową. Za wykorzystaniem tegoż oprogramowania przeznawiały ogromne możliwości pakietu, jak również względna łatwość implementacji kodu.

We wnioskach zapisano, iż zaproponowana sieć neuronowa w sposób zadowalający dokonała segmentacji obrazu. Zastosowanie sieci neuronowej wydatnie skróciło obliczenia z uwagi na pominięcie pikseli obrazujących przestrzenie upowietrznione. Ograniczeniu uległy również elementy obrazu prezentujące całkowicie fałszywe wartości czasów relaksacji, a więc artefakty.

Artificial neural networks are one of the fastest growing image processing methods. In diagnostic imaging, they are finding applications for analyzing images obtained by various diagnostic systems. Magnetic resonance imaging (MRI) seems to be the most promising source of data - images due to the variety of images obtained. This paper presents a method of image analysis and segmentation based on the shape of a function describing the dependence of signal intensity on repetition times (TR) and echo times (TE). In the first case, the curve described the signal variation for determining the longitudinal relaxation time (T1), while in the second case the curve corresponded to transverse relaxation (T2). The first part of the paper presents the results of image analysis of a phantom consisting of three test tubes containing different aqueous CuSO_4 solutions. The second part is an attempt to apply the method to the examination of prostate cancer tissue *ex vivo*. The MATLAB software package by The MathWorks was used for the analyses. It implemented both the reading of data directly from DICOM files and the proposed neural network. The huge capabilities of the package as well as the relative ease of code implementation were in favor of using the software.

In conclusion, it should be said that the proposed neural network satisfactorily performed image segmentation. The use of the neural network significantly shortened the calculations due to the omission of pixels depicting aerated spaces. Also reduced were the image elements presenting completely falsified values of relaxation times and thus artifacts.

Słowa kluczowe: MATLAB, T1, T2, czasy relaksacji, MR

Key words: MATLAB, T1, T2, relaxation times, MR

otrzymano / received:

04.06.2023

poprawiono / corrected:

07.06.2023

zaakceptowano / accepted:

09.06.2023



Wprowadzenie

Rezonans magnetyczny (MR) jest w dzisiejszym czasie podstawowym narzędziem pozwalającym na prowadzenie szeroko rozumianych badań. Zarówno w medycynie, jak i innych naukach zjawisko to oddaje nieocenione usługi w obrazowaniu struktur i czynności badanych organizmów. Tę wszechstronność światu nauki zawdzięcza zjawisku relaksacji. Dzisiaj relaksometria stanowi doskonałe narzędzie do prowadzenia badań i pozyskuje coraz to nowe obszary. Światowi producenci systemów MR dokładają wszelkich starań, aby ich systemy były wydajne. Jest to podkrywane faktem, iż w procesie diagnozowania i leczenia pacjenta czas jest bardzo ważnym czynnikiem. Sztuczna inteligencja coraz częściej jest wykorzystywana w tworzeniu obrazu na podstawie danych numerycznych. Wymaga to zarówno wydajnych aplikacji, jak i samych systemów komputerowych. Niniejsza praca przedstawia wyniki prac nad zastosowaniem sieci neuronowej do analizy danych, na podstawie których tworzona jest mapa rozkładu czasów T1 i T2. Należy dodać, iż artykuł ten nie opisuje klasycznego podejścia do segmentacji obrazu bazującego na algorytmie związanym z intensywnością pikseli na pojedynczym obrazie. Ideą tego tekstu jest pokazanie wyników prac nad analizą całościową danych podlegających obliczeniom.

Jedno z pierwszych miejsc zastosowania sieci neuronowych wydaje się być przypisane diagnostyce obrazowej. W badaniach wątroby sztuczna inteligencja pozwala na wykrywanie i ocenę stłuszczenia wątroby [1, 2], może ona również wykrywać i rozróżniać zmiany ogniskowe tego narządu [3, 4]. Tutaj źródłem danych są obrazy uzyskane ultrasonograficzne (USG). W zakresie tomografii komputerowej możliwości zdają się być znacznie większe. Praca autorów [5] pokazuje wyniki analizy z wykorzystaniem sztucznej inteligencji badań wątroby uzyskanych metodą tomografii komputerowej (CT). Sztuczne sieci neuronowe w łączności z obrazowaniem metodą rezonansu magnetycznego wydają się mieć najliczniejsze zastosowania. Metoda ta poprzez mnogość sekwencji, a co za tym idzie – różnorodności otrzymywanych obrazów tej samej przestrzeni badanej – posiada ogromny potencjał związany z automatyzacją analiz różnych narządów, w tym wątroby [6] czy też mięśnia sercowego [7, 8, 9, 10]. Szczególnym rodzajem obrazowania jest mammografia. Wymaga ona doskonałego przygotowania zarówno sprzętu, jak i personelu lekarsko-technicznego. W tej metodzie diagnostycznej sztuczna inteligencja pozwala na klasyfikację gęstości piersi [11], wykrywanie i klasyfikację asymetrii, zwapnień [12, 13]. Obszerne opracowania metod sztucznej inteligencji w diagnostyce mammograficznej podjęli się autorzy artykułów [14, 15]. Algorytmy głębokiego uczenia mają szczególne znaczenie w onkologii. W badaniu jelita grubego mogą wykrywać polipy stanowiące potencjalne ryzyko raka jelita grubego. Analiza ponad 200 artykułów została opublikowana przez autorów pozycji literaturowej [16]. Badacze przeanalizowali bardzo duży zbiór dostępnej literatury w zakresie uczenia maszynowego do wykrywania, segmentacji i klasyfikacji COVID-19. Wykazali,

iż szybkie opracowywanie wyników może być pomocne w skutecznej diagnostyce radiologicznej. Ponadto możliwość przewidywania zaawansowania choroby pozwala lepiej zarządzać procesem leczenia, jak również zasobami szpitali. Pozwala to lepiej i efektywniej wykorzystywać dostępne środki.

Cel pracy

Celem pracy jest kontynuacja badań związanych z sieciami neuronowymi, zapoczątkowanych przez autorów w pracy [17]. Przywołana tutaj pozycja literaturowa opisuje zarówno badania wykorzystujące fantom, jak również zastosowanie zaproponowanego rozwiązania do analizy hodowli komórkowej MCF-7 – raka piersi. Przedstawione zostanie zastosowanie sieci neuronowych do analizy danych uzyskanych w trakcie badania MR. Pokazane tutaj zastosowanie nie będzie służyć tradycyjnie rozumianej segmentacji, ale ukazane zostanie podejście do analizy danych z pomiarów czasów relaksacji T1 i T2 metodą odzyskiwania saturacji (SR) i krzywych intensywności sygnału. Analizowane będą sekwencje obrazów i ich zależność względem siebie, a nie – jak to ma najczęściej miejsce w tradycyjnej technice rozpoznawania obrazów – analiza sąsiadujących na jednej płaszczyźnie pikseli.

Niniejsza praca opisuje wykorzystanie SI w zastosowaniach do oceny efektów terapii fotodynamicznej raka prostaty. Metoda ta obecnie należy do dynamicznie rozwijających się sposobów walki z nowotworami. Jej szczegółowe omówienie dostępne jest w bogatej literaturze, z której to można wymienić pozycje [18, 19, 20].

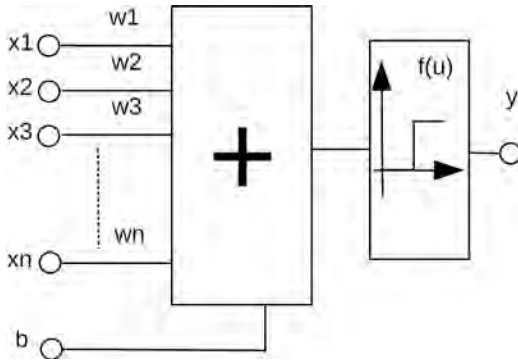
Sieć neuronowa

Sztuczna inteligencja jest dziedziną nauki, która znajduje zastosowanie w coraz to szerszych obszarach życia. Wkracza również do świata diagnostyki obrazowej, przez co staje się cennym narzędziem w rękach radiologów. Analizując piśmiennictwo, widać szybki wzrost liczby artykułów na temat zastosowania sieci neuronowych. Tylko w latach 2017–2021 liczba odpowiedzi na zapytanie „neural network in medicine” przekracza 10,5 tys. pozycji. Liczba ta pochodzi z bazy artykułów PubMed. Pokazuje to ogromne zainteresowanie badaczy tą metodą wspomagania szeroko pojętego procesu leczenia.

Zasadniczo pierwowzorem sztucznego neuronu był neuron rzeczywisty. Sztuczny odpowiednik jest niejako jego matematycznym modelem. Stworzone przez człowieka matematyczne odpowiedniki neuronów w lepszym bądź gorszym stopniu odwzorowują własności rzeczywistej komórki nerwowej. Modele te zawsze zawierają sumowanie informacji wejściowych z uwzględnieniem ich wag oraz czony wyjściowe będące elementami nieliniowymi. Funkcje nieliniowe, jakimi opisane są bloki wyjściowe, ich własności, mają zasadniczy wpływ na metody procesu uczenia sieci. Z punktu widzenia praktycznego uczenie to dobór wag, przez które mnożone są sygnały wejściowe z poszczególnych wejść, zaś same wagi stanowią zbiór



liczb będących macierzą. Zbiór pojedynczych neuronów to sieć neuronowa, która może występować w wielu odmianach. Nie sposób w tym krótkim opracowaniu przedstawić ogromnego obszaru, jaki stanowią sieci neuronowe.



Ryc. 1 Schemat podstawowy perceptronu
Źródło: Opracowanie własne.

Jest to funkcja skokowa, która przyjmuje tylko dwie wartości: 0 i 1. Innymi ciągłymi funkcjami aktywacji są funkcje – sigmoidalna i unipolarna:

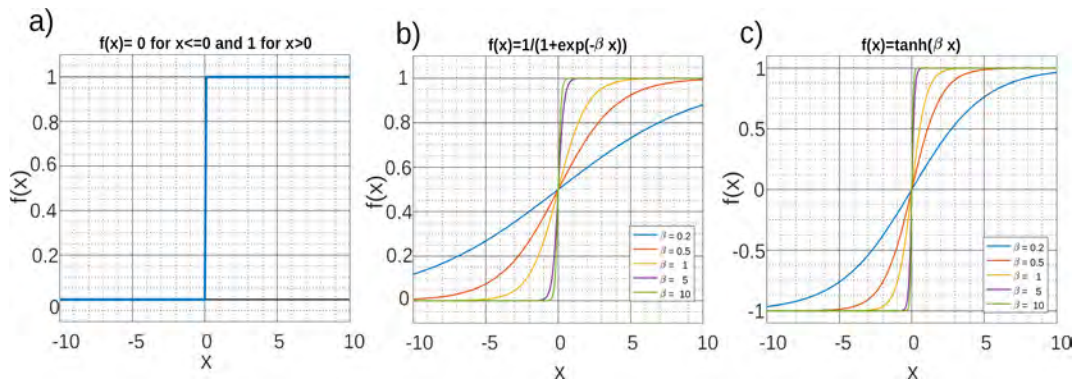
$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (4)$$

oraz bipolarna:

$$f(x) = \tanh(\beta x) = \frac{1 - e^{-\beta x}}{1 + e^{-\beta x}} \quad (5)$$

Wartość β jest parametrem, który zasadniczo wpływa na kształt funkcji aktywacji. Wzrost wartości tego parametru powoduje zwiększanie stromości funkcji. W przypadku granicznym przy $\beta \rightarrow \infty$ funkcje te przechodzą w funkcje skokowe. Rycina 2 prezentuje omawiane funkcje. Szersze omówienie teorii sieci neuronowych dostępne jest w bogatej literaturze tematu.

Niniejsza praca wykorzystuje sieć neuronową, której to funkcja aktywacji jest opisana funkcją unipolarną o dużej wartości



Ryc. 2 Funkcje aktywacji: a) funkcja skokowa, b) przebieg funkcji sigmoidalnej unipolarnej, c) przebieg funkcji sigmoidalnej bipolarnej
Źródło: Opracowanie własne.

Elementarną częścią sieci neuronowej jest pojedynczy neuron. Jego schemat został zaprezentowany na rycinie 1. Zastosowane oznaczenia to: b, x_1, \dots, x_n – wejścia sieci, w_1, \dots, w_n – wagi poszczególnych wejść będące współczynnikiem wzmocnienia, przez który mnożony jest każdy z sygnałów wejściowych, y – wyjście. Ogólnie sygnał wyjściowy można opisać zależnością:

$$y = f\left(b + \sum_{i=1}^n (x_i(t) \cdot w_i)\right) \quad (1)$$

Wyrażenie będące argumentem funkcji f jest sygnałem sumacyjnym. Wynosi ono:

$$u = b + \sum_{i=1}^n (x_i(t) \cdot w_i) \quad (2)$$

Sama funkcja $f(u)$ nosi nazwę funkcji aktywacji. Funkcja ta w najprostszym ujęciu wynosi:

$$f(u) = \begin{cases} 0 & \text{for } x \leq 0 \\ 1 & \text{for } x > 0 \end{cases} \quad (3)$$

współczynnika β . Wykorzystany tryb uczenia „z nauczycielem” wymaga dostarczenia zarówno zbioru uczącego, jak i wymaganej odpowiedzi. W tym przypadku zbiorem uczącym jest zbiór wycinków obrazu reprezentujący zarówno szum w przestrzeni upowietrznionej obrazu, jak również obszar będący badaną próbką. Wycinki pobierane są z dwóch miejsc obrazu, a ich położenie jest takie samo dla wszystkich obrazów będących podstawą określania czasów relaksacji. Odpowiedzią dla pierwszej grupy próbek związanej z szumem jest wartość wyjściowa „0”, natomiast dla grupy drugiej wartością wyjściową jest „1”. Zbiory służące trenowaniu sieci pochodzą z tych samych obrazów, które stanowiły podstawę do wyznaczenia map T1. Pozwoliło to w sposób naturalny uwzględnić charakterystykę sygnału i szumu będącego nieodłącznym elementem każdego badania, jak również systemu pomiarowego.

Sieć neuronową zaimplementowano w języku MATLAB. Poniżej przedstawiony jest listing funkcji użytych w projekcie: Function SN = siec_neuronowa_dicom(DaneNet, Odpowiedz);
% Funkcja tworzy sieć neuronową, dokonuje jej treningu
% używając danych wejściowych
% Parametr wyjściowy funkcji:

% SN – sieć neuronowa
 % Parametry wejściowe funkcji:
 % DaneNet – dane wejściowe pochodzące z zarejestrowanych
 % plików DICOM
 % Odpowiedz – wektor odpowiedzi
 SN = patternnet(10);
 SN = train(SN,double(DaneNet),double(Odpowiedz));
 view(SN)

Material i metoda

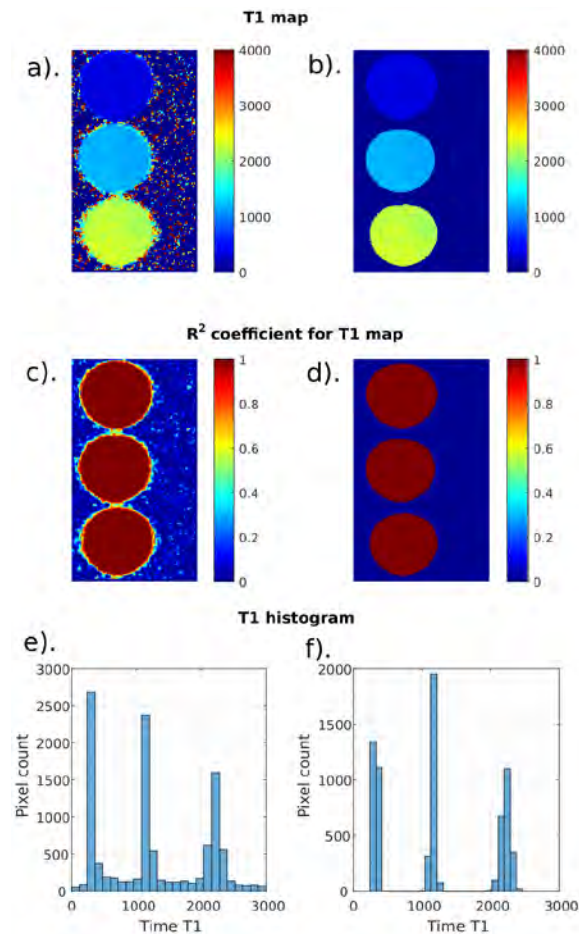
Badania opisane w niniejszej pracy podzielono na dwa etapy.

W pierwszym etapie przebadany został fantom dla potwierdzenia poprawności założeń. Składał się on z próbek wypełnionych wodnym roztworem CuSO_4 o różnych stężeniach. Pierwsza próbka zawierała około 0,1 g CuSO_4 oraz 10 ml H_2O o przewodności poniżej 8 $\mu\text{S}/\text{cm}$. Pobierając z niej 1 ml roztworu i uzupełniając 9 ml H_2O , uzyskiwano mniejsze stężenia. Każda z następnych próbek przygotowanych do badania różniła się od poprzedniej mniejszym stężeniem. Pozwoliło to na uzyskanie znacznych różnic w czasach T1 i T2 w badanych próbkach. Ostatecznie badaniu poddano trzy spośród pięciu przygotowanych próbek. Próbkę dla przypadku rejestracji czasu relaksacji podłużnej T1 badane były metodą SR (ang. *saturatuin recovery*). Z uwagi na potrzebę minimalizacji błędów aproksymacji badacze zdecydowali o zwiększeniu liczby punktów pomiarowych. Dla określenia czasu T1 czas TE wynosił 21 ms, natomiast czasy TR wynosiły odpowiednio: 40, 50, 60, 78, 80, 100, 120, 140, 200, 240, 300, 400, 500, 600, 700, 800, 1000, 1500, 2000, 3000, 5000, 10000, 15000 ms [21]. Akwizycja obrazów T2 odbywała się przy czasach TE: 8, 17, 44, 70, 88, 105, 132, 158, 176, 193 ms oraz czasie TR – 10000 ms. Przytoczone tutaj czasy TE i TR są parametrami odczytanymi z plików źródłowych.

Takie podejście do akwizycji jest możliwe tylko i wyłącznie w przypadku hodowli komórkowych lub też w badaniach niezwiązanych z pacjentem. Zwiększenie bowiem liczby sekwencji powoduje znaczne wydłużenie czasu badania. To z kolei, w przypadku często ciepłego pacjenta, jest niemożliwe i naraża go na dodatkowe niedogodności.

Rycina 3 prezentuje uzyskane wyniki analizy opisanego powyżej fantomu. Rycina 3a) obrazuje rozkład czasów T1 dla przypadku, w którym analiza sieciami neuronowymi nie miała miejsca, natomiast rycina 3b) to obraz tego samego fantomu, w którym została zastosowana ta metoda segmentacji. Wyraźnie widać efekt usunięcia szumu z obszaru upowietrzonego. Dodatkowo usunięty jest również obszar artefaktów występujący na granicy próbki i powietrza. Ryciny 3c) i 3d) obrazują mapę rozkładu współczynnika dopasowania R^2 , którego bliski jedności wynik pokazuje bardzo dobre dopasowanie funkcji aproksymującej do danych eksperymentalnych. Czas T1 jest określany w oparciu o funkcję aproksymującą. Ryciny 3e) i 3f) prezentują rozkład ilościowy pikseli metodą histogramu. Wykorzystanie sieci neuronowej usunęło z histogramów wartości pikseli odpowiadających

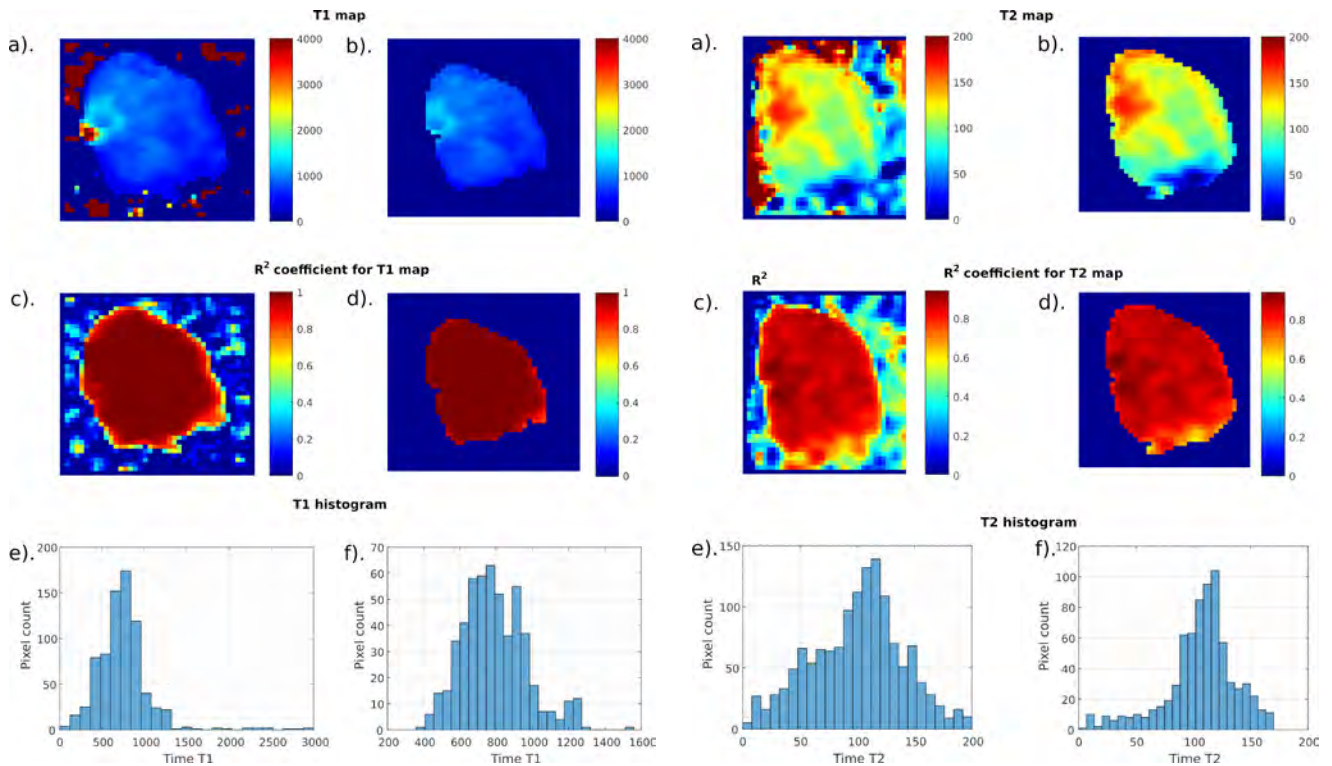
w dużej części szumowi. Należy dodać, iż ta metoda segmentacji obrazu nie wpływa na obszary obrazu będące obrazami tkanek. Nie istnieje więc niebezpieczeństwo zafalszowania obrazu tkanek przez dodatkowe operacje na nim.



Ryc. 3 a). - rozkład współczynnika T1, c). - współczynnika dopasowania R^2 oraz e). - histogram w przypadku niewykorzystywania sieci neuronowej; b). - rozkład współczynnika T1, d). - rozkład współczynnika dopasowania R^2 oraz f). - histogram dla analizy opartej o sieci neuronowe
 Źródło: Opracowanie własne.

Na rycinie 4 przedstawiono obrazy w sposób podobny do ryciny 3. Pokazano na niej rozkład współczynnika T1 dla tkanki prostaty wraz z histogramem. Zastosowanie sieci neuronowej spowodowało, iż przestrzeń upowietrzona nie była brana do analizy, co poskutkowało skróceniem czasu koniecznego do wykonania obliczeń i wyznaczenia mapy T1. Usunięte zostały również piksele będące artefaktem w górnej części obrazu badanej tkanki. Zmniejszeniu uległ również histogram. Świadczy to również o fakcie wyeliminowania pewnej części pikseli będących szumem, a nakładających się na wysokość histogramu.


Na rycinie 5 ukazano działanie algorytmu dla obrazów relaksacji poprzecznej T2. Podobnie jak w przypadku T1, ograniczeniu uległ szum. Poprawie uległ również rozkład obrazowany wykresem histogramowym.



Ryc. 4 a). - rozkład współczynnika T1 w badaniu wycinka tkanki prostaty, c). - współczynnik dopasowania R^2 oraz e). - histogram w przypadku niewykorzystywania sieci neuronowej; b). - rozkład współczynnika T1 dla tej samej tkanki, d). - współczynnika dopasowania R^2 oraz f). - histogram dla analizy opartej o sieci neuronowe
Źródło: Opracowanie własne.

Ryc. 5 a). - rozkład współczynnika T2 w badaniu wycinka tkanki prostaty, c). - współczynnik dopasowania R^2 oraz e). - histogram w przypadku niewykorzystywania sieci neuronowej; b). - rozkład współczynnika T2 dla tej samej tkanki, d). - współczynnika dopasowania R^2 oraz f). - histogram dla analizy opartej o sieci neuronowe
Źródło: Opracowanie własne.

Na rycinie 6 przedstawiono odpowiedź sieci neuronowej dla fantomu – a) oraz dla badanej tkanki prostaty – b). Zadaniem sieci neuronowej było rozróżnienie szumu od sygnału tkanki. Czarne pola odpowiadają przestrzeniom upowietrzniom, natomiast białe – fantomowi i tkance.



Ryc. 6 Odpowiedź sieci neuronowej: a) dla fantomu, b) dla tkanki prostaty
Źródło: Opracowanie własne.

Jak już wspomniano wcześniej, całość kodu zarówno pobierającego dane z plików DICOM, jak również implementacji sieci neuronowej dokonano w pakiecie MATLAB. Celem pracy była optymalizacja przez skrócenie czasu obliczeń rozkładu czasów relaksacji. Obliczenia były realizowane przy pomocy komputera PC wyposażonego w procesor INTEL i5, 16MB RAM oraz SSD 250GB. Do obliczeń nie wykorzystywano procesora graficznego.

Obrobka obrazów to zawsze proces czasochłonny ze względu


na specyfikę dużych zbiorów danych. Dlatego też wysoce pożądane są metody, które czas ten ograniczą. Przeciętny czas potrzebny na dopasowanie funkcji aproksymującej do jednego piksela zbioru danych z użyciem opisanego powyżej algorytmu oraz systemu komputerowego wynosił około 29,1 ms. Liczba pikseli, z których składa się obraz fantomu, wynosi około 20 500 (Ryc. 5a). Czas potrzebny na analizę obrazu i wyznaczenie czasów relaksacji T1 dla każdego punktu z udziałem metody SI to około 208 s. Dla przypadku, w którym ten sam obraz był analizowany w całości – bez metody SI – czas wynosił około 597 s. Zastosowanie tej metody pozwoliło skrócić czas potrzebny na wyznaczenie map T1 do około 35%. Podobne wyniki uzyskane zostały również dla czasu T2.

Czas związany z trenowaniem sieci z użyciem danych obrazowych pochodzących z tego samego zbioru danych był pomijalnie mały i nie przekraczał 2 s.

Należy zaznaczyć, iż przywołane tutaj dane liczbowe to dane obrazujące ten jeden wybrany obszar. Skrócenie czasu zależy w oczywisty sposób od stosunku powierzchni upowietrznionej do powierzchni objętej obszarem tkanki. Na wynik segmentacji pewien wpływ ma również wybór obszarów służących treningowi sieci. W przypadku, w którym w obszarze użytecznym wystąpią czasy relaksacji bardzo krótkie bądź bardzo długie, mogą one zostać błędnie zaklasyfikowane.



Wnioski

Zaproponowana sieć neuronowa w sposób zadowalający dokonała segmentacji obrazu. Zastosowanie sieci neuronowej wydawnie skróciło obliczenia z uwagi na pominięcie pikseli obrazujących przestrzenie upowietrznione. Ograniczeniu uległy również elementy obrazu prezentujące całkowicie zafaszkowane wartości czasów relaksacji, a więc artefakty. Obecność w obszarze zainteresowania obszarów o bardzo krótkich bądź bardzo długich czasach relaksacji może doprowadzić do tego, iż zostaną one błędnie zaklasyfikowane. 

Uwaga

Badanie zostało przeprowadzone zgodnie z Deklaracją helsińską i zatwierdzone przez Komisję Bioetyki Uniwersytetu Rzeszowskiego (kod protokołu 9.11.2018 i data zatwierdzenia: 08.11.2018).

Piśmiennictwo

1. M. Biswas, V. Kuppili, D.R. Edla, H.S. Suri, L. Saba, R.T. Marinho, J.M. Sanches, J.S. Suri. Symptosis: A liver ultrasound tissue characterization and risk stratification in optimized deep learning paradigm, *Comput Methods Programs Biomed.*, 155, 2018, 165–177.
2. M. Byra, G. Styczynski, C. Szmigielski, P. Kalinowski, Ł. Michałowski, R. Paluszkiwicz, B. Ziarkiewicz-Wróblewska, K. Zieniewicz, P. Sobieraj, A. Nowicki: *Transfer learning with deep convolutional neural network for liver steatosis assessment in ultrasound images*. *Int J Comput Assist Radiol Surg.*, 13(12), 2018, 1895–1903.
3. T.M. Hassan, M. Elmogy, E.S. Sallam: *Diagnosis of Focal Liver Diseases Based on Deep Learning Technique for Ultrasound Images*, *Arab J Sci Eng.*, 42, 2017, 3127–3140.
4. L.H. Guo, D. Wang, Y.Y. Qian, X. Zheng, C.K. Zhao, X.L. Li, X.W. Bo, W.W. Yue, Q. Zhang, J. Shi, H.X. Xu: *A two-stage multi-view learning framework based computer-aided diagnosis of liver tumors with contrast enhanced ultrasound images*, *Clin Hemorheol Microcirc.*, 69, 2018, 343–354.
5. B. Ibragimov, D. Toesca, D. Chang, Y. Yuan, A. Koong, L. Xing: *Development of deep neural network for individualized hepatobiliary toxicity prediction after liver SBRT*, *Med Phys.*, 45, 2018, 4763–4774.
6. H. Winther, C. Hundt, K.I. Ringe, F.K. Wacker, B. Schmidt, J. Jürgens, M. Haimerl, L.P. Beyer, C. Stroszczynski, P. Wiggermann, N. Verloh: *A 3D Deep Neural Network for Liver Volumetry in 3T Contrast-Enhanced MRI*, *Rofo*, 193(3), 2021, 305–314.
7. H.P. Do, Y. Guo, A.J. Yoon, K.S. Nayak: *Accuracy, uncertainty, and adaptability of automatic myocardial ASL segmentation using deep CNN*, *Magn Reson Med.*, 83(5), 2020, 1863–1874, doi: 10.1002/mrm.28043. Epub 2019 Nov 14.
8. J. Sander, B.D. de Vos, I. Išgum: *Automatic segmentation with detection of local segmentation failures in cardiac MRI*, *Sci Rep.*, 10(1), 2020, 21769.
9. T. Leiner, D. Rueckert, A. Suinesiaputra, B. Baeßler, R. Nezafat, I. Išgum, A.A. Young: *Machine learning in cardiovascular magnetic resonance: basic concepts and applications*, *J Cardiovasc Magn Reson.*, 21(1), 2019, 61.
10. A. Bratt, J. Kim, M. Pollie, A.N. Beecy, N.H. Tehrani, N. Codella, R. Perez-Johnston, M.C. Palumbo, J. Alakbarli, W. Colizza, I.R. Drexler, C.F. Azevedo, R.J. Kim, R.B. Devereux, J.W. Weinsaft: *Machine learning derived segmentation of phase velocity encoded cardiovascular magnetic resonance for fully automated aortic flow quantification*, *J Cardiovasc Magn Reson.*, 21(1), 2019, 1.
11. A.A. Mohamed, W.A. Berg, H. Peng, Y. Luo, R.C. Jankowitz, S. Wu: *A deep learning method for classifying mammographic breast density categories*, *Med Phys.*, 45(1), 2018, 314–321.
12. S. Boumaraf, X. Liu, C. Ferkous, X. Ma: *A New Computer-Aided Diagnosis System with Modified Genetic Feature Selection for BI-RADS Classification of Breast Masses in Mammograms*, *Biomed Res Int.*, 2020, 7695207.
13. H. Liu, Y. Chen, Y. Zhang, L. Wang, R. Luo, H. Wu, C. Wu, H. Zhang, W. Tan, H. Yin, D. Wang: *A deep learning model integrating mammography and clinical factors facilitates the malignancy prediction of BI-RADS 4 microcalcifications in breast cancer screening*, *Eur Radiol.*, 31(8), 2021, 5902–5912.
14. D. Abdelhafiz, C. Yang, R. Ammar, S. Nabavi: *Deep convolutional neural networks for mammography: advances, challenges and applications*, *BMC Bioinformatics*, 20(11), 2019, 281.
15. L. Zou, S. Yu, T. Meng, Z. Zhang, X. Liang, Y. Xie: *A Technical Review of Convolutional Neural Network-Based Mammographic Breast Cancer Diagnosis*, *Comput Math Methods Med.*, 2019, 6509357.
16. B. Alsaaidah, M.R. Al-Hadidi, H. Al-Nsour, R. Masadeh, N. AlZubi: *Comprehensive Survey of Machine Learning Systems for COVID-19 Detection*, *J Imaging*, 8(10), 2022, 267.
17. A. Truszkiewicz, D. Bartusik-Aebisher, Ł. Wojtas, G. Cieślak, A. Kawczyk-Krupka, D. Aebisher: *Neural Network in the Analysis of the MR Signal as an Image Segmentation Tool for the Determination of T1 and T2 Relaxation Times with Application to Cancer Cell Culture*, *International Journal of Molecular Sciences*, 2023, 24.
18. Ł. Ożóg, W. Domka, A. Truszkiewicz, J. Tarbarkiewicz, D. Aebisher: *Monitoring photodynamic oxygen consumption by endogenous oxygen contrast MRI*, *Photodiagnosis Photodyn Ther.*, 25, 2019, 492–498.
19. D. Bartusik-Aebisher, Ł. Ożóg, D. Aebisher, *Alternative methods of photodynamic therapy and oxygen consumption measurements - A review*, *Biomed Pharmacother*, 134, 2021, 111095.
20. D. Bartusik-Aebisher, Ł. Ożóg, W. Domka, D. Aebisher: *Rose Bengal and Future Directions in Larynx Tumor Photodynamic Therapy*, *Photochem Photobiol.*, 97(6), 2021, 1445–1452.
21. A. Truszkiewicz, D. Aebisher, D. Bartusik-Aebisher: *Assessment of spin-lattice T1 and spin-spin T2 relaxation time measurements in breast cell cultures at 1.5 Tesla as a potential diagnostic tool in vitro*, *Medical Research Journal*, 5, 2020, 1–11.