

## **Recenzja rozprawy doktorskiej kpt. mgr. inż. Fabiana Gila pt. „Zespoły sieci głębokich w rozpoznawaniu wybranych klas obrazów medycznych”**

### **1. Podstawy formalne**

Niniejsza recenzja napisana została na podstawie Uchwały Rady Dyscypliny Naukowej Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne Wojskowej Akademii Technicznej z dnia 19 czerwca 2024 r. w sprawie wyznaczenia recenzentów w postępowaniu o nadanie stopnia doktora kpt. mgr. inż. Fabianowi Gilowi. Recenzja przygotowana została na podstawie Ustawy z dnia 20 lipca 2018 r. – Prawo o szkolnictwie wyższym i nauce (Dz.U. 2023 r. poz. 742 z późn.zm.). Rozprawa kpt. mgr. inż. Fabiana Gila napisana została w języku polskim, pod kierunkiem promotora prof. dra hab. inż. Stanisława Osowskiego.

### **2. Zakres tematyczny rozprawy**

Doktorant w pracy skupia się na opisie opracowanych automatycznych metod zespołowego rozpoznawania obrazów medycznych, opierając się na połączeniu różnych głębokich konwolucyjnych sieci neuronowych oraz klasycznych klasyfikatorów, takich jak maszyna wektorów nośnych i lasy losowe. Celem, jaki postawił sobie Doktorant było stworzenie efektywnych zespołów klasyfikacyjnych oraz opracowanie metod fuzji wyników uzyskiwanych przez odpowiednie człony w finalny werdykt. Głębokie konwolucyjne sieci neuronowe stanowiły kluczowe narzędzie zarówno w generowaniu deskryptorów numerycznych dla klasyfikatorów klasycznych, jak i w podejmowaniu ostatecznych decyzji dotyczących klasyfikacji. Opracowane systemy zostały zastosowane do analizy dermoskopowych obrazów czerniaka i mammograficznych obrazów raka piersi, co ma prowadzić do znaczącej poprawy dokładności rozpoznawania zmian nowotworowych.

W pracy została sformułowana następująca teza:

**„Zastosowanie odpowiednio zdefiniowanego zespołu klasyfikatorów głębokich CNN pozwala istotnie polepszyć zdolności generalizacji systemu klasyfikacyjnego i poprawić wynik rozpoznania klasy przypisanej różnym zmianom nowotworowym w stosunku do rezultatów osiągniętych przez indywidualne klasyfikatory.”**

Tematyka pracy ma charakter interdyscyplinarny, łączy w sobie w zasadzie trzy dyscypliny naukowe: Automatykę, Elektronikę, Elektrotechnikę i Technologie Kosmiczne, Informatykę i Telekomunikację oraz Nauki Medyczne.

Doktorant w swojej rozprawie doktorskiej podejmuje bardzo ważne, aktualne zagadnienie analizy zdjęć dermoskopowych i mammograficznych z wykorzystaniem sztucznych sieci neuronowych (SNN). Analiza ta, a konkretnie klasyfikacja obrazów medycznych, odgrywa kluczową rolę we wczesnym wykrywaniu czerniaka oraz raka piersi, co ma bezpośredni wpływ na skuteczność leczenia i przeżywalność pacjentów.

Czerniak jest jednym z najbardziej agresywnych i śmiertelnych nowotworów skóry, ale jego wczesne wykrycie znacząco zwiększa szanse na wyleczenie. Dermoskopia, polegająca na analizie

zdjęć skóry przy użyciu specjalistycznych narzędzi optycznych, jest standardową metodą diagnostyczną, ale wymaga dużej wiedzy i doświadczenia od lekarza. SNN mogą wspierać dermatologów w diagnozie poprzez automatyzację procesu, co pozwala na szybsze wykrywanie zmian skórnych. Sieci neuronowe, zwłaszcza te wykorzystujące głębokie uczenie (deep learning), są w stanie rozpoznać subtelne wzorce i anomalie w obrazach, które mogą być niewidoczne dla ludzkiego oka. Automatyzacja diagnostyki za pomocą SNN może również zmniejszyć ryzyko błędów ludzkich, takich jak zmęczenie czy subiektywna ocena.

Rak piersi jest z kolei jednym z najczęstszych nowotworów u kobiet, a jego wczesne wykrycie jest kluczowe dla skutecznego leczenia. Mammografia, czyli rentgenowskie badanie piersi, jest podstawowym narzędziem w wykrywaniu raka piersi. Wykorzystanie SNN w analizie zdjęć mammograficznych przynosi wiele korzyści. SNN mogą identyfikować mikrokalcyfikacje i inne wczesne objawy raka, które mogą być trudne do wykrycia w tradycyjnej analizie. Sieci neuronowe mogą wspierać radiologów, oferując drugą opinię i zwiększając precyzję diagnostyki. SNN mogą również przetwarzać i analizować setki tysięcy obrazów, co jest niezwykle ważne w programach przesiewowych, gdzie szybkie i dokładne wyniki są kluczowe.

Wykorzystanie sztucznych sieci neuronowych w analizie obrazów medycznych, takich jak dermoskopia i mammografia, ma potencjał do rewolucjonizowania diagnozy onkologicznej. SNN mogą uczyć się na podstawie ogromnych zbiorów danych, co pozwala na stałą poprawę wyników. Dzięki uczeniu się na coraz większej liczbie przypadków, ANN stają się coraz dokładniejsze. Analiza danych za pomocą ANN może prowadzić do bardziej spersonalizowanych planów leczenia, dostosowanych do indywidualnych potrzeb pacjentów. W regionach z ograniczonym dostępem do specjalistów, systemy oparte na ANN mogą zapewnić wysokiej jakości diagnozę i skrócić czas oczekiwania na wyniki.

Biorąc pod uwagę uzyskane przez Doktoranta wyniki badań oraz wybrane metodologie i narzędzia badawcze, recenzowana rozprawa doktorska w sposób istotny wpływa na rozwój dyscypliny naukowej Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne.

### **3. Struktura rozprawy**

Praca składa się ze 109 stron, w tym strona tytułowa, streszczenie w języku polskim oraz angielskim, spis treści, siedem rozdziałów oraz wykaz literatury, spis rysunków oraz tabel. Literatura obejmuje 72 pozycje, z czego Doktorant jest współautorem czterech, we wszystkich tych pracach jest pierwszym autorem. Dwie spośród tych prac są artykułami opublikowanymi w czasopiśmie międzynarodowych (*Bulletin of the Polish Academy of Sciences, Technical Sciences* oraz *Metrology and Measurement Systems*) oraz dwie – konferencyjnymi (CPEE 2020 i 2022).

Praca składa się z siedmiu rozdziałów. W rozdziale pierwszym opisany został zakres tematyczny rozprawy, przegląd literaturowy oraz cele i teza pracy. W rozdziale drugim przedstawione zostały analizowane zbiory danych NIO i ISIC – obrazów dermoskopowych czerniaka oraz DDSM – obrazów mammograficznych raka piersi. Rozdział trzeci dotyczy metod klasyfikacji obrazów, m.in. konwolucyjnych sieci neuronowych, drzew decyzyjnych czy maszyny wektorów nośnych. W rozdziale czwartym znajduje się opis zaproponowanych przez Doktoranta koncepcji tworzenia zespołów klasyfikatorów wraz z metodami ich ewaluacji. W rozdziałach piątym i szóstym Doktorant zestawia wyniki klasyfikacji obrazów odpowiednio dermoskopowych czerniaka oraz mammograficznych raka piersi wraz z szerokim porównaniem między zastosowanymi rozwiązaniami klasyfikacji obrazów. W rozdziale siódmym znajduje się

podsumowanie osiągniętych rezultatów wraz z możliwymi dalszymi kierunkami rozwoju zaproponowanych badań.

#### 4. Uwagi szczegółowe

Podczas czytania pracy nasunęło mi się kilka następujących uwag:

- 1) W pracy zabrakło wykazu skrótów. Już w streszczeniu pojawiają się angielskie skróty dla nazw różnych metod uczenia maszynowego, jak CNN czy SVN, a następnie we wstępie MLP, ReLU, itd. Ponadto zbiory NIO, ISIC i DDSM pojawiają się we wstępie, ale ich nazwy wyjaśnione są dopiero w rozdziale drugim.  
Dodatkową kwestią jest używanie nazw angielskich. Praca jest w języku polskim, więc o ile polskie nazwy istnieją, to właśnie one powinny być wykorzystywane, jak np. Maszyna Wektorów Nośnych zamiast Support Vector Machine.
- 2) W przeciwieństwie do powyższego punktu w pracy opisane zostały „zespoły modeli/klasyfikatorów”, które w literaturze angielskiej określane są mianem „ensemble models”, które to określenie nawet raz nie pojawia się w opisie teorii w rozprawie, za to nawet w publikacjach Doktoranta jest wykorzystywane.  
Odnosząc się do samych zespołów modeli/klasyfikatorów: w literaturze możemy znaleźć, że wyróżniamy dwa typy takich zespołów, mianowicie homogeniczne oraz heterogeniczne. Wszystkie klasyfikatory w zespole homogenicznym są tego samego typu, czyli mają taką samą architekturę i algorytm. Mogą jednak różnić się np. parametrami, inicjalizacją, zestawem danych treningowych (np. różnymi podzbiorami danych), co powoduje, że każdy klasyfikator w zespole ma nieco inne wyniki. Przykładem homogenicznego zespołu jest las losowy, gdzie wiele drzew decyzyjnych, będących tym samym algorytmem, działa razem, aby uzyskać lepsze wyniki. Zespół heterogeniczny składa się natomiast z różnych typów klasyfikatorów, które mogą opierać się na odmiennych algorytmach, takich jak SVM (Support Vector Machine), sieci neuronowe, drzewa decyzyjne, itd. Dzięki różnorodności klasyfikatorów, zespół heterogeniczny może lepiej radzić sobie z różnorodnymi danymi, ponieważ każdy klasyfikator ma inne mocne i słabe strony. W ten sposób można wykorzystać różne podejścia do rozwiązania problemu klasyfikacji, co może prowadzić do bardziej wszechstronnych i dokładniejszych wyników.  
Kończąc tę uwagę: zabrakło mi w pracy wielu treści, zarówno teoretycznych jak i później praktycznych. Jeśli chodzi o teoretyczne aspekty, to oczywiście mam na myśli chociażby powyższy podział modeli zespołowych na homogeniczne oraz heterogeniczne. Jeśli chodzi o praktyczne aspekty, to mam na myśli np. ocenę jakości zaproponowanych klasyfikatorów. Jednymi z podstawowych sposobów oceny klasyfikatora binarnego są wykresy typu ROC czy precision vs. recall, których zabrakło w pracy.
- 3) Autor pracy pokazuje wiele wykresów słupkowych, na których brakuje opisu osi. O ile np. diagramy na rysunku 5.1, 5.8 czy 5.10 są dla mnie oczywiste (wartości miar AUC, ACC, TPR, TNR, PPV czy NPV przyjmują wartości z zakresu  $<0,1>$ ), to diagramy przedstawione na rysunku 3.7 nie mają opisanych osi, ale również opis znajdujący się w tekście nie wyjaśnia jasno przedstawionych na diagramach wyników.
- 4) W ostatnich latach standardem w klasyfikacji obrazów medycznych stały się sieci neuronowe typu U-Net. Sieci te są standardowo wykorzystywane w przetwarzaniu obrazów medycznych ze względu na swoją architekturę, która jest szczególnie dobrze dopasowana do zadań segmentacji obrazów. U-Net składa się z części kontrakcyjnej, która kompresuje informacje i wyodrębnia cechy, oraz części ekspansyjnej, która rekonstruuje obraz, łącząc informacje z różnych poziomów abstrakcji. Dzięki temu U-Net może precyzyjnie

segmentować struktury o różnych rozmiarach i kształtach w obrazach medycznych, co jest kluczowe w diagnozowaniu i planowaniu leczenia. Ponadto, U-Net wymaga stosunkowo niewielkiej liczby próbek do treningu, co jest istotne w medycynie, gdzie dostępność oznakowanych danych często bywa ograniczona. Te cechy czynią U-Net wyjątkowo efektywnym narzędziem do dokładnej i szybkiej analizy obrazów medycznych, takich jak MRI, CT czy zdjęcia rentgenowskie.

W związku z powyższym: w pracy nie ma wzmianki nawet o tego typu sieciach neuronowych (w mojej opinii jest to kolejny brak teoretyczny), a co za tym idzie nie ma również uwzględnionych cytowań, które by dotyczyły tego typu rozwiązań. Czy jest możliwość aby ustosunkować się do tego, że takie sieci (które również są w pełni sieciami konwolucyjnymi, jednak o specyficznej strukturze) nie zostały uwzględnione w pracy, ani pod względem teoretycznym, ani nie były rozważane jako jeden z członów modelu zespołowego?

- 5) W pracy znajduje się sporo błędów edycyjnych, które sprawiają, że rozprawa ma nieco mniej naukowy wydźwięk, np.:
- w równaniach matematycznych funkcje zapisuje się czcionką prostą, np. softplus, ReLU, ln, exp, min, max, itp., podczas gdy w pracy są one napisane czcionką pochyłą;
  - rysunek 3.3 powinien być przetłumaczony na język polski;
  - rysunek 3.4 jest mało czytelny i wydaje się, że nie jest autorstwa Doktoranta, lecz nie posiada cytowania;
  - w dwóch ostatnich akapitach na stronie 37 dwa razy opisane są „metody opakowane”, podczas gdy w drugim z nich zdaje się, że powinny być „metody wbudowane”;
  - na stronie 87 znajduje się rysunek 6.2, jednak odwołanie do niego (powyżej rysunku) to 5.2;
  - w mojej opinii „czas działania” nie jest odpowiednim sformułowaniem, które jest zamiennie stosowane z „czasem uczenia”, które też do końca mi nie odpowiada;
  - nie odpowiada mi również określenie „członek zespołu” na poszczególne klasyfikatory wchodzące w skład zespołu modeli, może „człon” brzmiałby lepiej?

## 5. Wnioski końcowe

W moim odczuciu Doktorant wykazał się dużą wiedzą z zakresu opisanej w rozprawie tematyki badawczej, a także umiejętnie sformułował i udowodnił postawioną tezę.

Pomimo pewnych usterek, które posiada rozprawa, moja ocena pracy mgra inż. Fabiana Gila jest pozytywna. Moim zdaniem recenzowana praca prezentuje cenne wyniki badań z punktu widzenia zarówno zastosowanych metod uczenia maszynowego jak i medycyny. Stanowi ona znaczące osiągnięcie w dyscyplinie naukowej Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne oraz w mojej ocenie wszystkie wymogi stawiane rozprawom doktorskim w Ustawie z dnia 20 lipca 2018 r. – Prawo o szkolnictwie wyższym i nauce (Dz.U. 2023 r. poz. 742 z późn.zm.).

Podsumowując wnioskuję do Rady Dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne o dopuszczenie Pana mgra inż. Fabiana Gila do dalszych etapów przewodu doktorskiego, w tym do publicznej obrony.

dr hab. inż. Aleksandra Świetlicka