

prof. dr hab. inż. Tomasz Zieliński
Instytut Telekomunikacji
Wydział Informatyki, Elektroniki i Telekomunikacji
Akademia Górniczo-Hutnicza im. St. Staszica
al. Mickiewicza 30
30-059 Kraków

RECENZJA

rozprawy doktorskiej mgr. inż. Mateusza Budy pt.

„Computer-aided image-based diagnosis:
extensions of computational models with domain knowledge”

Promotor:	prof. dr hab. inż. Artur Jerzy Przelaskowski
Promotor pomocniczy:	dr Maciej Andrzej Mazurowski
Dziedzina:	nauki inżyniersko-techniczne
Dyscyplina:	informatyka techniczna i telekomunikacja

1. Ogólna charakterystyka rozprawy

Recenzowana rozprawa doktorska dotyczy zagadnienia stosowania metod uczenia maszynowego/rozpoznawania wzorców (Machine Learning/Pattern Recognition) w obrazowej diagnostyce medycznej (rezonansie magnetycznym, ultrasonografii i mammografii). Doprecyzowując, Doktorant zajmuje się przede wszystkim opracowaniem metod jak najefektywniejszego uczenia spłotowych (CNN) i głębokich (DNN) sieci neuronowych (Convolutional Neural Networks, Deep Neural Networks) w przypadku licznie niezrównoważonych zbiorów danych uczących dla poszczególnych klas. Jest to problem niezwykle istotny ponieważ w zbiorach danych medycznych prawie zawsze przypadków patologii/choroby jest o wiele mniej niż przypadków normy/zdrowia. Praca jest wielowątkowa. Doktorant zweryfikował poprawność wielu hipotez badawczych, wymienionych w rozdz. 1 (dla wielu modalności obrazowych). Zdaniem recenzenta do najważniejszych, oryginalnych osiągnięć doktoratu należy zaliczyć:

- 1) przebadanie wielu metod i wykazanie, że równoważenie liczebności zbiorów uczących dla normy i patologii bardzo korzystnie jest realizować poprzez zwiększanie liczby wzorców patologii metodą interpolacji jej mniej licznych przykładów;
- 2) uczenie generatywnej sieci kontrykcyjnej GAN (Generative Adversarial Network) tylko przykładami normy i rozpoznawanie patologii jako przypadku różniącego się od stanu normy, co okazało się bardzo skuteczne w przypadku rozpoznawania raka piersi w mammogramach 3D.

Recenzowana rozprawa ma format książki (nieco większy od formatu A5), która została wydrukowana w 2024 roku przez Politechnikę Warszawską w serii WUT Ph. D. Thesis, Discipline of Science – Information and Communications Technology / Field of Science – Engineering and Technology (bez numeru ISBN/ISSN). Praca jest napisana w języku angielskim, liczy 179 stron oraz składa się z następujących części: streszczenia w języku angielskim (1 str.), streszczenia w języku polskim (1 strona), spisu treści (2 strony), wprowadzającego rozdziału 1 (7 stron), rozdziałów od 2 do 5 (łącznie 16 stron) opisujących poszczególne publikacje Doktoranta, rozdziału 6 z wnioskami końcowymi (6 stron) oraz rozdziału 7 (2 strony), ostatniego, przedstawiającego dorobek naukowy Doktoranta. Pracę zamyka wykaz literatury, składający się z 35 pozycji (5 stron), dodatki od A.1 do A.9 (razem 96 stron), zawierające kopie 9 publikacji Doktoranta, oraz oświadczenia autorskie (39 stron). Ogólnie można potraktować rozprawę jako monotematyczny zbiór publikacji, do którego dodano rozbudowany autoreferat, składający się ze: streszczenia, wprowadzenia (rozdz. 1), syntetycznego opisu rozwiązywanych problemów i otrzymanych wyników (rozdz. 2-5), oraz podsumowania (rozdz. 6 i 7).

2. Zawartość rozprawy

W tej części recenzji skrótowo scharakteryzowano poszczególne publikacje Doktoranta (dodatki A.1-A.9), składające się na rozprawę oraz zbiorczo omówione w rozdziałach od 2 do 6. W tabeli I podano przypisanie publikacji do poszczególnych rozdziałów.

Tabela I. Przypisanie publikacji Doktoranta do rozdziałów rozprawy

Rozdz.	Tytuł	Publikacje
2	Challenges to applied machine learning in radiology	[A.1] Maciej A Mazurowski, Mateusz Buda, Ashirbani Saha, and Mustafa R Bashir. „Deep learning in radiology: an overview of the concepts and a survey of the state of the art with focus on MRI”. <i>Journal of Magnetic Resonance Imaging</i>, 49(4):939–954, 2019. [A.2] Mateusz Buda, Atsuto Maki, and Maciej A Mazurowski. „A systematic study of the class imbalance problem in convolutional neural networks”. <i>Neural Networks</i>, 106:249–259, 2018.
3	Applications in brain magnetic resonance imaging	[A.3] Mateusz Buda, Ashirbani Saha, and Maciej A Mazurowski. „Association of genomic subtypes of lower-grade gliomas with shape features automatically extracted by a deep learning algorithm”. <i>Computers in Biology & Medicine</i>, 109:218–225, 2019. [A.4] Mateusz Buda, Ehab A AlBadawy, Ashirbani Saha, and Maciej A Mazurowski. „Deep radiogenomics of lower-grade gliomas: convolutional neural networks predict tumor genomic subtypes using MR images”. <i>Radiology: Artificial Intelligence</i>, 2(1), 2020.
4	Applications in thyroid ultrasound	[A.5] Mateusz Buda, Benjamin Wildman-Tobriner, Kerry Castor, Jenny K Hoang, and Maciej A Mazurowski. „Deep learning-based segmentation of nodules in thyroid ultrasound: improving performance by utilizing markers present in the images”. <i>Ultrasound in Medicine & Biology</i>, 46(2): 415–421, 2020. [A.6] Mateusz Buda, Benjamin Wildman-Tobriner, Jenny K Hoang, David Thayer, Franklin N Tessler, William D Middleton, and Maciej A Mazurowski. “Management of thyroid nodules seen on US images: deep learning may match performance of radiologists”. <i>Radiology</i>, 292 (3): 695–701, 2019. [A.7] Benjamin Wildman-Tobriner, Mateusz Buda, Jenny K Hoang, William D Middleton, David Thayer, Ryan G Short, Franklin N Tessler, and Maciej A Mazurowski. “Using artificial intelligence to revise ACR TI-RADS risk stratification of thyroid nodules: diagnostic accuracy and utility”. <i>Radiology</i>, 292(1): 112–119, 2019.
5	Applications in digital breast tomosynthesis	[A.8] Mateusz Buda, Ashirbani Saha, Ruth Walsh, Sujata Ghate, Nianyi Li, Albert Świącicki, Joseph Y Lo, and Maciej A Mazurowski. „A data set and deep learning algorithm for the detection of masses and architectural distortions in digital breast tomosynthesis images”. <i>JAMA network open</i>, 4(8), 2021. [A.9] Albert Swiecicki, Nicholas Konz, Mateusz Buda, and Maciej A Mazurowski. “A generative adversarial network-based abnormality detection using only normal images for model training with application to digital breast tomosynthesis”. <i>Scientific reports</i>, 11(1):1–13, 2021.

W rozdziale 1 pt. „Introduction” (7 stron) przedstawiono: 1) rys historyczny stosowania metod uczenia maszynowego (ML) do wspierania obrazowej diagnostyki medycznej, 2) istniejące ograniczenia użycia metod ML w przypadku obrazów medycznych (tomografia komputerowa, rezonans magnetyczny, ultradźwięki), przede wszystkim ograniczona liczebność przykładów oraz niezrównoważenie liczby przykładów dla poszczególnych klas, 3) problemy związane z walidacją i generalizacją, wynikające z użycia różnych urządzeń pomiarowych o specyficznych, odmiennych cechach, 4) problemy związane z efektywną integracją wyników rozpoznawania maszynowego w szpitalnych/klinicznych systemach obiegu informacji medycznej. Na tym tle zaprezentowane dwie tezy rozprawy, mówiące, że:

- 1) „*możliwe jest udoskonalenie użycia metod ML, skutkujące efektywniejszym wspieraniem diagnostyki obrazowej (poprzez uwzględnienie specyfiki użytego sprzętu oraz rozwiązanie problemu ograniczonej liczby danych i niezbalansowania liczebności przykładów normy i patologii)*”,
- 2) „*możliwe jest efektywne wkomponowanie metod ML w system obiegu informacji klinicznej w celu ułatwienia diagnozy medycznej*”.

Następnie wymieniono 9 hipotez szczegółowych, dotyczących, m. in.: niezrównoważenia klas, nadpróbkowania obrazów MRI, zastosowania metody transferu wiedzy oraz znaczenia opisu medycznego obrazów. Pod koniec podano dane bibliograficzne wszystkich publikacji cyklu oraz zaprezentowano zawartość poszczególnych rozdziałów rozprawy.

Rozdział 2 pt. „Challenges to applied machine learning in radiology” (3 strony) stanowi omówienie publikacji [A.1][A.2]. W przeglądowej publikacji [A.1] (16 stron w dwóch kolumnach, 125 odnośników, **272 cytowania**) w kompleksowy sposób przedstawiono aktualny stan wiedzy z zakresu zastosowania głębokich sieci neuronowych do segmentacji i klasyfikacji obrazów medycznych (szczególnie w obrazowaniu metodą rezonansu magnetycznego). Pod koniec pracy wymieniono istniejące trudności do pokonania. Z kolei w publikacji [A.2] (11 stron w dwóch kolumnach, 67 odnośników, **1343 cytowania**, najbardziej rozpoznawalna praca cyklu) zajęto się problemem uczenia sieci neuronowych w przypadku braku równoliczności przykładów poszczególnych klas. Z przetestowanych metod (nad-próbkowanie, pod-próbkowanie, dwu-etapowe uczenie, progowanie, adaptacyjne ważenie) najkorzystniejsze okazało się zastosowanie nadpróbkowania.

Rozdział 3 pt. „Applications in brain magnetic resonance imaging” (4 strony) stanowi omówienie publikacji [A.3][A.4]. Obie dotyczą zastosowania metod ML do danych z rezonansu magnetycznego ludzkiego mózgu. W [A.3] (8 stron, 2 kolumny, 37 odnośników, **129 cytowań**) zastosowano sieci neuronowe do ekstrakcji cech obrazu oraz wnioskowania na ich podstawie o typie glejaka. Użyto publicznie dostępnej bazy danych (110 pacjentów z 5 instytucji) i trenowano sieć splotową o architekturze U-Net. W celu redukcji niezbalansowania klas usunięto obrazy normy, niezawierające tkanki mózgowej, oraz nadpróbkowano obrazy patologii. Otrzymano współczynnik Dice’a o wartości 82%. Artykuł [A.4] (7 stron, 2 kolumny, 27 odnośników, 9 cytowań) również dotyczył rozpoznawania rodzaju glejaka na podstawie klasyfikacji neuronowej kształtów i tekstur na obrazach MRI mózgu. Problem małej liczby wzorców rozwiązano metodą transferu wiedzy. W tym przypadku uzyskano pole pod krzywą ROC równe $AUC=0.685$.

Rozdział 4 pt. „Applications in thyroid ultrasound” (5 stron) stanowi omówienie 3 publikacji [A.5][A.6][A.7]. Wszystkie one dotyczą zastosowania DNN do rozpoznawania i klasyfikacji guzków tarczycy w obrazach ultrasonograficznych. Publikacja [A.5] (7 stron, 2 kolumny, 21 odnośników, 24 cytowania) pokazuje jak wykorzystać istniejące adnotacje medyczne danych w celu zwiększenia liczby przykładów i zmniejszenia efektu niezrównoważenia klas. Publikacja [A.6] (7 stron, 2 kolumny, 23 odnośniki, **120 cytowań**) prezentuje zbudowany system do rozpoznawania guzków tarczycy, zaś artykuł [A.7] (8 stron, 2 kolumny, 20 odnośników, **77 cytowań**) przedstawia wytyczne, które należy uwzględnić budując system sztucznej inteligencji do szacowania ryzyka „nowotworowego” w obserwowanych zmianach tarczycy.

Rozdział 5 pt. „Applications in digital breast tomosynthesis” (4 strony) stanowi omówienie 2 publikacji [A.8][A.9], które dotyczą zagadnienia rozpoznawania zmian rakowych w mammografii 3D piersi (po angielsku „breast tomosynthesis”). W artykule [A.8] (10 stron, jedna kolumna, 26 odnośników, 32

cytowania) opisana jest stworzona i publicznie udostępniona baza mammogramów 3D (wraz z przykładami i wynikami użycia), natomiast w pracy [A.9] (12 stron, 1 kolumna, 31 odnośników, 11 cytowań) zaproponowano użycie sieci GAN, która wykorzystuje tylko obrazy normy do wykrywania patologii w mammogramach 3D piersi.

Rozdział 6 pt. „Summary” (6 stron) stanowi podsumowanie rozprawy. Doktorant zwraca w nim uwagę na szczególnie istotne wyniki swojej pracy w poszczególnych obszarach badań: jeszcze raz skrótowo przypomina wartościowe elementy każdej publikacji cyklu doktorskiego.

Rozdział 7 pt. „Overview of academic achievements” (2 strony) prezentuje sylwetkę naukową Doktoranta, w tym historię zatrudnienia (2.5 roku w Duke University, USA) oraz jego dorobek naukowy (wskaźniki biblio-metryczne w 2021 roku: sumaryczna liczb publikacji (11), liczba ich cytowań (ponad 1600), średni IF czasopism (12.7), H-index 9 w JCR, współorganizacja konferencji DBTex I oraz DBTex II; recenzje artykułów zgłaszanych do następujących czasopism: *Neural Networks* (IF=6), *Artificial Intelligence Review* (IF=10.7), *Computers in Biology and Medicine* (IF=7), *Data Mining and Knowledge Discovery* (IF=2.8), *Journal of Machine Learning Research* (IF=4.3)).

Bibliografia rozprawy (5 stron) liczy 35 pozycji.

Do pracy są dołączone **kopie 9 publikacji** oraz **oświadczenia** ich współautorów.

3. Wskaźniki bibliometryczne osiągnięcia

Według bazy Web of Science (WoS) w dniu 3 września 2024 roku Doktorant posiadał następujący dorobek naukowy: 14 publikacji, 4 preprinty, **H-index równy 9** oraz **2061 cytowań**, w tym 7 cytowań w patentach. W tabeli II podano liczbę cytowań artykułów, wchodzących w skład ocenianego, monotematycznego cyklu publikacji. Zwraca uwagę **bardzo duża liczba cytowań (aż 2016)** oraz wysoki IF czasopism (**średni IF=8.3**).

Tabela II. Wskaźnik IF czasopism oraz liczba cytowań publikacji cyklu doktorskiego.

Publikacja	A.1	A.2	A.3	A.4	A.5	A.6	A.7	A.8	A.9
IF (5-lat)	4.4	7.6	6.7	10.8	2.9	13.4	13.4	11	4.3
Cytowania	272	1342	129	9	24	120	77	32	11

Dodatkowo na uwagę zasługuje następujący raport konferencyjny, nie uwzględniony w doktoracie, cytowany 34 razy:

G. Modanwal, A. Vellal, M. Buda, MA Mazurowski. „MRI Image Harmonization using Cycle-Consistent Generative Adversarial Network”. *Conf. Medical Imaging 2020: Computer-Aided Diagnosis*. Proc. SPIE, Vol. 11314, paper no 1131413, 2020.

4. Ocena rozprawy

4.1. Ocena wyboru tematyki

Tematyka rozprawy jest wyjątkowo ważna i aktualna: medyczna diagnostyka obrazowa (MRI, USG, mammografia 3D), automatyczne rozpoznawanie zmian nowotworowych mózgu, tarczycy i piersi, użycie splotowych, głębokich oraz generatywnych-kontrykcyjnych sieci neuronowych, rozwiązywanie problemu braku równoliczności przykładów dla klas normy i patologii podczas uczenia sieci, zajmowanie się problemem efektywnego wkomponowania metod uczenia maszynowego w istniejące systemy diagnostyki szpitalnej/klinicznej.

4.2. Ocena przedstawienia stanu wiedzy światowej

Doktorant posiada wzorową orientację w stanie wiedzy światowej. Najdobitniej świadczy o tym przeglądowa, 16-stronicowa publikacja [A.1] z 2019 roku, mająca 125 odnośników, która jest cytowana

aż 272 razy do chwili obecnej. Także pozostałe publikacje Doktoranta prezentują wyniki własne na bardzo szerokim tle badań prowadzonych na świecie. Przykładowo praca [A.2] cytuje aż 67 publikacji, a praca [A.3] – 37 publikacji.

4.3. Ocena wyboru i cytowania literatury

Sam tekst rozprawy ma charakter rozbudowanego autoreferatu, prezentującego w sposób syntetyczny wyniki wieloletnich prac badawczych Doktoranta (jego pierwsza publikacja pochodzi z 2018 roku). Poprawnie jest nim cytowanych 35 publikacji z lat 1975-2023. W sposób zwięzły prezentują one rys historyczny rozwoju i użycia sieci ANN/CNN/DNN w obrazowaniu medycznym oraz wyniki wybranych, najważniejszych prac światowych, istotnych z punktu widzenia ocenianej rozprawy doktorskiej. Oczywiście wykaz ten mógłby bogatszy. Ale moim zdaniem nie jest to potrzebne, uwzględniając bardzo szerokie tło literaturowe, zaprezentowane w publikacjach [A.1][A.2] Doktoranta.

4.4. Ocena poprawności zastosowanych metod badawczych

Zastosowano poprawne metody badawcze.

- 1) Badania poprzedzono wnikliwą analizą aktualnego stanu wiedzy światowej – publikacje [A.1][A.2].
- 2) Użyto ogólnie dostępnych baz danych (np. MNIST, CIFAR-10, ImageNet ILSVRC-2012), co pozwala obiektywnie porównać wyniki prac własnych z innymi oraz poprawnie je ocenić [A.2].
- 3) Zastosowano klasyczne, sprawdzone metody uczenia, walidacji i testowania sieci.
- 4) Wykorzystano uznane wskaźniki jakości rozpoznawania (np. współczynnik Dice’a, pole pod krzywą ROC, parametry statystyczne), co również ułatwia ocenę otrzymywanych wyników.
- 5) Wielowątkowo koncentrowano się na rozwiązaniu problemu naukowego dot. ograniczonej liczebności i nieźrównoważenia ilościowego danych. W tym punkcie zaproponowano nowe, wartościowe rozwiązania.
- 6) Pracowano nad skutecznym wkomponowaniem opracowanych metod w szpitalne/kliniczne systemy diagnostyczne.
- 7) Co ważne, mając na uwadze „dobro wspólne”, **udostępniano tworzone przez siebie bazy danych medycznych oraz oprogramowanie w publicznie dostępnych repozytoriach.**

4.5. Ocena uzyskanych wyników

Badania prowadzono bardzo szeroko (nowotwory mózgu, tarczycy i piersi). Wykorzystywano różne metody obrazowania medycznego (MRI, USG, mammografia 3D). Przebadano różne metody rozwiązania problemu ograniczonej liczby danych. Zaproponowano różne oryginalne rozwiązania w każdym przypadku (np. nadpróbkowanie, transfer wiedzy). Opublikowane wyniki spotkały się z bardzo dużym zainteresowaniem światowym (1342 cytowania pracy [A.2] – technika nadpróbkowania obrazów podczas uczenia sieci, 129 cytowań pracy [A.3] – rozpoznanie glejaków w mózgu, 120 cytowań pracy [A.6] oraz 77 cytowań pracy [A.7] – rozpoznawanie raka tarczycy).

4.6. Silne strony rozprawy (osiągnięcia i elementy oryginalne)

Poniżej wymienione pozytywne aspekty rozprawy.

- 1) Przeprowadzenie bardzo wnikliwych/dokładnych badań, dotyczących metod redukcji wpływu niezbalansowania zbiorów uczących (przykładów normy jest o wiele więcej niż przykładów patologii) na skuteczność diagnostyki medycznej. Pokazanie, że nadpróbkowanie obrazów patologii jest lepszym rozwiązaniem niż pod-próbkowanie, dwu-etapowe uczenie, progowanie, adaptacyjne ważenie. Otrzymane wyniki są oryginalne i zostały zauważone w świecie, napisany artykuł [A.2] jest szeroko cytowany (1342 razy).
- 2) Zaproponowanie oryginalnej metody do wspomagania diagnostyki raka piersi [A.9], bazującej na uczeniu sieci GAN wyłącznie przykładami stanów normy (których zawsze jest

zdecydowanie więcej) i rozpoznawaniu stanów patologii jako przypadków bardzo różniących się od stanów normalnych.

- 3) Przeprowadzenie prac badawczych o bardzo szerokim zakresie. W doktoracie poruszono wiele różnych wątków/problemów badawczych. Każdy z nich stanowi osobny, ważny temat badawczy. Wszystkie prace zostały zakończone wartościowymi wynikami i znaczącymi publikacjami, co potwierdza fakt ich cytowania aż 2016 razy. Na tej podstawie można z pełnym przekonaniem stwierdzić, że Doktorant dysponuje w chwili obecnej bardzo dużym doświadczeniem badawczym oraz bardzo dobrym warsztatem naukowym.
- 4) Wielo-autorskie publikacje nie umniejszają bardzo dużego wkładu Doktoranta w każdej z publikacji. W sześciu przypadkach na dziewięć Doktorant jest pierwszym autorem publikacji. Jest on pierwszym autorem prac [A.2][A.3][A.6] łącznie cytowanych aż 1591 razy.
- 5) Doktorant wykazał się w swojej rozprawie doktorskiej umiejętnością „otwartej”, interdyscyplinarnej współpracy naukowej. Jest to bardzo cenna, pożądana cecha. Trudne zagadnienia badawcze rozwiązuje się efektywniej/lepiej, szybciej i przyjemniej w dużych, interdyscyplinarnych zespołach.
- 6) Wszystkie bazy danych i całe napisane oprogramowanie, które powstały w wyniku prowadzonych badań, **udostępniono w publicznie dostępnych repozytoriach**, co jest wyrazem dojrzałości naukowej Doktoranta oraz jego przełożonych: wyrazem szczególnej troski o użyteczny/społeczny charakter badań naukowych z zakresu diagnostyki medycznej oraz dowodem na nie przedkładanie własnej kariery naukowej nad dobro ogółu.

4.7. Słabe strony rozprawy (uwagi krytyczne i dyskusyjne, pytania)

Nie znajduję w rozprawie słabych elementów. Jedynie można mieć zastrzeżenia co do jej formy: postaci książki z bardzo krótkimi rozdziałami, które, moim zdaniem, zbyt ogólnikowo prezentują rozległe zagadnienia, przeprowadzone prace badawcze i uzyskane wyniki. Ponieważ w rozbudowanym podsumowaniu część treści przekazanych wcześniej w mini-rozdziałach powtarza się jeszcze raz, dlatego uważam, że lepsza byłaby forma doktoratu jako zbioru monotematycznych publikacji, podobnie jak w habilitacji, poprzedzonych jedynie rozbudowanym autorem referatem. Moim zdaniem publikacje Doktoranta bronią się bardzo dobrze same.

5. Wniosek końcowy

Zdecydowanie uważam, że recenzowana rozprawa doktorska Pana mgr inż. Mateusza Budy **spełnia wszystkie wymagania** stawiane rozprawom doktorskim (oryginalne, autorskie rozwiązania ważnych i aktualnych problemów naukowych) i **może być dopuszczona do oficjalnej obrony**. Ze względu na: 1) rozległość przeprowadzonych badań i mnogość poruszanych tematów (rozpoznawanie nowotworów w trzech modalnościach obrazowych), 2) osiągnięte bardzo dobre wyniki (potwierdzone bardzo dużą liczbą cytowań), 3) dużą liczbę publikacji w renomowanych czasopismach naukowych, oraz 4) bardzo wysoką pozycję naukową Doktoranta w skali światowej, będącą wynikiem prac nad doktoratem (potwierdzoną pełnieniem funkcji recenzenta w wielu renomowanych czasopismach), **wnioskuję także o wyróżnienie jego pracy**. Dodatkowo skłania mnie do tego fakt rozumienia przez Doktoranta olbrzymiego znaczenia współpracy naukowej (szczególnie na polu rozwoju metod diagnostyki medycznej) oraz **publiczne udostępniania zebranych zbiorów danych medycznych oraz napisanego oprogramowania**.

Tomasz Zidiński