



„Zastosowanie konwolucyjnych sieci neuronowych do klasyfikacji obrazów medycznych z wykorzystaniem wyjaśnialnej sztucznej inteligencji”

inż. Kacper Mielańczyk

dr inż. Piotr Dzierwa

Uniwersytet Opolski, Wydział Matematyki, Fizyki i Informatyki, Instytut Informatyki

- Rak piersi – jeden z najczęściej diagnozowanych nowotworów u kobiet; w Polsce ok. **22,8%** nowych rozpoznań onkologicznych
- **Mammografia** – podstawowe badanie przesiewowe, wykrywa zmiany niewyczuwalne palpacyjnie (guzy, mikrozwapnienia)
- Ograniczenia diagnostyki mammograficznej:
 - subiektywność i zależność od doświadczenia radiologa
 - zmienność ocen między specjalistami, przypadki graniczne
 - maskowanie zmian przez tkankę o dużej gęstości
- **Konwolucyjne sieci neuronowe (CNN)** – automatyczna ekstrakcja cech obrazowych, wsparcie diagnostyki
- Problem „czarnej skrzynki” $\Rightarrow$ potrzeba metod **wyjaśnialnej sztucznej inteligencji (XAI)**


Cel: ocena zastosowania sieci ResNet18 do klasyfikacji zmian mammograficznych oraz zbadanie wpływu jakości danych i interpretowalności predykcji.

Zadanie: klasyfikacja binarna wycinków (cropów) mammograficznych ze zbioru **CBIS-DDSM**:


- **MASS** – zmiany guzowate
- **CALC** – zwapnienia

Dane wejściowe: 3568 cropów (1696 MASS, 1872 CALC)
Zakres ograniczono do klasyfikacji wycinków – analiza zgodności wymiarowej mammogramów i masek ROI wykazała ich niejednorodność.

Źródło: opracowanie własne / CBIS-DDSM



CALC – zwapnienia



MASS – zmiana guzowata

Dla każdego cropa obliczono wskaźnik jakości technicznej *quality_score* (ostrość, kontrast lokalny, poziom szumu) i przypisano poziom: **HIGH / MEDIUM / LOW**.

Wariant danych	Liczba próbek	MASS	CALC
ALL (pełny zbiór)	3568	1696	1872
FILTERED (bez LOW)	2390	1136	1254


- Usunięto **1178** cropów (**33%**) ocenionych jako niskiej jakości (LOW)
- Cel: sprawdzenie, czy poprawa jakości technicznej danych przekłada się na jakość klasyfikacji
- Kontrola nakładania się pacjentów train/test oraz spójności ścieżek plików

Architektura

- ResNet18 (*transfer learning*, wagi z ImageNet)
- zamrożony ekstraktor cech, trenowana wyłącznie warstwa Linear(512,2)
- 1026 parametrów trenowalnych z 11,18 mln łącznie

Trening


- 50 epok, batch size = 32, AdamW (lr = 0,001)
- funkcja straty: CrossEntropyLoss
- augmentacja: rotacja, translacja, skalowanie
- wybór checkpointu wg najlepszego F1-score





Wariant	ACC	Prec.	Recall	F1
ALL	0,8381	0,7896	0,8865	0,8353
FILTERED	0,8385	0,8492	0,7972	0,8224

ROC-AUC: 0,9081 (ALL) vs. **0,9205** (FILTERED) | Loss: 0,3952 vs. **0,3631**

- Niemal identyczna **accuracy** ($\approx 0,838$) – ale odmienny profil decyzji!
- **ALL**: wyższa czułość (recall) na klasę CALC
- **FILTERED**: wyższa precyzja i lepsza separacja klas
- **Wniosek**: filtracja jakościowa zmienia charakter błędów modelu, nie daje jednoznacznej przewagi



Krzywe ROC modeli ALL i FILTERED



- Błędy częstsze przy niższej jakości cropa, ale występowały też w obrazach jakości HIGH/MEDIUM
- Główne źródła trudności: **podobieństwo wizualne** klas MASS/CALC, niejednoznaczne zmiany, cropy oznaczone jako "podobne do przeciwnej klasy"
- ALL: 77 błędów FP / 37 FN | FILTERED: 30 błędów FP / 43 FN

Metody


- **Grad-CAM** – mapa aktywacji ostatniej warstwy konwolucyjnej (layer4[-1])
- **Occlusion Sensitivity** – wpływ zasłaniania fragmentów obrazu na predykcję
- Analiza 30 przypadków: predykcje poprawne, błędne (wysoka pewność) oraz graniczne

Obserwacje


- **MASS** – aktywacje rozległe, obejmujące większy obszar zmiany
- **CALC** – aktywacje lokalne, skupione na jasnych punktowych strukturach
- Poprawne predykcje wysokiej pewności → mapy czytelne i skupione na zmianie
- Błędy i przypadki graniczne → aktywacje rozproszone / przesunięte na tło

Zgodność obu metod (6/30 przypadków w pełni zgodnych) zwiększa wiarygodność interpretacji decyzji modelu.


Poprawne CALC




Poprawne MASS



Błąd FP (MASS→CALC)



Błąd FN (CALC→MASS)



Źródło: opracowanie własne (praca dyplomowa, rozdz. 4.7)

- Kontrola jakości danych wejściowych jest niezbędnym elementem pracy z obrazami mammograficznymi
- Filtracja jakościowa **nie jest automatycznie korzystna** – poprawia selektywność kosztem czułości modelu
- Pojedyncza metryka (accuracy) **nie wystarcza** do rzetelnej oceny modelu medycznego
- Metody XAI ujawniają informacje niedostępne w samych metrykach, ale nie zastępują oceny eksperckiej

Ograniczenia: klasyfikacja cropów (nie pełnych mammogramów), podział danych na poziomie wycinków, brak walidacji zewnętrznej, wagi pretrenowane na danych niemedycznych (ImageNet)

- Praca stanowi **wielowymiarową ocenę** wpływu jakości danych na klasyfikację obrazów mammograficznych z użyciem CNN
- Połączono: kontrolę jakości danych + trening ResNet18 + analizę błędów + interpretację XAI
- **Kierunki dalszych badań:** walidacja na niezależnych zbiorach, podział na poziomie pacjenta, architektury dedykowane obrazowaniu medycznemu, ekspercka ocena map XAI

Dziękuję za uwagę