

POLITECHNIKA WARSZAWSKA

Wydział Elektroniki i Technik Informacyjnych

ROZPRAWA DOKTORSKA

mgr inż. Anna Wróblewska

Metody wspomaganie detekcji zmian patologicznych  
w mammografii

Promotor  
dr hab. inż. Artur Przelaskowski

Warszawa, 2008



---

# Podziękowania

---

Serdecznie dziękuję promotorowi dr hab. inż. Arturowi Przelaskowskiemu za pomysły wielu nowatorskich rozwiązań, cenne, merytoryczne uwagi i pomoc w pisaniu niniejszej pracy oraz prof. dr hab. Przemysławowi Wojtaszczykowi z Instytutu Matematyki Stosowanej i Mechaniki Uniwersytetu Warszawskiego za wskazówki teoretyczne i wsparcie.

Pragnę też gorąco podziękować lekarzom radiologom: dr Ewie Wesołowskiej z Centrum Onkologii, lek. med. Pawłowi Surowskiemu z Zakładu Diagnostyki Obrazowej Szpitala Wolskiego oraz lek. med. Indze Barańskiej z Instytutu Gruźlicy i Chorób Płuc w Warszawie za konsultacje i cenne wskazówki medyczne. W czasie długotrwałych testów zaimplementowanych narzędzi mogłam obserwować ich pracę, sposoby diagnozowania, co stało się dla mnie niezwykle cennym doświadczeniem naukowym, a także życiowym.

Dziękuję też mgr inż. Rajmundowi Kożuszkowi z Politechniki Warszawskiej za pomysł zastosowania metody grupowania DBSCAN, mgr inż. Andrzejowi Bodzkowi z firmy ACSYS B.s.c. za cenne odpowiedzi implementacyjne podczas tworzenia systemu *MammoViewer* oraz mgr Teresie Podsiadły-Marczykowskiej z Instytutu Biocybernetyki i Inżynierii Biomedycznej PAN, z którą na pewnym etapie pracy intensywnie współpracowałam.

Szczególnie jednak pragnę podziękować mojemu ukochanemu mężowi Pawłowi oraz dwóm córeczkom – Anielce i Rozalce, którzy towarzyszyli mi podczas przygotowywania niniejszej pracy. To przede wszystkim oni nauczyli mnie wytrwałości, stawiania sobie wysokich wymagań oraz pokonywania kolejnych trudności. Wyrazy wdzięczności kieruję także do ks. Jana O’Dogherty, który przez cały czas wspierał naszą rodzinę.

Założone zadania zostały zrealizowane dzięki częściowemu finansowaniu: z grantu pt. „Modelowanie informacji istotnej diagnostycznie w dziedzinie przekształceń falkowych do zastosowań radiologii cyfrowej” (KBN 3 T11E 014 28), przez Fundację Wspierania Rozwoju Radiokomunikacji i Technik Multimedialnych oraz Fundację na Rzecz Nauki Polskiej.



---

# Teza pracy

---

Zaproponowane metody komputerowego wspomaganie diagnostyki, będące integracją wybranych metod przetwarzania, analizy, rozpoznawania i rozumienia danych obrazowych w teleinformatycznym środowisku cyfrowej stacji diagnostycznej, pozwalają zwiększyć efektywność interpretacji badań mammograficznych.

Opracowany system wspomaganie diagnostyki mammograficznej, implementujący te wybrane metody – *MammoViewer* może być przydatny w praktyce klinicznej.



---

# Spis treści

---

Teza pracy	v
Spis treści	vii
Spis symboli i skrótów	xi
Wprowadzenie	1
<b>1 Komputerowe wspomaganie diagnostyki obrazowej</b>	<b>9</b>
1.1 Problemy w diagnostyce badań obrazowych . . . . .	10
1.2 Cele systemów wspomagania diagnostyki . . . . .	10
1.2.1 Detekcja zmian patologicznych . . . . .	11
1.2.2 Poprawa percepcji zmian patologicznych . . . . .	11
1.2.3 Opis obrazowanych zmian . . . . .	12
1.2.4 Pomiar cech struktur . . . . .	12
1.2.5 Klasyfikacja zmian . . . . .	12
1.2.6 Diagnoza obrazowanych zmian . . . . .	13
1.3 Przydatność CADD w procesie diagnozy . . . . .	13
1.4 Schemat przetwarzania informacji w systemach CADD . . . . .	14
1.5 Kryteria oceny systemów CAD . . . . .	16
1.6 Rozwój metod wspomagania diagnostyki – systemy komercyjne CAD	16
1.7 Wspomaganie badań mammograficznych . . . . .	19
1.7.1 Badania mammograficzne i powstające obrazy . . . . .	19
1.7.2 Podstawowe obrazowane patologie . . . . .	23
1.7.3 Charakterystyka stosowanych metod CADD w mammografii	31
<b>2 Metody i algorytmy, stosowane w systemach wspomagania diagnostyki do mammografii</b>	<b>39</b>
2.1 Przetwarzanie wstępne – poprawa jakości obrazów . . . . .	40
2.1.1 Metody histogramowe . . . . .	41
2.1.2 Filtracja w dziedzinie obrazu . . . . .	43
2.1.3 Operatory morfologiczne . . . . .	44
2.1.4 Przetwarzanie w wielu skalach . . . . .	45

2.1.5	Ocena jakości metod poprawy percepcji . . . . .	51
2.1.6	Uwydatnianie mikrozwapnień . . . . .	56
2.2	Detekcja potencjalnych guzów i zaburzeń architektury . . . . .	58
2.2.1	Detekcja, bazująca na analizie pojedynczych pikseli . . . . .	58
2.2.2	Detekcja, bazująca na analizie regionów . . . . .	60
2.3	Detekcja potencjalnych mikrozwapnień . . . . .	61
2.3.1	Lokalizacja . . . . .	61
2.3.2	Segmentacja . . . . .	68
2.3.3	Klasteryzacja . . . . .	69
2.4	Ekstrakcja i selekcja cech . . . . .	72
2.4.1	Właściwości zaczerpnięte bezpośrednio z wiedzy medycznej oraz danych klinicznych . . . . .	72
2.4.2	Właściwości obrazu zmian patologicznych, wyznaczane au- tomatycznie . . . . .	74
2.5	Klasyfikatory . . . . .	79
2.5.1	Sieci neuronowe jednokierunkowe trójwarstwowe . . . . .	79
2.5.2	Sieć neuronowa o radialnej funkcji bazowej . . . . .	81
2.5.3	Maszyny wektorów nośnych . . . . .	82

<b>3</b>	<b>System wspomagania diagnostyki mammograficznej – Mam- moViewer</b>	<b>83</b>
3.1	Opis narzędziowy systemu . . . . .	84
3.1.1	Proste operacje na obrazach . . . . .	86
3.1.2	Przetwarzanie i analiza w dziedzinie obrazu . . . . .	86
3.1.3	Wielorozdzielcza analiza obrazów . . . . .	87
3.2	Dobór warunków prezentacji – interfejs dla radiologa . . . . .	88
3.3	Metoda poprawy percepcji guzów i mikrozwapnień . . . . .	94
3.3.1	Optymalizowane parametry przetwarzania w dziedzinie fal- kowej . . . . .	94
3.3.2	Cel eksperymentów . . . . .	94
3.3.3	Wstępne testy doboru parametrów . . . . .	95
3.3.4	Kolejne testy optymalizacyjne porównawcze z udziałem ra- diologa . . . . .	103
3.3.5	Ogólne wnioski i dalsze konsultacje z radiologami . . . . .	110
3.4	Segmentacja gruczołu piersiowego . . . . .	112
3.4.1	Wstępny algorytm segmentacji tkanki piersi . . . . .	112
3.4.2	Uzasadnienie potrzeby optymalizacji algorytmu . . . . .	113
3.4.3	Optymalizacja algorytmu segmentacji gruczołu piersiowego	113
3.5	Detekcja klastrów potencjalnych mikrozwapnień . . . . .	120
3.5.1	Lokalizacja jasnych plamek . . . . .	120
3.5.2	Klasteryzacja . . . . .	123
3.5.3	Segmentacja obiektów potencjalnych mikrozwapnień . . . . .	131
3.6	Ekstrakcja cech pojedynczych mikrozwapnień i klastrów . . . . .	135
3.6.1	Opis potencjalnych mikrozwapnień . . . . .	135

3.6.2	Właściwości morfologiczne i numeryczne metody opisu właściwości klastrów mikrozwapnień dla ontologii i indeksowania obrazów . . . . .	137
3.7	Klasyfikacja . . . . .	138
3.8	Rozszerzenie obszaru zastosowań . . . . .	139
3.8.1	Detekcja potencjalnych guzków . . . . .	140
3.8.2	Detekcja zaburzeń architektury . . . . .	141
3.8.3	Doskonalenie metod indeksowania po zawartości . . . . .	141
3.8.4	Wspieranie systemu ontologii mammografii . . . . .	142
3.8.5	Koncepcja zintegrowanego interfejsu wspomaganie do stacji diagnostycznej . . . . .	142
<b>4</b>	<b>Eksperymenty</b>	<b>145</b>
4.1	Bazy testowych mammogramów . . . . .	145
4.1.1	DDSM . . . . .	145
4.1.2	Własne obrazy . . . . .	146
4.1.3	Ograniczenia testowych baz . . . . .	146
4.2	Detekcja potencjalnych klastrów mikrozwapnień . . . . .	147
4.2.1	Cel . . . . .	147
4.2.2	Testy wstępne detekcji półautomatycznej . . . . .	147
4.2.3	Testy detekcji automatycznej . . . . .	155
4.2.4	Analiza wyników . . . . .	155
4.2.5	Test detekcji na obrazach po stratnej kompresji – wyniki . . . . .	158
4.3	Klasyfikacja mikrozwapnień . . . . .	160
4.3.1	Testy wstępne . . . . .	160
4.3.2	Zasadnicze testy weryfikacyjne . . . . .	161
4.4	Testy kliniczne wpływu wspomaganie komputerowego na detekcję i diagnozę radiologów . . . . .	168
4.4.1	Cel . . . . .	168
4.4.2	Zestaw obrazów testowych . . . . .	168
4.4.3	Obserwatorzy – lekarze radiolodzy . . . . .	171
4.4.4	Procedura testu . . . . .	171
4.4.5	Wyniki . . . . .	173
4.4.6	Uwagi i opinie radiologów . . . . .	180
4.4.7	Dyskusja . . . . .	185
<b>5</b>	<b>Podsumowanie</b>	<b>189</b>
	<b>Lista publikacji, związanych z rozprawą</b>	<b>191</b>
	<b>Bibliografia</b>	<b>195</b>
<b>A</b>	<b>Obliczenia z programu DBM MRMC, pracującego na wynikach testów klinicznych – porównanie krzywych ROC</b>	<b>211</b>

A.1	Analiza dla trzech radiologów: Reader 1 – Ekspert, Reader 2 – Stażysta, Reader 3 – Specjalista . . . . .	211
A.2	Analiza dla dwóch doświadczonych radiologów: Reader 1 – Ekspert, Reader 2 – Specjalista . . . . .	214
<b>B</b>	<b>Obliczenia z programu ROCKIT, pracującego na wynikach testów klinicznych</b>	<b>217</b>
B.1	I tura – oryginał, trzech radiologów: Ekspert, Stażysta, Specjalista	217
B.2	II tura – oryginał, trzech radiologów: Ekspert, Stażysta, Specjalista	218
B.3	II tura – przetworzone, trzech radiologów: Ekspert, Stażysta, Specjalista . . . . .	220
B.4	II tura – przetworzone+AWPKM, trzech radiologów: Ekspert, Stażysta, Specjalista . . . . .	221
B.5	I tura – oryginał, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista . . . . .	223
B.6	II tura – oryginał, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista . . . . .	224
B.7	II tura – przetworzone, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista . . . . .	225
B.8	II tura – przetworzone+AWPKM, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista . . . . .	227
<b>C</b>	<b>Współczynniki filtrów falkowych, używanych w eksperymentach z poprawą percepcji</b>	<b>231</b>
<b>D</b>	<b>Szczegółowe wyniki klasyfikacji</b>	<b>233</b>
<b>E</b>	<b><i>Mammo Viewer</i> – dokumentacja systemu do analizy i obróbki obrazów mammograficznych</b>	<b>241</b>

---

## Spis symboli i skrótów

---

Skrót	Opis	Definicja
ACC	dokładność, procent prawidłowo zaklasyfikowanych przypadków	strona 178
AD	średnia różnica ( <i>Average Difference</i> )	strona 51
AHE	adaptacyjna korekcja histogramu	strona 42
ALOE	histogramu lokalnych orientacji krawędzi	strona 58
AR	powierzchnia obiektu – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
AWPKM	automatyczne wskazania potencjalnych klastrów mikrozwapnień, na obrazie są pokazywane tylko kwadratowe symbole znajdujące się w centroidzie wykrytego klastra	strona 171
BAC	średni poziom szarości tła obiektu – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
BIM0-BIM6	moment niezmienniczy 0-7 z obrazu binarnego – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 164
BI-RADS	System opisu medycznego w dziedzinie terminologii mammograficznej (obecnie standard)	strona 23
BR	<i>box ratio</i> – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
CAD	komputerowe wspomaganie detekcji ( <i>Computer-Aided Detection</i> )	strona 11
CADD	komputerowe wspomaganie diagnozy ( <i>Computer-Aided Diagnosis</i> )	strona 13
CBIR	system indeksowania po zawartości ( <i>Content-Based Image Retrieval</i> )	strona 13

---

Skrót	Opis	Definicja
CC	projekcja kranio-kaudalna w badaniu mammograficznym	strona 19
CII	indeks poprawy kontrastu	strona 52
CLAHE	adaptacyjna korekcja histogramu z możliwością ograniczania kontrastu	strona 42
CM	zwartość – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-*	właściwości tekstury liczone z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
CM-CO	kontrast liczony z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-COR	korelacja liczona z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-COV	kowariancja liczona z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-EN	entropia liczona z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-EE	energia liczona z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-IDM	odwrotny moment różnicowy liczony z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CM-SEN	entropia rozkładu sumacyjnego liczona z macierzy zdarzeń – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
CORR	<i>Corrcoef</i> – metoda selekcji właściwości na podstawie ich wartości – cech	strona 163
CQ	znormalizowany błąd średniokwadratowy ( <i>Correlation Quality</i> )	strona 52
CT	tomografia komputerowa	strona 139

Skrót	Opis	Definicja
DBSCAN	algorytm grupowania sygnałów <i>Density Based Spatial Clustering of Applications with Noise</i>	strona 123
DDSM	baza badań mammograficznych, dostępna w Internecie [64] ( <i>Digital Database for Screening Mammography</i> )	strona 145
DR	skontrastowanie obiektu i tła – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 52
DSM	miara separacji rozkładów ( <i>Distribution Separation Measure</i> )	strona 52
EAUC	wyznaczone eksperymentalnie pole pod krzywą ROC, liczone z surowych (nieaprosymowanych danych)	strona 178
EE	energia – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 135
EFR3	efektywny promień $EFR3=IM3/IM4$ – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 164
EG	wydłużenia właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
Eks, Ekspert	radiolog ekspert, biorący udział w testach przyjętych rozwiązań	strona 171
ELD1, ELD2	stopień eliptyczności – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
ESM	średnia siła krawędzi – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 95
ESSD	odchylenie standardowe wyrazistości krawędzi – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 135
FAUC	pole pod krzywą ROC, wyznaczaną na podstawie aproksymacji wyników testów	strona 178
FBD	różnica poziomów szarości obiektu i tła – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 135

Skrót	Opis	Definicja
FBR	stosunek średniego poziomu szarości obiektu i tła – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
FDA	<i>Food and Drug Administration</i>	strona 17
FN	przypadki fałszywie negatywne ( <i>False Negative</i> )	strona 54
FP	przypadki fałszywie pozytywne, fałszywe wskazania ( <i>False Positive</i> )	strona 54
FPF	frakcja przypadków fałszywie pozytywnych	strona 54
FPI	średnia liczba fałszywych wskazań na obraz ( <i>False Positives per Image</i> )	strona 33
FPIwB	średnia liczba fałszywych wskazań na obraz bez uwzględniania oczywistych, niepodejrzanych zmian łagodnych, zwykle nieopisanych w bazach referencyjnych	strona 149
FROC	krzywe (wykresy), służące do analizy czułości w zależności od liczby FP na obraz ( <i>Free-Response Receiver Operating Characteristic</i> )	strona 16
GLCM	macierz powinowactwa (zdarzeń) <i>Gray Level Co-occurrence</i>	strona 76
GLDM	macierz <i>Gray Level Difference</i>	strona 76
GLRLM	macierz <i>Gray Level Run-Length</i>	strona 76
IF	dokładność rekonstrukcji obrazu ( <i>Image Fidelity</i> )	strona 52
IM0-IM6	moment niezmienniczy 0-7 – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 136
INFOG	<i>Infogain</i> – metoda selekcji właściwości na podstawie ich wartości – cech	strona 163
L, H	podpasma dolno- i górnoprzepustowe po dekompozycji falkowej	strona 48
LL, LH, HL, HH	podpasma tworzone podczas dekompozycji falkowej dla sygnałów dwuwymiarowych – obrazów	strona 50
LoG	filtry <i>Laplacian-of-Gaussian</i>	strona 62
LoGR	odpowiedź filtru <i>LoG</i> z metody lokalizacji (opisanej w p. 3.5)	strona 135
LOGRAT	<i>Logratio</i> – metoda selekcji właściwości na podstawie ich wartości – cech	strona 163
MD	maksymalna różnica ( <i>Maximal Difference</i> )	strona 51
MDIAM	maksymalna średnica – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 137
MLO	projekcja skośna (przyśrodkowo-boczna) w badaniu mammograficznym	strona 19
MR	rezonans magnetyczny	strona 35
MSE	błąd średniokwadratowy ( <i>Mean Square Error</i> )	strona 51

Skrót	Opis	Definicja
MX	średni poziom szarości – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 135
PACS	<i>Picture Archiving and Communication System</i>	strona 33
PCA	analiza składowych głównych – metoda redukcji właściwości	strona 72
PSNR	szczytowy stosunek sygnału do szumu ( <i>Peak Signal to Noise Ratio</i> )	strona 51
PWTH	algorytm progowania <i>white top-hat</i>	strona 131
RBF	radialna funkcja bazowa	strona 82
RC	względny kontrast – stosunek średniego poziomu szarości wzdłuż konturu do wartości najjaśniejszego piksela obiektu – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 164
REL	<i>Relief</i> – metoda selekcji właściwości na podstawie ich wartości – cech	strona 163
RG1, RG2	„chropowatość” konturu – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
ROC	<i>Receiver Operating Characteristic</i>	strona 54
ROI	region zainteresowania, zwykle większy region, zawierający podejrzaną zmianę z sąsiedztwem ( <i>Region of Interest</i> )	strona 15
ROS	region chorobowym zaznaczonym przez lekarza radiologa w bazie badań mammograficznych ( <i>Region of Suspiciousness</i> )	strona 148
RSNA	Amerykańskie Towarzystwo Radiologiczne ( <i>Radiological Society of North America</i> )	strona 17
SBS	metoda redukcji właściwości stosująca porównywanie efektywności klasyfikacji poprzez wyrzucanie właściwości, niedających istotnej informacji z początkowego zestawu właściwości ( <i>Sequential Backward Selection</i> )	strona 72
SD	miara tekstury – odchylenie standardowe poziomów jasności wewnątrz obiektu – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>MammoViewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 135
SE	czułość ( <i>sensitivity</i> )	strona 54

Skrót	Opis	Definicja
SEC	czułość liczona na przypadkach – badaniach. Podstawowe badanie mammograficzne składa się z 4 obrazów. Jeśli w danym przypadku jest obecna podejrzana zmiana, jest ona widoczna na 2 obrazach – projekcji MLO i CC. Wskazanie prawdziwie pozytywne odnotowuje się, jeśli analizowana metoda oznacza co najmniej raz podejrzaną zmianę – w jednej z dwóch projekcji.	strona 34
SFS	metoda redukcji właściwości stosująca porównywanie efektywności klasyfikacji poprzez dokładanie kolejnych właściwości ( <i>Sequential Forward Selection</i> )	strona 72
SIM	<i>Simba</i> – metoda redukcji właściwości, bazujące na optymalizacji marginesu	strona 72
SM1-SM4	momenty kształtu 1-4 – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>Mammo Viewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 135
SNN	sztuczna sieć neuronowa	strona 79
Spe, Specjalista	radiolog specjalista, biorący udział w testach przyjętych rozwiązań	strona 171
SPEC	specyficzność ( <i>specificity</i> )	strona 55
SRDM	macierz <i>Surrounding Region-Dependance</i>	strona 61
Sta, Stażysta	radiolog stażysta, biorący udział w testach przyjętych rozwiązań	strona 171
SVM	maszyna wektorów nośnych ( <i>Support Vector Machine</i> )	strona 82
test PMN	eksperyment dotyczący opisu potencjalnych mikrozwapnień — klasyfikacji: potencjalne mikrozwapnienie-norma (prawidłowa tkanka)	strona 161
test K	eksperyment dotyczący klasyfikacji kształtów pojedynczych mikrozwapnień	strona 161
TN	przypadki prawdziwie negatywne ( <i>True Negative</i> )	strona 54
TP	przypadki prawdziwie pozytywne ( <i>True Positive</i> )	strona 54
TPF	frakcja przypadków prawdziwie pozytywnych	strona 54
TR	trójkątność – właściwość oraz jej numeryczna metoda opisu zaimplementowana w systemie <i>Mammo Viewer</i> (definicja podana w dokumentacji systemu – załącznik E)	strona 138
1-NN	metoda klasyfikacji najbliższego sąsiada	strona 162

---

# Wprowadzenie

---

Intensywny rozwój technologiczny kilku ostatnich dekad spowodował rewolucję w diagnostyce obrazowej. Istnieje nagła potrzeba komputerowego wsparcia pracy lekarzy, w tym radiologów i onkologów. Wzrost ilościowy i jakościowy danych medycznych, dotyczących różnych schorzeń, sprawia, że analiza badań obrazowych staje się coraz trudniejsza, coraz bardziej złożona. Skuteczną pomocą jest często wykorzystanie metod komputerowego wspomaganie detekcji i diagnozy podejrzanych zmian, czyli włączenie technologii komputerowej w proces wykrywania i rozpoznawania anomalii w badaniach obrazowych.

Najgroźniejszym nowotworem złośliwym kobiet jest rak piersi<sup>1</sup>. Każdego roku 8 tysięcy Polek zapada na raka piersi, a 5 tysięcy umiera z tego powodu [42]. Statystyki wykazują, że w Polsce zajmuje on pierwsze miejsce pod względem zachorowań na nowotwory kobiet, ponadto jest najczęstszą przyczyną śmierci u kobiet z wykrytym rakiem [36].

Najskuteczniejszą, według obecnego stanu wiedzy, metodą przesiewowego wykrywania raka piersi jest w wielu przypadkach, przede wszystkim u kobiet powyżej 50. roku życia, mammografia rentgenowska [42]. Za pomocą mammografii można wykryć małe guzki, mikrozwapnienia lub inne nieprawidłowości piersi, zanim będą wyczuwalne podczas badań palpacyjnych.

Spośród wszystkich patologii piersi, mikrozwapnienia są jednym z ważniejszych objawów, umożliwiającym wczesne wykrycie raka piersi. Mammografia jest podstawowym badaniem w ich ocenie ilościowej i jakościowej [123]. Na obrazach rentgenowskich mikrozwapnienia wyglądają jak drobne jasne plamki (o średnicach od 0,1 do kilku milimetrów) o różnej charakterystyce kształtu i tekstury, występujące najczęściej w skupiskach. Ten subtelny typ zmiany jest szczególnie trudny dla radiologów do wykrywania i rozpoznawania [99].

Ogólnie mammografia jest uznawana za najtrudniejszą modalność w interpretacji diagnostycznej. Bardzo ważne jest tu doświadczenie radiologa. Do tej pory nie wyznaczono jednoznacznie standardu dla określenia prawidłowej budowy piersi. Odniesieniem w ocenie jest zwykle obraz drugiej piersi, a przy kolejnych badaniach – porównanie ze zdjęciami poprzednimi [123, 42]. Zdarza się, że nawet

---

<sup>1</sup>W terminologii medycznej prawidłową nazwą „piersi” jest „sutek”. W rozprawie użyto powszechnie przyjętego terminu „pierś”.

doświadczeni radiolodzy niezależnie od siebie wydają różne diagnozy, dotyczące tego samego przypadku. Błędy w diagnostyce mogą dotyczyć przeoczenia zmiany widocznej (zwyrodnienia czasem są bardzo małe lub ukryte w zdrowej tkance) lub niewłaściwej oceny wykrytej patologii (m.in. rozróżnienia pomiędzy zmianami złośliwymi i łagodnymi).

Uznaną metodą poprawy skuteczności diagnozy jest druga opinia lub wykorzystanie systemów CAD (*Computer Aided Detection*), zatwierdzonych w ostatnich latach przed FDA (*Food and Drug Administration*), np. *ImageChecker* [73] zaaprobowany do badań przesiewowych już w 1998 roku.

Konsultacje kilku lekarzy, dotyczące tego samego przypadku, zwiększają skuteczność mammografii o około 15% [78], ale jednocześnie zmniejszają wydajność ich pracy. Natomiast czułość jednego radiologa wspieranego przez system wspomagania detekcji CAD, może wzrosnąć od 7% do 19,5% [38].

Komputerowe wspomaganie diagnostyki raka piersi pozwala w większym stopniu zobiektywizować interpretację zdjęć mammograficznych i zmniejszyć konieczny nakład pracy lekarzy. Jego celem jest pomoc lekarzowi w wydawaniu prawidłowej diagnozy (zwiększenie dokładności diagnostycznej) poprzez zwiększenie możliwości detekcji i właściwej oceny patologii.

Komputerowa analiza i przetwarzanie cyfrowych obrazów mammograficznych są wykorzystywane do poprawy jakości obrazów, lepszej prezentacji zawartej w nich informacji diagnostycznej oraz automatycznej detekcji i klasyfikacji podejrzanych zmian w tkance. Komputerowe wspomaganie diagnostyki oraz komputerowa detekcja różnych radiologicznych anomalii są dziedzinami, które rozwijają się intensywnie w ostatnich latach [78, 97], a mimo tego w wielu przypadkach są zawodne.

## Motywacja i przebieg prac

Oprócz powyższych rozważań, wykazujących, jak ważne są projektowanie i realizacja systemów wspomagających tak trudną modalność jak mammografia, poniżej przedstawiam koncepcje oraz kolejne cele, które stawiałam sobie podczas wykonywania prac, związanych z niniejszą rozprawą.

Od początku przyświecał mi cel realizacji aplikacji – systemu, który będzie mógł być w przyszłości wykorzystany przez radiologów, będzie wspomagał ich pracę w fazie analizy badań mammograficznych. Dodatkowym moim założeniem było stworzenie wygodnego środowiska (*framework*) do implementacji i testowania różnych algorytmów, przede wszystkim przetwarzania i analizy obrazów. Wykorzystanie istniejących dostępnych aplikacji, służących do przetwarzania obrazów, okazało się niewystarczające, przede wszystkim ze względu na specyfikę obrazów mammograficznych i problemy ich analizy. W obrazach mammograficznych dominują różne rodzaje tekstur, a zmiany są często słabo skonstrastowane. Ponadto współcześnie cyfrowe obrazy mammograficzne mają głębię koloru 2-bajtową (10-, 12-, 16-bitową) oraz są to bardzo duże obrazy (rzędu 4-5,5 tys. na 6-7 tys. pikseli). Opracowany system *MammoViewer* pozwalał na realizację wielu metod przetwarzania obrazów oraz ich optymalizację, w tym na stworzenie

modułu przetwarzania w dziedzinie falkowej, zawierającego wiele nowatorskich rozwiązań.

System *MammoViewer* był udoskonalany o różne metody przetwarzania i analizy obrazów. Początkowo były to częściej spotykane algorytmy z możliwością ich optymalizacji – dostosowywania parametrów do zagadnienia przetwarzania obrazów mammograficznych. Następnie dodawałam coraz bardziej nowatorskie pomysły. Opracowałam wygodny interfejs do przeglądania obrazów medycznych różnych modalności oraz ich porównywania. Ponadto *MammoViewer* został wykorzystany w pracowni<sup>2</sup> do badań nad detekcją wczesnego udaru mózgu w badaniach tomografii komputerowej, przetwarzania i analizy obrazów ultrasonograficznych oraz obrazów radiologicznych innych modalności niż mammografia.

Niezbędna okazała się szczegółowa charakterystyka patologii obrazowanych w mammografii. Ponieważ właściwie wszystkie opracowania tego typu są napisane językiem medycznym, potrzebne było usystematyzowanie tej wiedzy, jej obiektywizacja i przystosowanie do tworzenia deskryptorów, charakteryzujących poszczególne patologie. Numeryczny opis zmian został wykorzystany w detekcji oraz opisie i klasyfikacji tychże patologii. W późniejszym etapie prac nawiązałam współpracę z mgr Teresą Podsiadły-Marczykowską, zajmującą się ontologią mammografii, z którą udoskonaliłyśmy medyczno-matematyczną charakterystykę patologii.

W pierwszej fazie prac nad metodami wspomagania diagnostyki mammograficznej skoncentrowałam się na metodach detekcji i analizy pojedynczych potencjalnych mikrozwapnień: ich lokalizacji, segmentacji oraz implementacji numerycznych metod opisu ich właściwości. Następnie analizowałam metody grupowania potencjalnych mikrozwapnień w klastry. Opracowałam metodę półautomatyczną detekcji klastrów potencjalnych mikrozwapnień z ręcznym wyborem najistotniejszego parametru. Potem podjęłam próbę automatyzacji metody detekcji, tak aby mogła wskazywać w całym obszarze piersi na mammogramie potencjalne klastry mikrozwapnień, które radiolog powinien zweryfikować (przyglądając się bardziej szczegółowo wskazanemu obszarowi). Bardzo istotne w fazie pełnej automatyzacji okazało się opracowanie algorytmów segmentacji gruczołu piersiowego w celu odrzucenia zaszumionego tła w ucyfrowionych obrazach mammograficznych.

Następnie powstała koncepcja wykorzystania falkowych metod poprawy percepcji zmian patologicznych w mammografii. W systemie *MammoViewer* opracowałam narzędzia do przetwarzania w dziedzinie falkowej, zawierające nowatorskie elementy, takie jak możliwość manualnego kształtowania funkcji przekształceń w wybranych podpasmach transformaty oraz różne formy wizualizacji i selekcji rozkładu współczynników falkowych. Celem była przede wszystkim poprawa percepcji drobnych zmian patologicznych (słabo widocznych, takich jak mikrozwapnienia, zagęszczenia, spikule w guzkach), tak aby radiolog mógł łatwiej je wykryć lub też zauważyć subtelne oznaki, towarzyszące większym zmianom, które często zmieniają interpretację/diagnozę. Opracowanie metod poprawy percepcji

---

<sup>2</sup>Pracownia Komputerowego Wspomagania Diagnostyki Medycznej na Wydziale Elektroniki i Technik Informacyjnych, gdzie wykonywałam moją pracę doktorską.

przebiegało w kilku etapach, przy ścisłej współpracy z radiologami.

W końcowej fazie prac, przy współudziale trzech lekarzy radiologów, przeprowadzono testy wpływu opracowanych metod na diagnozę lekarską. Wykazały one użyteczność kliniczną opracowanego systemu *MammoViewer*.

Należy tutaj zauważyć, że stworzony system *MammoViewer* miał za zadanie wspomaganie pracy lekarzy radiologów, a więc nie była to próba redukcji wpływu lekarza na proces diagnostyczny, ale ułatwienie stawiania lepszych diagnoz przez radiologów. Bardzo ważną podczas prac okazała się obserwacja pracy lekarza specjalisty i rzeczywistych jego potrzeb oraz zrozumienie przedmiotu badań. Stąd rozbudowany opis właściwości zmian patologicznych, obrazowanych w mammografii. W fazie realizacji położyłam też większy nacisk na metody opisu i przetwarzania obrazów: tworząc metodę wstępnej detekcji, wskazującą regiony podejrzane o występowanie klastrów mikrozwapnień oraz metody poprawy percepcji zmian w obrazie. Rozbudowany został także blok ekstrakcji cech wysegmentowanych regionów zainteresowania. Następnie podjęłam próbę klasyfikacji wysegmentowanych potencjalnych mikrozwapnień w celu wstępnej weryfikacji. Jednakże celem badań nie była pełna automatyzacja diagnozy. Współcześnie nie istnieją systemy komercyjne, akceptowane przez FDA, podejmujące automatyczne decyzje diagnostyczne, a zadanie to wydaje się bardzo trudne, wymagające łączenia wyników badań z różnych modalności.

## Teza pracy

**Zaproponowane metody komputerowego wspomagania diagnostyki, będące integracją wybranych metod przetwarzania, analizy, rozpoznawania i rozumienia danych obrazowych w teleinformatycznym środowisku cyfrowej stacji diagnostycznej, pozwalają zwiększyć efektywność interpretacji badań mammograficznych.**

**Opracowany system wspomagania diagnostyki mammograficznej, implementujący te wybrane metody – *MammoViewer* może być przydatny w praktyce klinicznej.**

## Szczegółowe cele pracy – przyjęta metodologia

1. Zaprojektowanie i realizacja systemu wspomagającego diagnostykę mammograficzną – *MammoViewer*, spełniającego następujące wymagania:
  - a) efektywna prezentacja obrazów mammograficznych oraz umożliwienie wygodnej manipulacji danymi obrazowymi (m.in. doboru warunków prezentacji), w celu użyteczności systemu w warunkach klinicznych,
  - b) zapewnienie wygodnego środowiska oprogramowania (*framework*) do testowania algorytmów analizy i przetwarzania obrazów, m.in. poprawy percepcji, automatycznej detekcji i segmentacji patologii w celu dalszej rozbudowy systemu,

- c) zapewnienie otwartej architektury, umożliwiającej integrację z innymi rozwiązaniami i pracami badawczymi, m.in. realizowanymi przez innych członków zespołu, w celu kompleksowego wsparcia procesu diagnozy,
  - d) dołączenie zaawansowanego narzędzia do analizy wielorozdzielczej oraz innych metod przydatnych w obróbce obrazów, zwiększających skuteczność opisu zmian i charakterystyki ich właściwości.
2. Opracowanie metod poprawy percepcji zmian patologicznych (w szczególności mikrozwapnień).
  3. Opracowanie metod automatycznej detekcji skupisk potencjalnych mikrozwapnień oraz segmentacji mikrozwapnień.
  4. Opracowanie metod klasyfikacji potencjalnych mikrozwapnień.
  5. Wspieranie ontologii mammografii oraz indeksowania w bazie badań mammograficznych – realizacja teleinformatycznego środowiska cyfrowej stacji diagnostycznej, m.in. poprzez segmentację i wybór matematycznych metod opisu właściwości mikrozwapnień.
  6. Weryfikacja metod poprawy percepcji oraz automatycznej detekcji mikrozwapnień – przeprowadzenie m.in. testów klinicznych przyjętych rozwiązań.

## Organizacja pracy

Ogólna koncepcja systemów wspomaganie diagnostyki obrazowej, ze szczególnym uwzględnieniem mammografii jako modalności najtrudniejszej w diagnostyce oraz charakterystyka cech obrazowych najważniejszych zmian patologicznych w mammografii zostały opisane w rozdziale 1. Rozdział 2 rozprawy zawiera przegląd stosowanych metod i narzędzi wspomaganie diagnostyki w mammografii oraz sposoby oszacowania ich przydatności.

W rozdziale 3 przedstawiono opracowany system wspomaganie diagnostyki mammograficznej *Mammo Viewer*. Zaprezentowano własną koncepcję systemu, narzędzia dostępne w systemie oraz jego funkcjonalność, w tym proponowane: algorytmy i metody poprawy percepcji wybranych zmian patologicznych, detekcji, segmentacji i klasyfikacji mikrozwapnień w mammografii. Dalej opisano także inne zastosowania systemu do badań w dziedzinie kompresji, metody lokalizacji zaburzeń architektury i segmentacji potencjalnych guzków w mammografii, a także wykorzystanie opracowanych algorytmów do indeksowania obrazów w bazie badań mammograficznych oraz wspierania systemu ontologii mammografii.

Weryfikacja eksperymentalna algorytmów (poprawa percepcji, detekcja i klasyfikacja mikrozwapnień), testy kliniczne przy współudziale lekarzy radiologów oraz analiza wyników zostały przedstawione w rozdziale 4.

Całość pracy podsumowano w ostatnim rozdziale.

## Efekty prac badawczych i oryginalny dorobek autorki

Do nowatorskich osiągnięć autorki, zawierających oryginalne rozwiązania i własne koncepcje, należy zaliczyć przede wszystkim:

1. koncepcja i realizacja systemu do wspomagania diagnostyki obrazowej *MammoViewer* (opis w rozdziale 3):
  - z interfejsem dostosowanym do pracy radiologa, blokiem doboru warunków prezentacji obrazów do potrzeb stacji diagnostycznej,
  - zawierającego szereg zaawansowanych narzędzi do wizualizacji obrazów, zestaw podstawowych operacji obrazowych (m.in. operatory morfologiczne),
  - z modułem optymalizacji przekształceń falkowych wielorozdzielczych z doбором bazy oraz z wizualizacją efektów przetwarzania,
  - narzędzia do optymalizacji metod – środowiska do tworzenia i testowania algorytmów, m.in. przetwarzania obrazów oraz detekcji, segmentacji i ekstrakcji cech,
  - systemu o otwartej architekturze, umożliwiającej integrację z innymi systemami wspomaganie pracy diagnosty/radiologa – platformy badań nad zintegrowaną stacją diagnostyczną,
2. opracowanie i zaimplementowanie metod poprawy percepcji objawów patologicznych poprzez nieliniowe przetwarzanie mammogramów w dziedzinie falkowej (opis w p. 3.3 oraz testy w p. 4.4),
3. opracowanie i zaimplementowanie metody detekcji skupisk mikrozwapnień (opis w p. 3.5 oraz testy w p. 4.2 i p. 4.4), w tym:
  - optymalizacja metody lokalizacji pojedynczych obiektów potencjalnych mikrozwapnień, bazującej na filtracji *Laplacian-of-Gaussian*,
  - opracowanie algorytmu segmentacji zlokalizowanych obiektów,
  - zastosowanie metody klasteryzacji, bazującej na analizie gęstości obiektów z uwzględnieniem szumu DBSCAN – oraz dostosowanie jej do zagadnienia detekcji skupisk mikrozwapnień,
4. zaimplementowanie szeregu numerycznych metod opisu właściwości pojedynczych obiektów i skupisk mikrozwapnień (opis w p. 3.6 oraz w załączniku E)
5. metoda wstępna klasyfikacji pojedynczych mikrozwapnień (opis w p. 3.6, 3.7 oraz wyniki testów w p. 4.3),
6. rezultaty szeregu konsultacji z radiologami, wyniki testów klinicznych metod poprawy percepcji zmian patologicznych i wpływu automatycznych wskazań na diagnozę lekarską, wykazujące użyteczność systemu *MammoViewer* w praktyce klinicznej (konsultacje były przeprowadzane w niemal

każdej fazie budowy systemu i jego weryfikacji, testy kliniczne opisano w p. 4.4).

7. rezultaty eksperymentów poprawy efektywności i weryfikacji opracowanych narzędzi (opis w rozdziale 4).
8. wybór numerycznych metod opisu właściwości do redukcji wskazań fałszywych mikrozwapnień i klasyfikacji skupisk w zależności od jednorodności (praca zespołowa z mgr Teresą Podsiadły-Marczykowską – udział autorki 50%; opis w p. 3.6.2, zastosowano w [16]),
9. usystematyzowanie wiedzy dotyczącej właściwości obrazowych najważniejszych patologii w mammografii (praca zredagowana wspólnie z mgr Teresą Podsiadły-Marczykowską – udział autorki 50%; opis w p. 1.7.1 i 1.7.2),

System *Mammo Viewer* znalazł zastosowanie także w innych badaniach naukowych, które nie były prowadzone bezpośrednio przez autorkę, ale wykorzystywały elementy systemu i prac autorki, m.in. w trzech rozprawach doktorskich (jedna w fazie finalnej) oraz w jednej pracy inżynierskiej na Politechnice Warszawskiej [16, 8, 76]. W systemie *Mammo Viewer* zostały zrealizowane:

- metoda lokalizacji zaburzeń architektury [76] (krótki opis w p. 3.8.2),
- segmentacja tkanki gruczołu piersiowego (następnie na bazie tej metody autorka stworzyła nowy algorytm segmentacji piersi, opisany w rozprawie) (opis w p. 3.4),
- metoda detekcji i segmentacji potencjalnych guzów [20] (krótki opis w p. 3.8.1).

System został również wykorzystany w badaniach nad stratną kompresją mammogramów [122] oraz progresją wiarygodności [128], w badaniach nad poprawą percepcji wczesnego niedokrwienego zawału mózgu w tomografii komputerowej [8].

Ponadto wybrane algorytmy *Mammo Viewera* służą jako moduł indeksowania po zawartości w bazie referencyjnych badań mammograficznych *IShark* [18, 16]. Metodę segmentacji i ekstrakcji cech wykorzystano także do wspierania ontologii mammografii – klasyfikacji kształtów mikrozwapnień według trzech charakterystycznych typów. Na bazie przeprowadzonych badań zespołowych powstała koncepcja integracji systemu *Mammo Viewer* z ontologią mammografii oraz referencyjną bazą obrazów, mająca na celu realizację nowatorskiej koncepcji zintegrowanej stacji diagnostycznej. Powyższe dodatkowe zastosowania zostały opisane w p. 3.8 „Rozszerzenie obszaru zastosowań”.



## Rozdział 1

---

# Komputerowe wspomaganie diagnostyki obrazowej

---

Rozdział ten zawiera ogólne wprowadzenie w problematykę systemów wspomagania. Podano definicje podstawowych zagadnień istotnych w komputerowym wspomaganiu diagnostyki obrazowej. Omówiono wybrane problemy związane z diagnozowaniem badań obrazowych. Zdefiniowano cele systemów wspomagających oraz podano kilka przykładów zastosowań. Na bazie opracowanego tła teoretycznego zaprojektowano otwartą architekturę systemu *MammoViewer*, opisanego w rozdziale 3.

Następnie, już na bardziej szczegółowym poziomie, dokonano analizy mammografii jako obecnie najtrudniejszego w interpretacji badania obrazowego. Podano usystematyzowany przegląd właściwości patologii obrazowanych w mammogramach. Celem charakterystyki było przygotowanie do tworzenia numerycznych metod opisu wybranych, istotnych diagnostycznie właściwości. Przedstawiono systemy komercyjne do wspomagania detekcji zmian patologicznych (CAD), kryteria oceny oraz skuteczność takich systemów, w celu porównania z realizowanym systemem *MammoViewer*.

Opisano także krótko inne badania, zajmujące się obrazowaniem piersi. Obecnie mammografia uznawana jest za standardową procedurę w badaniach przesiewowych i diagnostyce raka piersi, ale inne badania mają także istotne znaczenie. Na końcu rozdziału omówiono kierunki rozwoju wspomagania diagnostyki piersi, przede wszystkim mammograficznej. Wykazano, że opracowany system wpisuje się we współczesne kierunki badań naukowych nad wspomaganiem diagnostyki piersi.

\* \* \*

Poprawna interpretacja obrazów medycznych, możliwie czuła percepcja i trafna ocena zmian wymagają, obok dużego doświadczenia diagnostycznego, także zna-

jomości technicznych uwarunkowań konkretnego systemu obrazowania. Dlatego też komputerowe wspomaganie oraz automatyczna analiza danych stają się coraz bardziej niezbędne i istotne, tak aby uzyskać odpowiedni poziom efektywności.

Można przyjąć uproszczoną definicję obrazu (szczególnie w kontekście obrazowania medycznego) jako mieszaniny: konturów, tekstur i tła o znaczeniu (treści semantycznej), odnoszącym się do wiedzy i doświadczeń obserwatora oraz określonych warunków rejestracji/rekonstrukcji/formowania obrazu. Relacja pomiędzy semantyką, rozkładem konturów i krawędzi, charakterystyką tekstur i tła stanowi informację obrazową interpretowaną (odczytywaną, ustaloną) przez obserwatora lub też algorytmy i metody wspomagające diagnostykę obrazową [126].

Komputerowe wspomaganie diagnostyki powinno pomagać lekarzom w prawidłowym rozumieniu obrazów medycznych. System komputerowego wspomaganie diagnostyki to zestaw wyrafinowanych metod (algorytmów, rozwiązań technologicznych, narzędzi inteligencji obliczeniowej itp.) analizy i interpretacji określonych cech obrazowych (oraz dodatkowych informacji) w celu wsparcia radiologa przy sformułowaniu diagnozy (rozszerzenie definicji z [126]).

W ostatnich latach nastąpił i ciągle trwa bardzo intensywny rozwój systemów wspomaganie diagnostyki obrazowej – badań radiologicznych [68, 69], m.in.: mammografii, rentgenografii płuc, angiografii, tomografii komputerowej płuc, mózgu, rezonansu magnetycznego, badań ultrasonograficznych.

## 1.1 Problemy w diagnostyce badań obrazowych

Zdarza się, że nawet doświadczeni radiolodzy niezależnie od siebie różnie opisują oraz wydają różne diagnozy, dotyczące tego samego przypadku. Przyczynami obniżającymi skuteczność diagnostyczną badań obrazowych są zmienność w opisie badań obrazowych i w ich ocenie, błędy percepcji zmian oraz niedokładna analiza (błędy interpretacji) [118, 119]. Powyższe błędy obserwatora-człowieka zwykle zwiększają się poprzez: złą jakość obrazów, zmęczenie, brak doświadczenia oraz czynniki zewnętrzne (złe oświetlenie itp.) [126].

## 1.2 Cele systemów wspomaganie diagnostyki

Ogólnie w radiologii interpretację obrazów można podzielić na trzy zasadnicze zadania [46]: detekcję (dostrzeżenie zmian, percepcję), opis (proces opisu i interpretacji cech) i diagnozę (ostateczny wynik, ewentualnie określenie dalszych wymagań diagnostycznych). Stąd celem komputerowego wspomaganie jest zwiększenie dokładności diagnostycznej poprzez poprawę warunków detekcji, właściwej oceny i opisu oraz klasyfikacji patologii przez radiologa.

Z drugiej strony taki podział zadań systemów wspomaganie wydaje się trochę sztuczny. Korzyści z dostrzeżenia i odpowiedniej interpretacji zmian wzajemnie się przenikają i wpływają na siebie. Jeśli radiolog będzie mógł łatwiej zauważyć pewne cechy obrazu, będzie też mógł lepiej je opisać i zinterpretować, jeśli lekarz ma dostęp do większej wiedzy, lepiej i szybciej interpretuje poszczególne cechy obrazu, łatwiej dostrzeże pewne zmiany.

### 1.2.1 Detekcja zmian patologicznych

Najszybszy postęp można zaobserwować w dziedzinie systemów wspomaganie detekcji zmian patologicznych (CAD – *Computer-Aided Detection*). Można je zdefiniować jako zestaw wyrafinowanych metod (algorytmów, rozwiązań technologicznych, narzędzi sztucznej inteligencji itd.) detekcji cech związanych z patologią [126].

Takie systemy okazują się być szczególnie przydatne w badaniach skriningowych (przesiewowych), takich jak mammografia oraz rentgenografia płuc. W badaniach skriningowych najważniejszym celem jest wykrycie zmian bezobjawowych klinicznie u pacjentów bez podejrzenia choroby. W ogromnej ilości obrazów – badań skriningowych rzadko znajduje się zmiany patologiczne, jednak konsekwencje przeoczenia potencjalnie złośliwej zmiany są katastrofalne.

Systemy wspomaganie detekcji mogą być wykorzystywane do wskazania (sugestii) potencjalnych zmian patologicznych oraz do wykluczania przypadków zdrowych (prawidłowych – bez podejrzanym zmian), zmniejszając w ten sposób nakłady pracy lekarzy. CAD ma przyciągnąć uwagę radiologa do podejrzanym zmian, ocenionych przez komputer jako mających cechy raka. W tym kontekście CAD służy jako „druga para oczu” (*'second pair of eyes', 'second opinion'*).

### 1.2.2 Poprawa percepcji zmian patologicznych

Zakres komputerowego wspomaganie obejmuje także poprawę:

- jakości diagnostycznej obrazów, służącą lepszej widoczności struktur oraz zmniejszeniu widoczności szumów i artefaktów<sup>1</sup>,
- warunków prezentacji informacji diagnostycznej, służących lepszej percepcji (postrzeganiu) zmian oraz lepszemu scharakteryzowaniu cech patologii (m.in. precyzyjna identyfikacja anatomicznego zasięgu anomalii, własności jej obrazu, np.: rozmiar, wygląd zarysu, kształt, gęstość, tekstura, relacja do tła).

Wynikiem metod poprawy percepcji ma być uwydatnienie zmian patologicznych, uzyskane przede wszystkim poprzez:

- odszumienie – usunięcie lub redukcję (stłumienie) szumów oraz informacji nieistotnej dla diagnozy,
- wzmocnienie lokalnego kontrastu oraz inne metody wzmocniania cech istotnych dla diagnozy w celu uwydatnienia krawędzi, konturów zmian oraz podkreślenia innych cech zmian patologicznych (tekstury wewnątrz patologii oraz w jej otoczeniu, kształtu zmian, relacji do tła),
- zapewnienie lepszych warunków wizualizacji (korekta histogramu), dobranie odpowiednich warunków prezentacji badań (np. dobór okna w badaniu tomografii komputerowej CT),

---

<sup>1</sup>Artefakty to małe — o powierzchni kilku pikseli obiekty, np. rysa, pyłek, który osiadł na zdjęciu rentgenowskim podczas skanowania itp.

Metody przetwarzania obrazu, uwydatniające zmiany, aby poprawić ich percepcję, powinny być:

- dostosowane do typów zmian (*'lesion specific'*),
- dostosowane do cech zmian (*'feature specific'*), np. metody uwydatniające kontury, teksturę, szczegóły wewnątrz zmiany.

Ważne jest także zapewnienie odpowiednich warunków: technicznych, ergonomicznych i organizacyjnych w pracy specjalisty (rola stacji diagnostycznej) [118, 129].

### 1.2.3 Opis obrazowanych zmian

Komputerowe wspomaganie etapu opisu zmian dotyczy poprawy warunków prezentacji informacji diagnostycznej (jak wyżej) oraz samego procesu i sposobu opisu zmian – używanej terminologii, pojęć opisujących właściwości anomalii oraz relacji pomiędzy pojęciami. Mogą mieć tutaj zastosowanie systemy ontologii, służące do formalnej reprezentacji wiedzy medycznej (wiedzy o dziedzinie) używanej do semantycznego opisu i przede wszystkim interpretacji zmian w kategoriach diagnozy obiektów w obrazie [118].

Ontologia jest tutaj środkiem do standaryzacji opisu oraz redukcji zmienności w interpretacji (obiektywizacja opisu). W systemach ontologii można wykorzystywać także wiedzę i pojęcia odnoszące się do obrazu wraz z odpowiadającymi im deskryptorami matematycznymi i metodami przetwarzania. Tak rozumiana ontologia może być jasna dla lekarza radiologa (użytkownika systemu) oraz dla samego systemu komputerowego. System zyskuje „zrozumienie” semantycznej informacji podczas etapu przetwarzania obrazu. Zadaniem systemu jest ekstrakcja cech zmiany (w tym również lokalizacji) i przedstawienie ich w postaci obiektywnej obliczeniowo. Końcowym wynikiem takiego przetwarzania jest odpowiedź semantyczna, zrozumiała dla lekarza. [117, 116].

### 1.2.4 Pomiary cech struktur

Komputerowe wspomaganie jest także wykorzystywane do pomiarów struktur, które pojawiają się w zdrowej tkance oraz do pomiaru rozwoju choroby – rozwoju struktur patologicznych. Pod pojęciem „pomiaru” można rozumieć nie tylko określenie rozmiarów zmian, ale także określenie stopnia zmian tekstury, wyrazistości krawędzi, gęstości itp. Przydatne jest to w ocenie progresji choroby oraz w ocenie ilościowej terapii.

### 1.2.5 Klasyfikacja zmian

Pojęcie klasyfikacji zmian łączy się z ich opisem. Komputerowe wspomaganie może zostać użyte do klasyfikowania zmian w różnych kategoriach (pojęciach) oraz do grupowania zmian podobnych wykorzystywanego przez systemy indeksowania

### 1.3. PRZYDATNOŚĆ CADD W PROCESIE DIAGNOZY

po zawartości – CBIR (*Content-Based Image Retrieval*) przy wyszukiwaniu wiedzy w bazie danych klinicznych. Klasyfikowanymi obiektami mogą być nie tylko same zmiany patologiczne, ale też np. typ budowy tkanki obrazowanego narządu.

Kluczowymi kwestiami są tu definicja pojęcia podobieństwa (związku) pomiędzy klasyfikowanymi obiektami, tzn. podział przestrzeni obiektów na klasy (kategorie, pojęcia) oraz możliwość precyzyjnego przeszukiwania dużych baz danych badań (obrazów z danymi klinicznymi) [17, 18].

#### 1.2.6 Diagnoza obrazowanych zmian

Najtrudniejszym aspektem interpretacji badania jest diagnoza – wymaga ona syntezy informacji obrazowej (m.in. cech obrazu zmian, także porównania z wcześniejszymi badaniami), wiedzy semantycznej (znaczenia obrazu w kategoriach diagnozy – „wiedzy medycznej”) oraz danych klinicznych (wieku pacjenta, wywiadu, objawów choroby, danych demograficznych).


System komputerowego wspomaganą diagnozy (CADD – *Computer-Aided Diagnosis*) można zdefiniować jako zestaw wyrafinowanych metod (algorytmów, rozwiązań technologicznych, narzędzi sztucznej inteligencji itp.) analizy i interpretacji określonych cech obrazowych (oraz dodatkowych informacji) w celu sformułowania diagnozy różnicującej (na zmiany łagodne i złośliwe) [126].

### 1.3 Przydatność CADD w procesie diagnozy

Radiolog podejmuje decyzję diagnostyczną na podstawie wcześniejszej samodzielnej analizy badań obrazowych, danych klinicznych (wywiad, badanie przedmiotowe), praktyki klinicznej (m.in. wyniku weryfikacji poprzednich decyzji diagnostycznych) oraz wyniku wspomaganą komputerowego. Wynikiem komputerowego wspomaganą może być przetworzony obraz, symbol oznaczający podejrzone miejsce, wartość numeryczna np. określająca stopień podejrzenia zmiany o złośliwość, opis cech charakterystycznych zmiany, baza podobnych przypadków lub inna sformalizowana wiedza. Schemat podejmowania decyzji jest przedstawiony na rys. 1.1.

W szczególności system CAD może pomóc radiologowi w detekcji patologii we wczesnym stadium złośliwości (bardzo subtelną) [75, 38]. Ponadto wspomaganą komputerowe pozwala w większym stopniu zobiektywizować interpretację badań obrazowych (zmniejszyć różnice w diagnozach, wydawanych przez różnych radiologów lub też przez jednego, ale w różnym czasie) oraz zmniejszyć nakłady pracy lekarzy [53, 84]. Najważniejszą ostateczną decyzję podejmuje jednak zawsze lekarz, a wskazania systemu mają jedynie charakter sugestii.

Zwykle diagnoza jednego lekarza przy wspomaganą komputerowym na ogół będzie mniej skuteczna niż konsultacje dwóch lub więcej radiologów, dotyczące jednego badania, ale może być efektywniejsza niż samodzielna diagnoza lekarza bez wspomaganą. Najnowsze wyniki wykazują, że efektywność radiologa przy wspomaganą komputerowym jest porównywalna, a nawet nieznacznie wyższa od konsultacji dwóch lekarzy [55]. W USA systemy CAD często są stosowane jako tzw. drugie spojrzenie zamiast konsultacji z drugim radiologiem. Problemem



Rysunek 1.1: Uproszczony schemat procesu diagnozy badania obrazowego, przeprowadzany przez radiologa przy zastosowaniu komputerowego systemu wspomaganie. (Udoskonalony schemat, bazujący na pracach [53, 46].)

jest jednak fakt, że sugestie systemu CADD mogą być łatwo zignorowane przez radiologa [84].

Jednak na przykładzie wspomaganie detekcji zmian: nawet w przypadku współdziałania kilku lekarzy CAD może wskazać zmiany, które zostały niezauważone i zwiększyć skuteczność detekcji. Testy przeprowadzone w USA dla mammografii skriningowej wykazały wzrost liczby wykrytych raków o 7%, nawet w przypadku analizowania badań przez dwóch lekarzy z dodatkową pomocą systemu CAD [35]. Przydatność systemu komputerowego nie oznacza, że jest on „lepszy” — skuteczniejszy niż radiolog, ale że jest w stanie wykryć niektóre zmiany, które mogą zostać niezauważone przez lekarza. Wspomaganie detekcji może być użyteczne nawet w badaniach diagnostycznych (ocena wcześniej wykrytych patologii), gdzie rak może znajdować się także w innym obszarze niż wskazanie z badania klinicznego, tzw. detekcja kliniczne niepodjejranych raków [25].

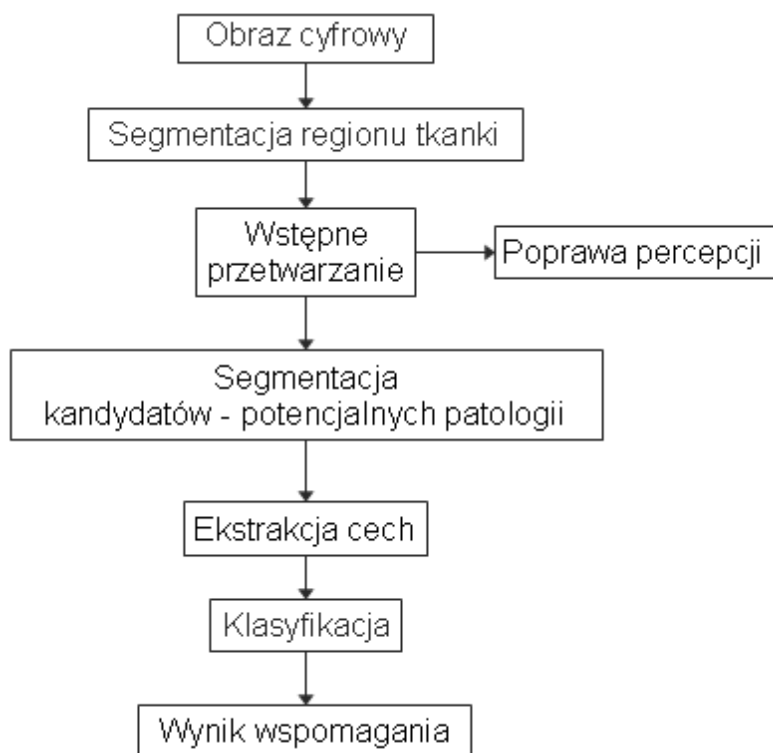
## 1.4 Schemat przetwarzania informacji w systemach CADD

Całościowa architektura systemu CADD powinna zawierać moduły do przetwarzania i analizy obrazów, a także bazę danych obrazowych i klinicznych, zakodowaną wiedzę, informację zwrotną, pochodzącą ze zweryfikowanych badań obrazowych [46]. Jednak w dalszej części rozprawy będzie mowa głównie o module dotyczącym bezpośrednio przetwarzania obrazu – w tym kontekście będzie stosowana nazwa systemu CADD – ze szczególnym uwzględnieniem systemów wspomaganie

#### 1.4. SCHEMAT PRZETWARZANIA INFORMACJI W SYSTEMACH CADD

detekcji CAD.

Ogólny schemat systemu CADD został przedstawiony na rysunku 1.2. Dany-  
mi wejściowymi dla systemu są obrazy cyfrowe. By oszczędzić czas przetwarzania,  
dokonuje się segmentacji obszaru tkanki użytecznej, odrzucając zaszumione i nie-  
istotne diagnostycznie tło.



Rysunek 1.2: Schemat narzędziowy systemu CAD/CADD. (Udoskonalony schemat, zaczerpnięty z pracy [53].)

Wstępne przetwarzanie służy do poprawy percepcji oraz przygotowania obrazów w celu zwiększenia efektywności metod systemów CAD/CADD, np. selekcji regionów zainteresowania (ROI), które są bardziej podatne na wystąpienie patologii.

Do ekstrakcji potencjalnej patologii służą techniki segmentacji (m.in. różnego typu progowanie, metody rozrostu regionów). Następnie dla każdej potencjalnej patologii są obliczane cechy. Ze zbioru cech należy wybrać te najlepiej rozróżniające poszczególne klasy patologii (selekcja cech), np. pozwalające skutecznie rozdzielić kandydatów. Do wybranego zbioru można dodać też dane kliniczne (wiek pacjenta, dane wywiadu rodzinnego – obecność pewnych zachorowań w rodzinie itp.) oraz wyniki innych dodatkowych badań. Najczęściej stosowane metody klasyfikacji, to: analiza dyskryminacyjna, sieci neuronowe, maszyna wektorów nośnych lub inne hybrydowe klasyfikatory [150].

Analizując zagadnienie projektowania systemów wspomagania, okazuje się,

że właściwie każdy z bloków: wstępnego przetwarzania, segmentacji patologii, klasyfikacji powinien składać się rekurencyjnie z takich samych podbloków, wyprofilowanych jednak odpowiednio do ściśle określonych celów (rys. 1.3b). Już w fazie wstępnego przetwarzania należy określić pewne interesujące właściwości i w jakiś sposób je sklasyfikować, np. zdefiniować szum.

Algorytmy detekcji (segmentacji) patologii na ogół składają się z dwóch etapów (rys. 1.3) [138]:

1. detekcja podejrzanych regionów w obrazie – zastosowanie m.in. skutecznych technik segmentacji w celu uzyskania jak najwyższej czułości, by nie pominąć żadnego „podejrzanego” obszaru,
2. klasyfikacja wykrytych regionów jako podejrzanej lub niepodejrzanej tkanki w celu uzyskanie wysokiej specyficzności wskazań przy zadowalającym poziomie czułości.

W niektórych metodach w poszczególnych krokach (rys. 1.3b) wykorzystywane są bardzo zaawansowane algorytmy, niekiedy znacznie prostsze. Na przykład na pierwszym etapie detekcji często klasyfikacja zostaje zredukowana do prostego progowania lub usuwania regionów o powierzchni mniejszej od zadanej wartości.

Wynikiem systemu CAD/CADD może być przetworzony obraz, lokalizacja zmiany – symbol oznaczający podejrzane miejsce (np. gwiazdka, strzałka), wyodrębniony region podejrzanej zmiany (dokładne granice zmiany), wartość numeryczna (np. oszacowane prawdopodobieństwo złośliwości) lub też sugestia dalszego postępowania (leczenia).

## 1.5 Kryteria oceny systemów CAD

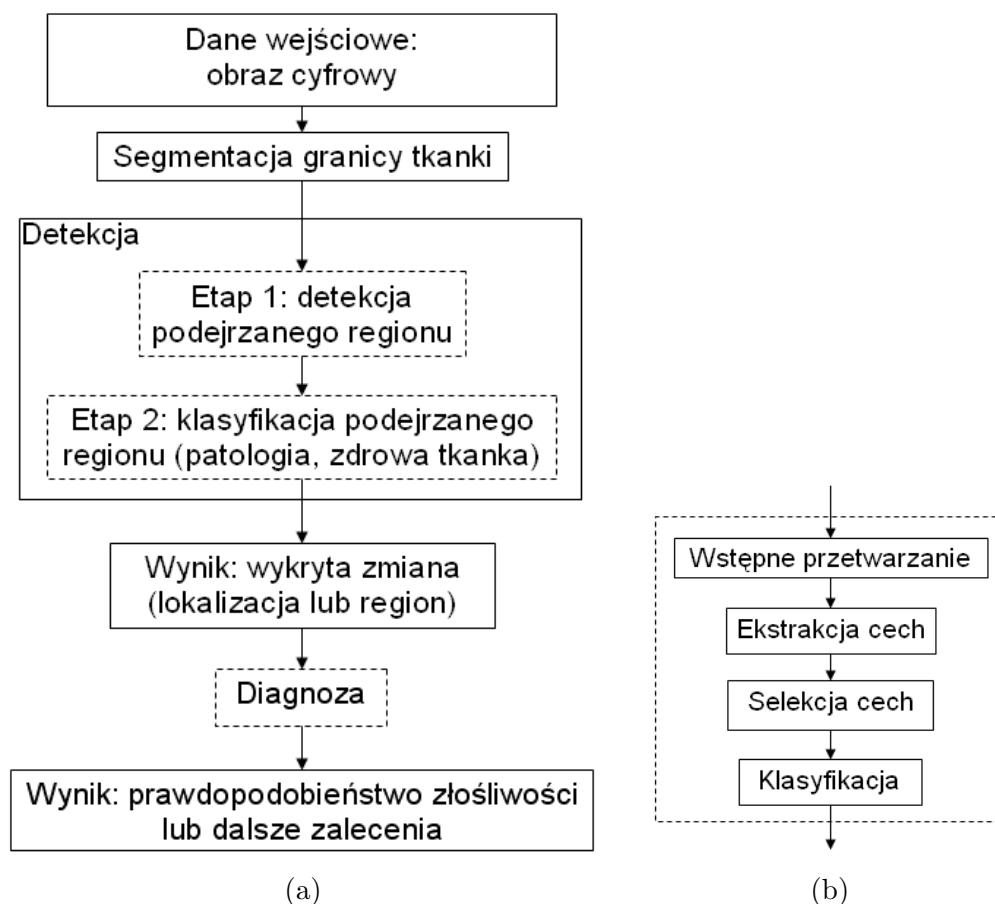
Ocena systemów CAD (wspomagania detekcji) polega na oszacowaniu wydajności automatycznej komputerowej metody detekcji ze względu na czułość i liczbę wskazań fałszywych średnio na obraz (FP – *'false positives'*) – analizie wykresów czułości w zależności od liczby FP na obraz (krzywe FROC – *'Free-Response Receiver Operating Characteristic'*) [138].

Jednak ostatecznym testem jest badanie jakości diagnozy radiologów, którzy używają danego systemu wspomaganie komputerowego – wpływ systemu CAD na praktykę kliniczną, tj. testy obserwacyjne, które mierzą efektywność radiologa pracującego samodzielnie oraz pracującego ze wsparciem systemu CAD (analiza statystyczna) [53, 38].

## 1.6 Rozwój metod wspomaganie diagnostyki – systemy komercyjne CAD

Komputerowe wspomaganie diagnostyki radiologicznej oraz komputerowa detekcja różnego typu patologii są obszarem intensywnych badań w ostatnich latach. Świadczy o tym liczba nowych publikacji, chociażby na corocznych konferencjach

1.6. ROZWÓJ METOD WSPOMAGANIA DIAGNOSTYKI – SYSTEMY KOMERCYJNE CAD



Rysunek 1.3: (a) Szczegółowy schemat strukturalny systemu CAD/CADD. (b) Poszczególne kroki, włączone w projektowanie metod na etapie 1. i 2. detekcji oraz diagnozy.

Amerykańskiego Towarzystwa Radiologicznego RSNA (szczególnie tematyka detekcji raka w radiografii i tomografii komputerowej płuc, mammografii, tomografii komputerowej jelita grubego [38]). Powstało już kilka zaawansowanych technologicznie komercyjnych systemów detekcji zmian patologicznych w różnych modalnościach. Coraz więcej systemów o udowodnionej klinicznie skuteczności zostało zatwierdzonych przez amerykańską *Food and Drug Administration (FDA)*.

Przykładowe systemy komercyjne to [69]:

- rentgenografia klatki piersiowej – detekcja i pomiary guzków: IQQA-Chest firmy EDDA Technologies/Philips (zatwierdzony przez FDA w 2004 roku), xLNA firmy Philips Medical Systems (wykrywa guzki o średnicy od 5 mm), Rapid Screen CAD firmy Riverain Medical (pierwszy system CAD do rentgenografii płuc zatwierdzony przez FDA), Lung VCAR firmy GE Healthcare,
- tomografia komputerowa płuc: Syngo Lung CAD firmy Siemens Medical Solutions (zatwierdzony przez FDA, wykrywa guzki poniżej 3 mm), CAD-

Lung firmy Median Technologies, CADLung firmy Medicsight, ImageChecker Lung CT firmy Hologic/R2 Technology (zatwierdzony przez FDA w 2001),

- tomografia wątroby: IQQA-Liver firmy EDDA Technology,
- echokardiografia: Axius Auto EF CAD firmy Siemens Medical Solutions,
- kolonografia tomografii komputerowej: firma iCAD, Medicsight ColonCT firmy Medicsight, CAD firmy Philips Medical Systems, CAD Colon firmy iMED, CAD-Colon firmy Median Technologies,
- przetwarzanie obrazów medycznych różnych modalności (mammografia, CT i inne) – tworzenie map tkanek: Signature Mapping firmy Guardian Technologies International,
- systemy dla badań rezonansu magnetycznego: Full-Time-Point MR firmy CAD Sciences,
- inne systemy wspomaganie diagnostyki piersi zostały opisane w dalszej części pracy.

## 1.7 Wspomaganie badań mammograficznych

### 1.7.1 Badania mammograficzne i powstające obrazy

Podstawową metodą w zakresie wczesnego wykrywania raka piersi u kobiet powyżej 40 lat jest mammografia rentgenowska. W badaniu tym wykorzystuje się niskie dawki promieniowania rentgenowskiego do wykonania zdjęcia piersi. Można tu zobaczyć nawet bardzo małe zmiany (np. mikrozwapnienia lub guzki o średnicy ok. 0,5 cm, tzw. nieme klinicznie) na długo przedtem, zanim staną się wyczuwalne w dotyku. Wczesne wykrycie raka zwiększa szanse pacjentek na wyleczenie nawet o 25% [42]. Jest to możliwe dzięki wprowadzeniu mammografii skriningowej (przesiewowej), w której najważniejszym celem jest wykrycie zmian bezobjawowych klinicznie u pacjentek bez podejrzenia choroby. Mammografia umożliwia także dokładniejszą ocenę charakteru zmian patologicznych stwierdzonych wcześniej badaniem klinicznym.

Podstawowe badanie mammograficzne zawiera zdjęcia w dwóch projekcjach — skośnej (przysiódkowo-bocznej) i kranio-kaudalnej (rys. 1.4). Prawidłowo wykonana projekcja skośna (MLO), pod kątem 40-60° do pionu, uwidacznia całą pierś dobrze obrazując część położoną blisko klatki piersiowej oraz ogon pachowy (Spence'a). Natomiast projekcja kranio-kaudalna (CC) uzupełnia projekcję skośną, dobrze obrazując część centralną i przysiódkową piersi (rys. 1.5) [42].


Jeżeli to podstawowe badanie budzi wątpliwości (ewentualna obecność raka lub innej zmiany), wykonuje się zdjęcia dodatkowe (w innych projekcjach, celowane ze zwiększonym uciskiem, powiększone). Niezbędne informacje uzupełniające przy stwierdzonej w mammografii zmianie dają badanie kliniczne i wywiad oraz często badanie USG. Natomiast ostateczną odpowiedź zapewnia biopsja aspiracyjna cienkoigłowa, biopsja gruboigłowa lub chirurgiczna, a następnie badanie histopatologiczne pobranej tkanki [123, 152].

### Ograniczenia interpretacji badań w mammografii

Ogólnie ograniczenia interpretacji badań w diagnostyce obrazowej wynikają generalnie z trzech podstawowych powodów:


- specyfiki anatomii i fizjologii badanego narządu,
- właściwości tkanek badanego narządu w wybranej technice obrazowania,
- innych uwarunkowań (organizacja i warunki pracy lekarza, poziom techniczny sprzętu, itp.).

Aby w pełni zdać sobie sprawę z powodów ograniczeń interpretacji badania mammograficznego, należy wziąć pod uwagę: anatomie piersi oraz zmienność osobniczą jej budowy, właściwości fizyczne tkanek piersi. Dodatkowo splot tych czynników stanowi trudne do pokonania ograniczenie interpretacji badań mammograficznych.



Rysunek 1.4: Typowe badanie mammograficzne w dwóch projekcjach.

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH



Rysunek 1.5: Sposób wykonania badania mammograficznego: (a) projekcja MLO; (b) projekcja CC. (Rysunek zaczerpnięty z pracy [88].)

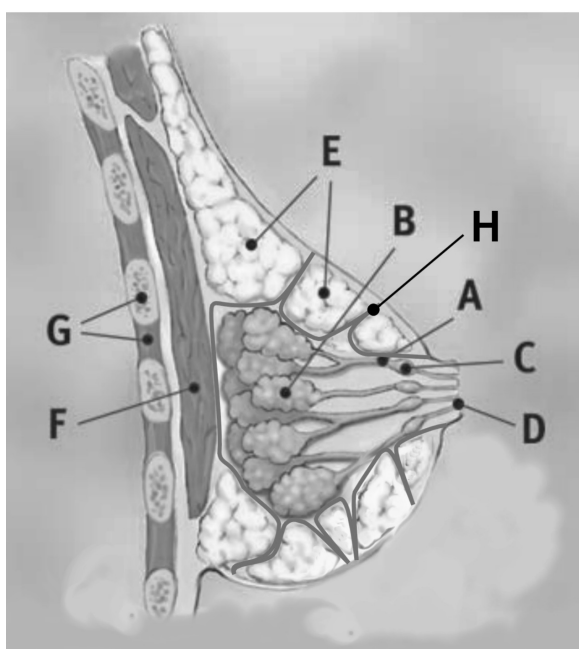
### Anatomia piersi

Pierś jest zbudowana z tkanki gruczołowej, łącznej włóknistej, tłuszczowej, przewodów mlecznych, nerwów oraz naczyń krwionośnych i limfatycznych. Z tkanki podskórnej piersi wnikają do jej wnętrza łącznotkankowe przegrody, tworzące trójwymiarowe rusztowanie, nazywane zrębem łącznotkankowym. Zrąb podtrzymuje naczynia krwionośne, limfatyczne, nerwy i stabilizuje wszystkie struktury sutka. Rysunek 1.6 przedstawia schematycznie anatomię piersi.

Tkanka gruczołowa piersi jest zgrupowana w ok. 15-20 stożkowatych płatach, skierowanych wierzchołkiem ku brodawce. W obrębie płata tkanka gruczołowa jest podzielona na mniejsze jednostki (zraziki), poprzerastane wewnętrzną tkanką łączną i tłuszczową. Każdy płat kończy się przewodem mlecznym, uchodzącym do brodawki sutkowej, tworząc przed nią rozszerzenie (4-5 x 10-15mm), zwane zatoką mleczną. Mimo iż płaty są ułożone kolistnie wokół brodawki, to rozkład tkanki gruczołowej nie jest jednorodny. Najwięcej jest jej w obszarze centralnym i górno-bocznym piersi. Zmiany nowotworowe w piersi powstają z tkanki gruczołowej i nabłonka gruczołowego, wyścielającego przewody mleczne.

### Zmienność obrazu piersi

Pierś rozwija się gwałtownie w okresie dojrzewania w odpowiedzi na hormony produkowane przez jajniki (estrogen). W ciągu życia kobiety narząd ten jest w stanie periodycznych zmian pod wpływem stymulacji hormonalnej, aż do menopauzy. Specyficzne zmiany zachodzą w piersi w okresie ciąży i laktacji. Dopiero w okresie okołomenopauzalnym obraz piersi stabilizuje się.



- A – przewód mleczny
- B – płat gruczołowy
- C – zatoka mleczna
- H – zrąb łącznotkankowy
- D – brodawka sutkowa
- E – tkanka tłuszczowa
- F – mięsień piersiowy większy
- G – ściana klatki piersiowej i żebra

Rysunek 1.6: Anatomia piersi — podstawowe struktury. Dla jasności rysunku nie uwzględniono: naczyń krwionośnych, limfatycznych i całości przegród łącznotkankowych. (Rysunek na podstawie [66].)

Ogólnie przyjmuje się, że piersi są narządami symetrycznymi. Mimo to możliwymi, mieszczącymi się w granicach normy wariantami są asymetria utkania gruczołowego obu piersi i asymetria ich wielkości. Nawet przy istnieniu asymetrii mammograficznym odniesieniem w ocenie jest zwykle obraz drugiej piersi, a przy kolejnych badaniach – porównanie ze zdjęciami poprzednimi (ocena względna, porównawcza) [123].

Budowę piersi cechuje również duża zmienność osobnicza. Normą jest występowanie w populacji różnych typów budowy piersi dla tych samych przedziałów wiekowych [42]. Skuteczność mammografii ma ścisły związek z rodzajem budowy piersi. U kobiet poniżej 40 lat (tkanka gruczołowa piersiowa najczęściej jest bardzo gęsta) sutki zawierają dużą ilość tkanki gruczołowej i włóknistej, taka budowa znacząco obniża czułość mammografii w zakresie małych zmian. Jednak nawet w tym przypadku mammografia jest podstawowym badaniem w ocenie mikrozwapnień [111, 42].

### **Ograniczenia wynikające z właściwości tkanek piersi w obrazowaniu rentgenowskim**

Mammografia jest możliwa dzięki istnieniu różnic w wartościach współczynnika pochłaniania promieni X dla różnych rodzajów tkanek piersi. Tkanka tłuszczowa ma najmniejszy współczynnik pochłaniania i jest dla promieni rentgenowskich „prawie przezroczysta” (czarne obszary w mammogramie). Współczynniki pochłaniania dla tkanki gruczołowej i łącznej są co prawda wyższe niż dla tkanki

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH

tłuszczowej, ale różnica ich wartości jest niewielka. Co gorsza, współczynniki pochłaniania dla prawidłowej tkanki gruczołowej i tkanki gruczołowej zmienionej nowotworowo są prawie identyczne. Widoczne w mammogramie zagęszczenia i linie o różnych stopniach szarości są cieniami nakładających się na siebie prawidłowych struktur gruczołowych piersi, przewodów mlecznych i zrębu łącznotkankowego oraz ewentualnych zmian patologicznych. Zmiana nowotworowa w piersi (powstająca z tkanki gruczołowej) jest wyraźnie widoczna tylko wtedy, gdy jest otoczona tkanką tłuszczową lub gdy istotnie zmienia morfologię prawidłowych struktur piersi [42].

Podsumowując, pierś jest narządem złożonym zarówno anatomicznie, jak i funkcjonalnie. Z tego względu, jak również ze względu na dużą zmienność osobniczą, nie ma jak dotąd i wydaje się niemożliwe stworzenie „wzorca prawidłowej (zdrowej) piersi”. Wszystko to sprawia, że interpretacja mammogramu jest zadaniem złożonym.

### Ograniczenia wynikające z innych uwarunkowań

Do czynników obniżających trafność diagnozy należy również zaliczyć znaczący wpływ uwarunkowań technicznych (często bardzo zróżnicowana klasa aparatów) oraz dodatkowo niekorzystne warunki zewnętrzne (niewłaściwe oświetlenie, słaba jakość mammogramów itp.), zmęczenie lekarza analizującego seryjnie dużą liczbę obrazów w przeważającej większości bez zmian patologicznych (badania skriningowe), brak wystarczającego doświadczenia zawodowego.

### Subiektywizm i błędy w diagnostyce

Często zdarza się, że nawet doświadczeni radiolodzy niezależnie od siebie wydają różne diagnozy, dotyczące tego samego przypadku. W 1996 roku w USA przeprowadzono badania zmienności w interpretacji badań skriningowych przez radiologów. Wykazały one 53% różnicy w czułości diagnozy: w skrajnych przypadkach procent pacjentek skierowanych na biopsje wynosił 100% i 47% [13].

Błędy w diagnostyce mogą dotyczyć przeoczenia zmiany słabo widocznej (bardzo małej lub na tle gęstego utkania gruczołowego) lub niewłaściwej oceny wykrytej patologii, tzn. rozróżnienia pomiędzy zmianami złośliwymi i łagodnymi. Poziom przekłamań w diagnozie zmian mammograficznych to około 10-30% raków, które nie zostają wykryte podczas rutynowego skriningu (decyzje fałszywie negatywne) i 30-40% decyzji fałszywie pozytywnych [138].

Prace badawcze dążą do zmniejszenia subiektywizmu diagnozy. Konsultacje kilku lekarzy (dodatkowa ocena), dotyczące tego samego przypadku zwiększają skuteczność mammografii o około 15% [78], ale jednocześnie zmniejszają wydajność ich pracy i podnoszą cenę badania.

### 1.7.2 Podstawowe obrazowane patologie

Standaryzacja opisu medycznego jest ważnym tematem badawczym w informatyce medycznej [72]. W terminologii mammograficznej za standard jest obecnie uważany leksykon BI-RADS [2, 88] (*Breast Imaging Reporting and Database*

*System*, rekomendowany przez *'American College of Radiology'*). Intencją twórców systemu BI-RADS było stworzenie narzędzia kontroli jakości w mammografii i standaryzacji raportów mammograficznych. BI-RADS zawiera zalecenia, dotyczące: sposobu opisu zmian mammograficznych, organizacji raportu, monitorowania wyników badania i założeń dla amerykańskiej porównawczej bazy danych związanych z mammografią. BI-RADS wyszczególnia: typy patologii mammograficznych, ich podstawowe cechy, kategorie oceny i słownik zalecanych terminów.

Według BI-RADS radiologiczne obrazy patologii piersi można podzielić na pięć zasadniczych grup [2]:

- guzy (masy),
- zwapnienia,
- zaburzenie architektury,
- przypadki specjalne,
- zmiany towarzyszące.

Guz dobrze odgraniczony jest najczęstszą zmianą patologiczną, stwierdzaną w mammografii, a guz spikularny jest zmianą radiologiczną typową dla raka sutka (ok. 80% palpacyjnych raków piersi to guzki spikularne) [42].

Prawidłowa ocena mikrozwapnień ma zasadnicze znaczenie, ponieważ jest to jeden z ważnych objawów, umożliwiających wykrycie małych niepalpacyjnych nowotworów piersi. Zmiany łagodne również zawierają zwapnienia (zarówno makro- jak i mikro-). Weryfikacja histopatologiczna każdego przypadku nie jest uzasadniona ani merytorycznie, ani ekonomicznie. Ważna jest natomiast analiza cech mikrozwapnień i na tej podstawie ocena prawdopodobieństwa ich złośliwości.

## Guzy

Guz to patologia pokrywająca pewien obszar, widoczna w dwóch projekcjach [138]. Najmniejsze guzy widoczne na mammogramach mają średnicę ok. 0,5 cm. Najbardziej znaczącymi cechami, które wskazują na złośliwość lub łagodność guza są jego kształt (*'shape'*) oraz charakter zarysu (*'margin'*).

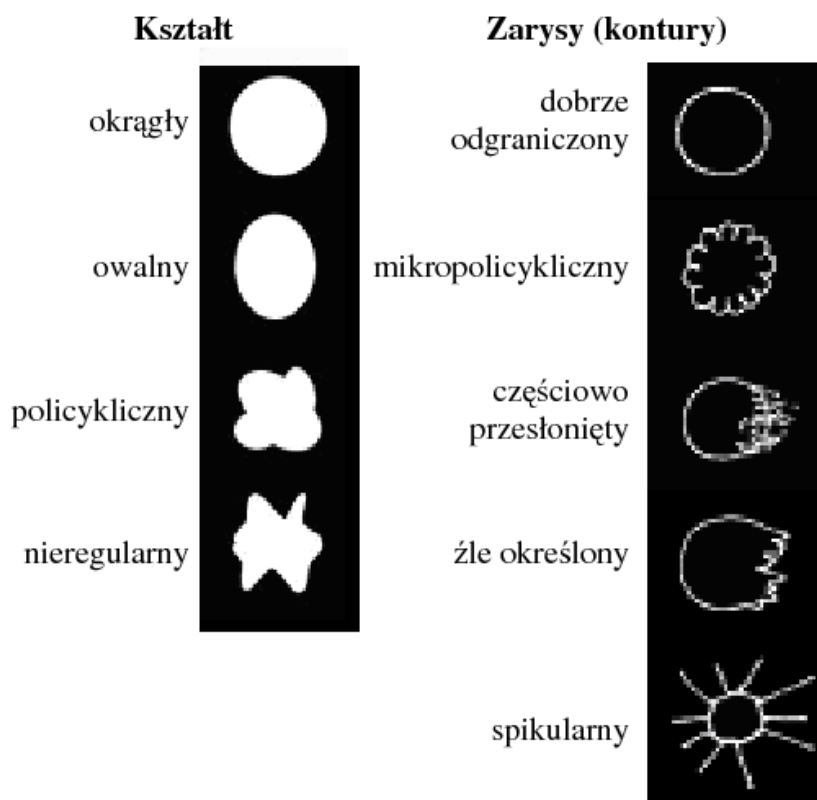
Kształt może być (rys. 1.7):

- okrągły (*'round'*) – kształt sferyczny, podobny do piłki, okrągły, kulisty,
- owalny (*'oval'*) — kształt eliptyczny lub w kształcie jajka,
- policykliczny (syn. zrazikowy) (*'lobulated'*) — utworzony przez zewnętrzne kontury nakładających się okręgów lub elips,
- nieregularny (*'irregular'*) — kształt, który nie może być scharakteryzowany przez żaden z poprzednich opisów.

Zarys (syn. brzeg, kontur, margines) może być opisany jako (rys. 1.7):

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH


- dobrze odgraniczony (*'circumscribed'*) — Brzegi są ostro odgraniczone z nagłym przeskokiem pomiędzy patologią a otaczającą tkanką. W obrębie guza i jego otoczeniu nie ma zmian, sugerujących naciekanie sąsiadujących tkanek,
- mikropolicykliczny (syn. ząbkowany) (*'microlobulated'*) — Brzegi faliste z kółkami tworzącymi małe fale,
- częściowo przesłonięty (*'obscured'*) — Margines częściowo ukryty przez nałożoną lub sąsiadującą zdrową tkankę i nie jest możliwa dalsza ocena,
- źle określony (*'ill-defined', 'indistinct'*) — Słaba ostrość brzegu, wskazująca na naciekanie i najprawdopodobniej nie jest to spowodowane nałożeniem prawidłowych tkanek piersi,
- spikularny (*'spiculated'*) — Patologia jest scharakteryzowana przez linie promieniujące gwiazdźście od brzegu zmiany (naciekanie).



Rysunek 1.7: Schematycznie przedstawione rodzaje kształtów i zarysów oraz odpowiadająca im terminologia, używana do opisu guzów. (Rysunek zaczerpnięty z pracy [88].)

Guzy łagodne zwykle mają: regularny kształt (kolisty lub owalny), gładkie zarysy, jednolitą teksturę. Są dobrze odgraniczone od tkanki otaczającej (rys. 1.7). Guzy o nieregularnym kształcie, z nieostrymi zarysami lub spikulami wrastającymi w otaczającą tkankę, mają większe prawdopodobieństwo złośliwości (rys. 1.8

i 1.10). Wysycenie zmiany (niskie, średnie lub wysokie w stosunku do obszarów zdrowej tkanki) może także dostarczyć pewnych wskazówek na temat jej diagnozy radiologicznej. Zmiany złośliwe często mają wyższe wysycenie (rys. 1.8).



Rysunek 1.8: Guzy złośliwe. (a) Zarysy odcinkowo nieostre, źle określone. (b) Mocno wysycony guz o przypadkowej orientacji. (Rysunek zaczerpnięty z pracy [97].)

### Mikrozwapnienia

Mikrozwapnienia są jednym z ważniejszych objawów, umożliwiającym wczesne wykrycie raka sutka [42]. W 30-50% wcześniej wykrytych w mammografii raków są widoczne klastry mikrozwapnień, a w 60-80% raków piersi schorzenie ujawnia się jako mikrozwapnienia podczas badania histopatologicznego [27]. Mammografia jest podstawowym badaniem w ich ocenie ilościowej i jakościowej [123].


Mikrozwapnienia to małe złoże wapnia, formujące się w tkance piersi. Zwapnienia odkładają się w różnych narządach nie tylko w wyniku nadmiaru wapnia w organizmie, ale również podczas bliznowacenia lub martwicy i różnego typu zmian zapalnych (zmiany zapalne towarzyszą również procesowi nowotworowemu). Zwapnienia w piersi powstają też w przewodach mlecznych w wyniku zwapnienia pozostałości wewnątrzprzewodowych, które nie mogły zostać wchłonięte lub wydzielone [42].

Na zdjęciach rentgenowskich mikrozwapnienia wyglądają jak drobne jasne plamki różnych rozmiarów i kształtów, najczęściej o wymiarach od 0,05 do 1 mm (średnio 0,3 mm). Najważniejszymi diagnostycznie cechami zwapnień są ich: rozmiar, kształt (lub morfologia), liczba i rozłożenie (*'distribution'*).


Typowo łagodne zwapnienia (rys. 1.11), to:

- skórne — makrozwapnienia zlokalizowane w skórze, najczęściej obrączkowate (*'lucent center'*) duże, gładka powierzchnia, przezroczyste centrum (rys. 1.13b), lub sferyczne,

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH



Rysunek 1.9: Łagodne guzy dobrze odgraniczone. (a) Halo: wąska półprzezroczysta obręczka naokoło guza. (b) Tłuszczak — niskie wysycenie. (c) Torbiel o gładkich zarysach i orientacji w kierunku brodawki. (Rysunek zaczerpnięty z pracy [97].)



Rysunek 1.10: Złośliwe patologie gwiaździste. (a) Wyraźny centralny guz z gęstymi kolcami promieniującymi we wszystkich kierunkach. (b) Bardzo mały guz, niewyczuwalny w dotyku — w mammografii widoczne zaburzenie architektury. (Rysunek zaczerpnięty z pracy [97].)

- naczyniowe (*'vascular'*) — makrozwapnienia o kształcie liniowym, zlokalizowane w przebiegu naczyń krwionośnych,
- zgrubne, kleksowate (*'coarse'*) — makrozwapnienia charakterystyczne dla degenerującego gruczolakowłókniaka (rys. 1.13c),
- jak skorupka jajka (*'egg-shell'*) — mikro- lub makrozwapnienia w ściankach torbieli,
- mleczko wapnia (*'milk of calcium'*) — mikro- lub makrozwapnienia.

Najczęściej łagodne zwapnienia (rys. 1.11), to:

- pałeczkowate (*'rod-like'*) — łagodne zwapnienia (jeśli makro-) w przewodach mlecznych, występują również (mikro-) w przedinwazyjnym raku przewodowym [42],
- punkcikowate (*'punctate'*) — mikrozwapnienia okrągłe lub owalne, mniejsze niż 0,5 mm, z wyraźnie określonym zarysem (rys. 1.13a), zwykle łagodne, ale występują również w przedinwazyjnym raku przewodowym [42].

Zwapnienia o interpretacji niepewnej, pośredniej (prawdopodobieństwo raka to 36%) są małe, niewyraźne, o trudnym do dokładnego określenia kształcie, czasami opisując je, stosuje się terminy bezpostaciowe lub amorficzne (*'amorphous, indistinct'*).


Mikrozwapnienia o zwiększonym prawdopodobieństwie złośliwości są zwykle mniejsze niż 0,5 mm i mogą być:

- niejednorodne, różnokształtne (*'pleomorphic, heterogeneous'*) (rys. 1.12a) – prawdopodobieństwo raka to 56%,
- cienkie, liniowe (mogą być nieciągłe), rozgałęziające się (*'fine, linear, branching'*) (rys. 1.12b) – prawdopodobieństwo raka to 90%.


Rozłożenie w tkance zwapnień może być opisane jako:

- skupisko (*'clustered'*) — grupa więcej niż pięciu w małej objętości tkanki (poniżej 2 cm<sup>3</sup>) (rys. 1.12a),
- liniowe (*'linear'*) — ułożone w linię, która może się rozgałęziać (bardziej prawdopodobna złośliwość) (rys. 1.12b),
- segmentarne lub przewodowe (*'segmental'*) — Rozłożenie sugerujące lokalizację zwapnień w płacie piersi lub przewodach mlekowych do niego należących. Jeśli kształt zwapnień nie jest typowo łagodny, rozmieszczenie to budzi podejrzenie złośliwości.
- regionalne (*'regional'*) — rozrzucone w dużej objętości tkanki, ale nie w całej piersi,
- rozsiane losowo w całej powierzchni piersi (*'diffuse, scattered'*) — są prawie zawsze łagodne (rys. 1.13b).


1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH



Rysunek 1.11: Terminologia używana do opisu mikrozwapnień. (Rysunek zaczerpnięty z pracy [88].)



Rysunek 1.12: Mikrozwapnienia złośliwe. (a) Punkcikowate kropki lub o wydłużonym kształcie, niezliczone w skupisku. (b) Robaczkowate, linijne, rozgałęziające się. (Rysunek zaczerpnięty z pracy [97].)



Rysunek 1.13: Mikrozwapnienia łagodne. (a) Jednorodne, lite, ostro odgraniczone, bardzo drobne i gęste. (b) Obrączkowe, środek przezroczysty. (c) Gruboziarniste, nieregularne i bardzo gęste. (Rysunek zaczerpnięty z pracy [97].)

### Wczesne oznaki złośliwości


Inne delikatne objawy, sugerujące wczesną postać raka, to:

- nowe, w porównaniu z poprzednimi badaniami zagęszczenie,
- zaburzenie architektury tkanki bez masy guza (rys. 1.8b, 1.14),
- asymetria gęstości tkanki w obydwu piersiach.

### Raport z badania mammograficznego

Standaryzowane (wg BI-RADS) sprawozdanie z badań mammograficznych powinno zawierać:

- powód (uzasadnienie) wykonania badania,
- ocenę utkania (lub inaczej budowy) tkanki sutka (rys. 1.15): tłuszczowa, tłuszczowa z ogniskami tkanki gruczołowej, o zróżnicowanej gęstości, bardzo gęsta,
- standaryzowany opis wykrytych zmian (określenie prawdopodobieństwa złośliwości zmiany, widoczność zmiany: subtelna w skali 0-5, średnia 6-7, oczywista 8-9),
- ocena końcowa z zaleceniem dalszych działań (tab. 1.1).



Rysunek 1.14: Delikatne zaburzenie architektury — zmiana złośliwa. (Rysunek zaczerpnięty z pracy [88].)


### 1.7.3 Charakterystyka stosowanych metod CADD w mammografii

#### Przegląd rozwiązań komercyjnych

Już w 1998 roku FDA (*U.S. Food and Drug Administration*) zatwierdziło pierwszy system wspomaganie detekcji zmian patologicznych w mammografii skriningowej – *ImageChecker* firmy *R2 Technology* – do badań analogowych, a w 2001 roku do obrazów cyfrowych [73], a także do mammografii diagnostycznej. Od 1998 roku nastąpił bardzo szybki rozwój zaawansowanych technologicznie komercyjnych systemów detekcji. Kolejne dwie firmy otrzymały akceptację FDA: *iCAD Medical Systems* z systemem *SecondLook* do detekcji zmian w mammografii cyfrowej i analogowej (rok 2002) [70] oraz *Kodak* do badań analogowych [71]. Inne systemy CAD to: *Mammex MammoCAD* firmy *Scanis* [74], *M-Vu Mammography CAD System* firmy *VuCOMP*, *Easy Vision* firmy *Philips* [67, 69].

Kategoria	Ocena	Opis
0	Ocena niekompletna	Dodatkowe badanie obrazowe
1	Negatywna (zmiana zdecydowanie łagodna)	Bez komentarza (0 cech zmian złośliwych i wszystkie cechy zmiany łagodnej)
2	Zmiana łagodna	Zmiana zdecydowanie łagodna (0 cech zmian złośliwych)
3	Zmiana prawdopodobnie łagodna	Bardzo wysokie prawdopodobieństwo zmiany łagodnej; krótko czasowa obserwacja w celu uzyskania pewności diagnozy (1-2 cechy zmian złośliwych)
4	Podejrzenie patologii (zmiany złośliwej)	Zmiana nietypowa, złośliwa ze znaczącym prawdopodobieństwem; należy rozważyć biopsję (3-4 cechy zmian złośliwych)
5	Silne przekonanie o patologii (zmianie złośliwej)	Wysokie prawdopodobieństwo rakowej zmiany złośliwej; należy podjąć odpowiednie działania (5 cech zmian złośliwych)

Tabela 1.1: Kategorie oceny końcowej badania mammograficznego BI-RADS.



Rysunek 1.15: Różne typy budowy (utkania) piersi i ich wpływ na czułość badania mammograficznego: (a) utkanie tłuszczowe, (b) utkanie tłuszczowo-gruczołowe, (c) utkanie gruczołowo-tłuszczowe, tkanka gruczołowa drobnoguzkowa, (d) gęste utkanie gruczołowe. Widać wyraźnie, że ostatni typ budowy piersi znacznie ogranicza czułość mammografii jeśli chodzi o małe zmiany. (Na podstawie [65].)

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH

Bezsprzecznym liderem rynku jest system *R2 ImageChecker* o udowodnionej skuteczności przez wiele badań klinicznych. Drugie miejsce na rynku zajmuje *iCAD SecondLook*.

Wymagania stawiane takim systemom przez użytkowników (radiologów, personel przychodni i szpitali) są bardzo wysokie: przede wszystkim dokładność (wysoka czułość, mała liczba fałszywych wskazań na badanie, niewielki wzrost procentowy pacjentek wysyłanych na biopsje), właściwa prezentacja obrazu, interfejs wygodny dla lekarzy, często praca na badaniach mammografii analogowej i cyfrowej, integracja z PACS (*Picture Archiving and Communication System*).

### Szczegółowa ocena wybranych systemów

Testy systemu *R2 ImageChecker*, przeprowadzone na dużej bazie badań skriningowych wykazały, że już w 2000 roku jego czułość całkowita wynosiła ok. 90%, liczba fałszywie pozytywnych wskazań na obraz (FPI) to 0,5 (tab. 1.2) [24], a w 2007 czułość wzrosła do 91%, liczba fałszywych wskazań na prawidłowy (zdrowy) przypadek to 1,5, a więc FP/obraz to 0,375 [38]. Wyniki badań klinicznych z radiologami nad poprawą detekcji raków z użyciem systemu CAD są przedstawione w tabeli 1.3 — zanotowano wzrost czułości radiologów w zakresie 1,7% do 19,5% [38].

	dane z roku 2001	dane z roku 2007
Czułość detekcji — mikrozwapnienia	98,3%	98,3%
Czułość detekcji — guzy	85,7%	brak danych
Czułość całkowita	90,4%	91%
FP / przypadek prawidłowy (zdrowy) (złożony z 4 obrazów)	2,0 (0,5 FPI)	1,5 (0,375 FPI)

Tabela 1.2: Skuteczność systemu R2 ImageChecker [24, 50, 38, 73].

Czułość systemu *iCAD SecondLook* to 92-96%, a liczba FP na zdrowy przypadek to 1,6 do 2,8 w zależności od opcji oprogramowania [70]. Zwiększa czułość radiologa o ok. 21,2% [22, 101, 26, 141, 100].

Porównanie skuteczności najbardziej rozpowszechnionych komercyjnych systemów CAD w detekcji złośliwych zaburzeń architektury wypada zdecydowanie na korzyść systemu *R2 ImageChecker* [6], podobnie jest dla raków o średnicy mniejszej niż 16 mm [44] — wyższa czułość i niższa liczba fałszywych wskazań (tab. 1.4, 1.5).

W kwietniu 2007 ukazał się jednak artykuł [49] opisujący badania kliniczne, w którym autorzy udowadniają, że użycie systemu CAD w mammografii zmniejsza czułość tego badania przy jednoczesnym wzroście liczby pacjentek, wysyłanych na dodatkowe badania. Wywołał on dyskusję i kolejne artykuły oraz badania naukowe [21, 51, 45] na ten temat. Przede wszystkim zauważono, że w badaniu wzięli udział radiolodzy bez praktyki w używaniu oprogramowania CAD, testy zostały przeprowadzone bezpośrednio po zainstalowaniu nowego oprogramowa-

autorzy	rok	liczba badań	wzrost w detekcji raków	liczba pacjentek skierowanych na dodatkowe badania ('recall rate')
Freer i in. [50]	2001	12 860	19,5%	18,8%
Gur i in. [57]*	2004	115 571	1,7%	0,1%
Birdwell i in. [15]	2005	8 682	7,4%	7,6%
Cupples i in. [31]	2005	27 274	16,1%	8,1%
Morton i in. [106]	2006	18 096	7,6%	10,8%
Dean i in. [33]	2006	9 520	10,8%	26,0%

Tabela 1.3: Testy użyteczności systemu CAD w detekcji raka piersi w mammografii screeningowej. W pierwszej fazie testu radiolodzy interpretowali badania bez użycia CADu, w drugiej fazie, z zastosowaniem systemu wspomagania. Wszystkie testy, oprócz badań z ostatniego wiersza, były przeprowadzane przy użyciu systemu *R2 ImageChecker*, ostatni wiersz to badania przy użyciu *iCAD Second Look*. (Udoskonalona tabela, wzorowana na [38].)

\*Prawdopodobnie badania, przeprowadzone z doświadczonymi radiologami, podważone w [48].

	Liczba	<i>R2 ImageChecker</i>	<i>iCAD SecondLook</i>
SEC	27	48%	19%
SE	51	31%	10%
FPI	—	0,7	1,27

Tabela 1.4: Porównanie czułości komercyjnych systemów *R2 ImageChecker* i *iCAD SecondLook* w detekcji złośliwych zaburzeń architektury [6]. Oznaczenia: FPI — liczba fałszywie pozytywnych wskazań na obraz, SE — czułość, SEC — czułość liczona na przypadkach — badaniach. Podstawowe badanie mammograficzne składa się z 4 obrazów. Jeśli w danym przypadku jest obecna podejrzana zmiana, jest ona widoczna na 2 obrazach — projekcji MLO i CC. Wskazanie prawdziwie pozytywne odnotowuje się, jeśli analizowana metoda oznacza co najmniej raz podejrzaną zmianę — w jednej z dwóch projekcji.

	<i>R2 ImageChecker</i>	<i>iCAD SecondLook</i>
SEC	81,8%	60,9%
SE	64,7%	42,6%
FPI	1,08	1,41

Tabela 1.5: Porównanie czułości komercyjnych systemów *R2 ImageChecker* i *iCAD SecondLook* w detekcji raków o średnicy mniejszej od 16 mm, nie zawierających mikrozwapnień [44].

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH

nia (właściwie był to okres nabierania doświadczenia w pracy z systemem CAD) oraz nie było mowy o rozmiarach i stanie zaawansowania wykrywanych zmian. Doświadczeni radiolodzy twierdzą, że za pomocą CADu są w stanie znajdować mniejsze raki, o średnich wymiarach 5 mm (w porównaniu z rakami wykrywanymi bez użycia CAD – średnio 10,5 mm), przy pewnym wzroście liczby skierowań na dodatkowe badania [58]. Najnowsze badania kliniczne wykazują poprawę efektywności diagnozy mammografii przy użyciu systemu CAD – wzrostu czułości przy bardzo małym wzroście skierowań na dodatkowe badania [55].

### Systemy CAD w praktyce klinicznej

W USA praktyka diagnozy ze wspomaganie komputerowym detekcji raka piersi jest już szeroko rozpowszechniona [38]. W 2003 w USA działało ok. 1200 stacji wspomaganie detekcji. Około 25-30% (8 mln) badań skriningowych było diagnozowanych za pomocą systemów CAD [53].

### Inne rodzaje badań wspomagające diagnostykę piersi

W chwili obecnej mammografia rentgenowska jest uznawana za standardową procedurę zarówno w badaniach przesiewowych, jak i w diagnostyce raka piersi [151]. Jednak często wymaga dodatkowych uzupełniających badań. Najczęściej stosowane to:

- ultrasonografia USG – technika obrazowania tkanek i narządów wewnętrznych, wykorzystująca zasadę odbicia fali ultradźwiękowej o wysokiej częstotliwości. Charakter echa zależy od struktury badanej tkanki. Jest używana jako diagnostyka wspomagająca mammografię w celu identyfikacji obszarów budzących podejrzenie na mammogramie lub u młodych kobiet o gęstej budowie piersi. USG posiada największą dokładność diagnostyczną przy różnicowaniu między zmianą o charakterze litym a wypełnioną płynem torbielowym, ale nie umożliwia identyfikacji mikrozwapnień charakterystycznych dla wczesnego raka piersi (zbyt mała rozdzielczość zobrazowań) [151]. W 2003 roku Soo i in. przeprowadzili testy, które wykazały, że ok. 23% podejrzanym mikrozwapnień jest widocznych w USG [146].
- rezonans magnetyczny MR – wykorzystujący silne pole magnetyczne i fale radiowe. Prowadzone są prace nad jego zastosowaniem w badaniach przesiewowych specyficznych grup pacjentów, m.in. młodych kobiet z grup wysokiego ryzyka zachorowania na raka piersi. Może być użyty np. w obrazowaniu piersi po operacjach plastycznych. Wadą badań MR piersi jest brak skutecznego rozróżnienia zmian złośliwych i łagodnych, duża ilość rozpoznania fałszywie dodatnich oraz cena badania około dziesięciokrotnie wyższa niż mammografii [151].
- pozytronowa emisyjna tomografia komputerowa PET – komputerowe mapy procesów metabolicznych zachodzących w komórkach. Technika ta jest bardziej efektywna w wykrywaniu większych lub bardziej inwazyjnych guzów

(powyżej 8 mm). Metody tej używa się do różnicowania zmian łagodnych od złośliwych, a także przy podejrzeniu raka, którego nie można zidentyfikować innymi technikami obrazowania, lub przy ocenie stopnia zaawansowania wznowy raka [151].

- inne: optyczne, opto-ultradźwiękowe, termiczne, elastografia.

W 2004 powstały pierwsze systemy wspomaganie diagnozy badań MR *Full-Time-Point MR* firmy *CAD Sciences* (wcześniej *3TP ImagingSciences*), *CADstream MRI* firmy *Confirma*, *DynaCAD* firmy *Invivo Corp.* oraz *USG – B-CAD* firmy *Cedara* [67].

### Tendencje w obrazowaniu piersi

Z powodu niekompletności mammografii (np. udowodniona skuteczność dla pacjentek powyżej 40. roku życia) w ciągu ostatnich 25 lat obserwuje się następujące tendencje w obrazowaniu piersi (za [150]):

- przesunięcie z obrazowania struktury i anatomii narządów do obrazowania funkcjonalnego lub fizjologicznego (fMR, PET),
- od badania 2-wymiarowego do 3-wymiarowego (MR, tomosynteza),
- odchodzi się od promieniowania jonizującego (MR, ultrasonografia, tomografia optyczna),
- fuzja danych z różnych modalności,
- od obrazowania narządów do obrazowania na poziomie komórek (obrazowanie molekularne – *BSGI Breast Specific Gamma Imaging*, obrazuje aktywności komórkowe). Jest to wynikiem rozwoju wiedzy na temat biologii molekularnej. Podstawy leżą w fakcie, że rak jest chorobą o niekontrolowanym wzroście komórek.
- wykorzystanie detektorów cyfrowych (cyfrowa mammografia).

### Systemy wspomaganie detekcji – cele i wyzwania światowe

Intensywny rozwój systemów wspomaganie detekcji ciągle trwa. Przede wszystkim potrzeba jeszcze wielu testów klinicznych — zebranie dużej bazy przypadków (liczba raków w populacji skriningowej jest mała) z różnych populacji pacjentek oraz staranne przygotowanie testów i procedur ich oceny (m.in. wybór reprezentatywnej grupy radiologów, oceniających wyniki CAD). Przykładem takich testów jest program DMIST: przeprowadzono testy na 43 tys. pacjentek w celu porównania efektywności mammografii skriningowej analogowej i cyfrowej [115].

Współczesne kierunki badań naukowych w dziedzinie systemów CAD w mammografii i innych badaniach obrazowych piersi (za [150, 53]):

## 1.7. WSPOMAGANIE BADAŃ MAMMOGRAFICZNYCH

- segmentacja regionu piersi, segmentacja brodawki (m.in. ważne w określaniu kierunku klastrow mikrozwapnień, kierunek do brodawki wskazuje na ich złośliwy charakter), segmentacja mięśnia w projekcji skośnej, segmentacja stożka gruczołowego (zmiany znajdujące się poza stożkiem gruczołowym są szczególnie podejrzane, ważne także do oceny gęstości utkania piersi),
- rejestracja i fuzja obrazów wewnątrz modalności (np. 3-wymiarowy obraz mikrozwapnień, otrzymany z 2-wymiarowych projekcji mammograficznych) i obrazów różnych modalności (np. badań MRI i mammografii),
- detekcja mikrozwapnień: redukcja fałszywych wskazań przy zachowaniu wysokiej czułości, stworzenie bazy danych mikrozwapnień (zaznaczone obszary pojedynczych mikrozwapnień oraz klastrow) do badań naukowych, detekcja w trzech wymiarach (fuzja obrazów z 2-wymiarów, tomosynteza), wstępna diagnoza mikrozwapnień – wybranie cech różnicujących mikrozwapnienia, dodanie informacji klinicznych do klasyfikacji mikrozwapnień, analiza dokładności diagnostycznej radiologa samego i przy użyciu CADu, ocena komputerowej detekcji mikrozwapnień jako podstawowego wskaźnika diagnostycznego (*'primary reader'*),
- detekcja guzów: poprawa czułości i redukcja fałszywych wskazań, analiza niewykrywanych przypadków (w obecnym stanie zaawansowania systemów CAD niektórzy radiolodzy mogą ignorować wskazania detekcji guzów jako mało skuteczne [53]),
- analiza gęstości utkania piersi (czynnik ryzyka raka),
- detekcja subtelnych oznak wczesnego raka piersi: subtelnych zmian (średnica poniżej 1 cm), zaburzeń architektury, analiza asymetrii utkania, analiza poprzednich badań,
- analiza dużej ilości danych – połączenie analizy wyników i badań z różnych modalności (używanych szczególnie w skriningu pacjentek wysokiego ryzyka, np. USG, MRI), m.in. badania 3-wymiarowe,
- projektowanie algorytmów uczenia dostosowanych do specyficznych zagadnień, np. detekcji guzów w mammografii,
- metodologia testowania algorytmów detekcji (złożonych z podalgorytmów, np. segmentacji, selekcji cech itp.) – strategia testów,
- ocena wydajności algorytmów (metodologia oceny, metryki wydajności algorytmów),
- analiza wielorozdzielcza i w wielu skalach naśladująca sposób diagnozowania przez radiologa (od bardzo zgrubnej skali – pierwsze spojrzenie na badanie – do szczegółów – przez radiologa odczytywanych lupą),
- model i atlas piersi oraz chirurgia wspomagana przez komputer,

- niezależne od modalności algorytmy analizy obrazu, w tym segmentacja, porównywanie obrazów,
- ocena potencjalnej roli CAD jako detekcji zdrowych przypadków (bez potrzeby weryfikacji przez radiologa) – *'prescreener'*,
- rozwój systemów wspomagania diagnozy,
- rozwój systemów mammografii cyfrowej, redukcja dawki, kontrola jakości, poprawa czułości kontrastu.

## Rozdział 2

---

# Metody i algorytmy, stosowane w systemach wspomagania diagnostyki do mammografii

---

W rozdziale dokonano wstępnej selekcji użytecznych algorytmów i narzędzi systemów wspomagania diagnostyki obrazowej w mammografii. Szczególnie uwzględniono metody, dotyczące mikrozwapnień, które były głównym przedmiotem zainteresowań przy opisie patologii. Omówiono przede wszystkim metody poprawy percepcji w obrazowaniu medycznym i kryteria ich oceny, algorytmy detekcji zmian patologicznych oraz przeanalizowano właściwości patologii w mammogramach, przechodząc od właściwości określanych przez radiologów do numerycznych metod opisu właściwości wysegmentowanych zmian. Następnie krótko streszczono stosowane metody klasyfikacji.

Dokładniej przeanalizowano metody wykorzystywane i optymalizowane w opracowanym systemie *MammoViewer*, opisanym w rozdziale 3. Niektóre fragmenty rozdziału bezpośrednio powołują się na dokumentację systemu *MammoViewer* (załącznik E), w której wybrane metody opisano bardziej szczegółowo.

\* \* \*

Współczesne badania naukowe w dziedzinie mammografii skupiają się na rozwoju cyfrowego obrazowania piersi oraz na systemach do analizy obrazów, które mogą wykrywać określone ich właściwości, klasyfikować je, w wyniku generując wizualne podpowiedzi, zrozumiałe dla radiologa [150]. Metody przetwarzania i analizy obrazów, które są użyteczne w systemach wspomagania diagnostyki w mammografii, dotyczą:

- poprawy percepcji zmian,
- detekcji mikrozwapnień,

- analizy mikrozwapnień,
- detekcji guzków,
- analizy kształtu i tekstury guzków,
- analizy zmian tekstury (*'texture flow-field'*),
- analizy asymetrii,
- detekcji zaburzeń architektury,
- bezstratnej kompresji,
- klasyfikacji i komputerowego wspomaganie diagnozy.

Z uwagi na bardzo szeroki zakres tej tematyki dalej zostaną wybrane tylko niektóre zagadnienia, bezpośrednio dotyczące bloków rozwijanych w systemie *MammoViewer* (opisanym w rozdziale 3), ze szczególnym uwzględnieniem metod dedykowanych mikrozwapnieniom.

## 2.1 Przetwarzanie wstępne – poprawa jakości obrazów

Wynikiem wstępnego przetwarzania mammogramów ma być poprawa jakości obrazów i warunków percepcji zmian patologicznych, czyli uwydatnienie symptomów i zmian patologicznych, w tym przede wszystkim guzków i mikrozwapnień. Jest to ważne szczególnie w mammogramach z gęsto utkanymi piersiami, gdzie kontrast pomiędzy złośliwą i niezłośliwą tkanką może występować poniżej poziomu percepcji (postrzegania) lekarza. Dlatego też mikrozwapnienia w bardziej gęstej tkance mogą nie być wystarczająco widoczne, a co za tym idzie – trudne do zidentyfikowania [169].

Innym zastosowaniem przetwarzania wstępnego mammogramów może być poprawa efektywności algorytmów automatycznej detekcji. Jednakże zwykle metody przetwarzania, mające wspomagać percepcję radiologów i te mające wspomagać efektywność („percepcję”) automatu znacznie się różnią, ponieważ inny jest sposób postrzegania człowieka – radiologa, a inny sposób analizy obrazu komputera. W tym akapicie szczególny nacisk jest położony na wspomaganie percepcji lekarza oraz na metody oceny takiej poprawy jakości obrazów.

Sposobem poprawy warunków percepcji patologii jest: odszumienie, poprawa lokalnego kontrastu lub inne metody ukierunkowane na wzmacnianie wybranych właściwości obrazów (opis także w p. 1.2.2).

Należy jednak zauważyć, że poprawa percepcji wybranej patologii (np. guzów) może czasem prowadzić do pogorszenia widoczności innej patologii (np. mikrozwapnień) – zależy to od wybranych metod oraz od podkreślanych cech patologii.

Ogólnie metody przetwarzania wstępnego obrazów to matematyczne przekształcenia macierzy danych do postaci, w której łatwiej jest odnaleźć i zinterpretować interesujący region – zagrożony występowaniem patologii. Przekształcenia te to przede wszystkim transformacje przestrzenne (operujące w dziedzinie pikseli obrazu), częstotliwościowe (operujące w dziedzinie częstotliwościowej)

oraz przekształcenia wielorozdzielcze (należące do rodziny przekształceń czasowo-częstotliwościowych) [8].

### 2.1.1 Metody histogramowe

Histogramem poziomów jasności nazywamy statystyczny rozkład występowania w obrazie cyfrowym (lub w jego regionie zainteresowania) poszczególnych poziomów jasności [41]:  $h(i)$  dla  $i = 0, \dots, L$ , gdzie  $L$  – liczba poziomów jasności w obrazie. Na podstawie częstości wystąpień określonych współczynników jasności można uzyskać informacje o charakterze obrazu, np. jaki rodzaj tkanki dominuje w regionie zainteresowania [8]. Algorytmy bazujące na analizie histogramu są często używane do nieliniowej korekcji wartości jasności pikseli w obrazie. Stosuje się w tym celu analizę histogramową, na podstawie której jest wyznaczana funkcja przejścia (transformacji) jasności pikseli obrazu w celu modyfikacji histogramu.

Histogramem obrazu cyfrowego (lub regionu zainteresowania w obrazie) nazywa się wektor, którego elementy zawierają informację o liczbie punktów regionu o określonej jasności, czyli jest to rozkład wartości pikseli w obrazie w interesującym regionie [168].

Jeśli histogram będzie znormalizowany (wartości występują w zakresie  $[0, 1]$ ), wartości histogramu  $h(i)$  dla poszczególnych poziomów jasności określą prawdopodobieństwo pojawienia się danego poziomu jasności w danym obrazie  $p(i) = h(i)/K$ , gdzie  $K$  oznacza liczbę pikseli w obrazie. Dystrybuanta  $T(i)$  (kumulacyjna funkcja rozkładu) rozkładu prawdopodobieństwa danego znormalizowanym histogramem, czyli histogram kumulacyjny, to:

$$T(r) = \sum_{i=0}^r p^{(wej)}(i) \quad (2.1)$$

gdzie  $r = 0, \dots, L$ ,  $L$  – liczba poziomów jasności w obrazie [41].

Różne metody modyfikacji histogramu mogą wzmacniać – podkreślać wybrany zakres jasności obrazu. Jest to zależne od wybranej funkcji przejścia, zakładającej wyjściowy rozkład gęstości prawdopodobieństwa [121]. Dystrybuanta przetworzonego obrazu (po zastosowaniu funkcji przejścia) to [142]:

$$G(z) = \sum_{i=0}^z p^{(wyj)}(i) \quad (2.2)$$

gdzie  $p^{(wyj)}(i)$  są to wartości znormalizowanego histogramu obrazu wynikowego,  $z = 0, \dots, L$ ,  $L$  – liczba poziomów jasności w obrazie wynikowym.

Wartości kumulacyjnych funkcji rozkładów dla obrazu oryginalnego i przetworzonego powinny być sobie równe:

$$G(z) = T(r) \quad (2.3)$$

gdzie  $r$  i  $z$  są zmiennymi (jak wyżej), reprezentującymi poziomy jasności obrazów: odpowiednio – oryginalnego i przetworzonego (po operacji korekcji histogramu).

W dziedzinie ciągłej, gdzie sumie odpowiada całka, można zapisać:

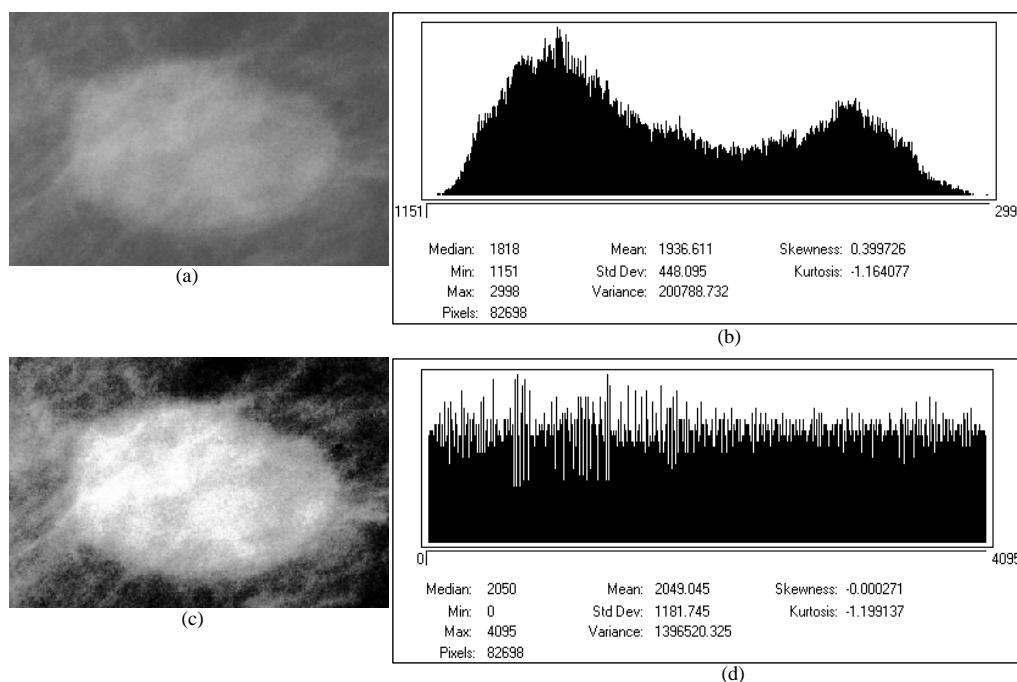
$$\int_0^z p^{(wej)}(w)dw = \int_0^r p^{(wyj)}(w)dw \quad (2.4)$$

gdzie  $p^{(wej)}(w)$  i  $p^{(wyj)}(w)$  są gęstościami prawdopodobieństwa występowania punktu o określonej jasności  $w$  odpowiednio w obrazie oryginalnym i przetworzonym (odpowiada to histogramom w dziedzinie dyskretnej).

Stąd można otrzymać wzór na funkcję przejścia:

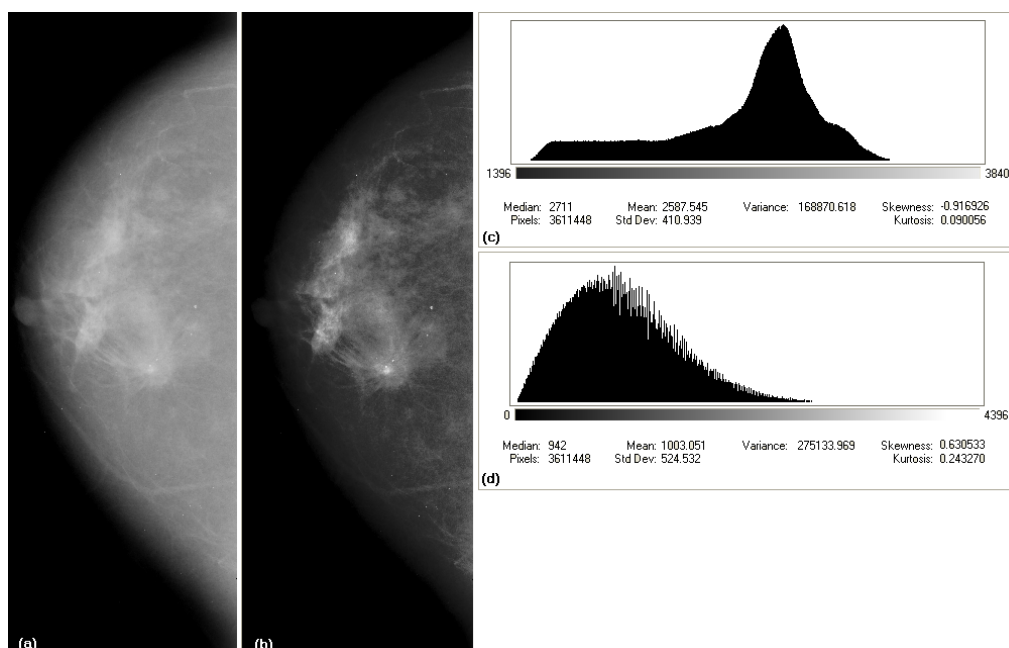
$$z = G^{-1}(T(r)) = F(r) \quad (2.5)$$

Jednak analityczne obliczenie funkcji przejścia rzadko jest możliwe. Opis algorytmu wyznaczania wartości funkcji przejścia oraz przykłady takich funkcji (rozkład jednostajny, wykładniczy, Rayleigha) są podane w dokumentacji systemu *MammoViewer*, dostępnej w załączniku E. Przykłady mammogramów po modyfikacjach histogramu są pokazane na rysunkach 2.1 i 2.2.



Rysunek 2.1: Obraz radiologiczny guza spikularnego. (a) Obraz oryginalny; (b) Histogram obrazu (a); (c) Obraz po linearyzacji histogramu; (d) Histogram obrazu (c). (Obraz źródłowy pochodzi z własnej, eksperymentalnej bazy danych. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

Adaptacyjne modyfikacje algorytmu wyrównywania histogramu polegają na korekcji wybranych wartości pikseli na podstawie lokalnych charakterystyk histogramowych, np. adaptacyjna korekcja histogramu (AHE) oraz jej modyfikacja, wzbogacona o możliwość ograniczania kontrastu (CLAHE) [8].



Rysunek 2.2: Mammogram z guzem spikularnym. (a) Obraz oryginalny; (b) Obraz po modyfikacji histogramu; (c) Histogram obrazu (a); (d) Histogram obrazu (b); Do obliczenia histogramów uwzględniono obszar tkanki piersi – bez tła. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

### 2.1.2 Filtracja w dziedzinie obrazu

Do podstawowych technik filtracji w dziedzinie obrazu, stosowanych w systemach wspomagania diagnostyki, należy zaliczyć:

- filtrację liniową realizowaną operacją splotu w dziedzinie obrazu,
- filtrację nieliniową – filtrację medianową, modalną itp.

Filtracja liniowa w dziedzinie przestrzennej obrazu polega na wykonaniu dwuwymiarowej operacji splotu dla tzw. maski oraz macierzy określającej obraz. Maska jest macierzą, zwykle o niewielkich rozmiarach (3x3, 5x5 lub 7x7), której elementy określają charakterystykę filtru (odpowiedź impulsową filtru) [168]. Istnieje wiele rodzajów filtrów, dobieranych w zależności od potrzeb: filtry dolnoprzepustowe do redukowania szumów w obrazie, filtry górnoprzepustowe do wzmacniania szczegółów o dużej częstotliwości, występujących w obrazie przy zachowaniu integralności szczegółów o małej częstotliwości (skutek uboczny – wzmacnianie szumów), filtry gradientowe i laplasjany do wykrywania i podkreślania krawędzi [41].

Splot dwóch jednowymiarowych rzeczywistych funkcji  $f$  (sygnał) i  $g$  (okno filtru) definiuje się za pomocą wzoru: w dziedzinie ciągłej:

$$(f * g)(t) = \int_{-\infty}^{\infty} f(t-x)g(x)dx \quad (2.6)$$

a w dziedzinie dyskretnej:

$$(f * g)(m) = \sum_{n \in \mathbb{Z}} f_n g_{m-n} \quad (2.7)$$

Dla funkcji dwuwymiarowych rzeczywistych  $f$  i  $g$  spłot definiuje się jako:  
w dziedzinie ciągłej:

$$(f * g)(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x-u, y-t)g(u, t)dudt \quad (2.8)$$

a w dziedzinie dyskretnej:


$$(f * g)(m, n) = \sum_{k \in \mathbb{Z}} \sum_{l \in \mathbb{Z}} f_{m-k, n-l} g_{k, l} \quad (2.9)$$

Filtracja nieliniowa, stosowana w systemach wspomaganie diagnostyki do mam-  
mografii:

- filtracja medianowa (usuwa szum bez rozmywania krawędzi):  
Dla każdego punktu obrazu oryginalnego porządkuje się zbiór punktów są-  
siadujących (którego wielkość zależy od wymiarów i kształtu maski) zgodnie  
z relacją większości. Następnie z tego uporządkowanego zbioru wybiera się  
jego medianę – wartość środkową, która jest przypisywana punktowi obrazu  
po filtracji.  
Filtr medianowy – podobnie do dolnoprzepustowego – uśrednia stopień ja-  
sności obiektów, ale zniekształcenie krawędzi jest mniejsze [168].
- selektywna filtracja medianowa (filtracja medianowa „najbliższego sąsia-  
da”) [90] – w obliczaniu mediany dla wybranego okna zbiór pikseli jest  
ograniczony do tych, których różnica poziomów jasności z pikselem cen-  
trum okna jest nie większa niż zadany próg  $T$ .  
Parametr  $T$  kontroluje jakość rozmycia krawędzi: jeśli  $T$  jest mały, to za-  
chowuje krawędzie, ale efekt wygładzający też jest mniejszy.
- wyostrzenie ekstremum (*'extremum sharpening'*) – Wartością operatora  
ekstremum jest minimum albo maximum z okna sąsiedztwa o środku w ana-  
lizowanym punkcie w zależności od tego, które z nich jest bliższe wartości  
funkcji jasności w tym punkcie. Jeśli wartość funkcji w punkcie jest dokład-  
nie w połowie pomiędzy wartościami ekstremów, wartość pozostaje niezmie-  
niona. Rozmiar okna sąsiedztwa zależy od szerokości krawędzi w obrazie  
(rys. 2.3) [136]. Standardowa procedura analizy filtrem, to: filtr medianowy  
9x9 (usuwanie szumu), wyostrzenie ekstremum 3x3, filtr medianowy 5x5.

### 2.1.3 Operatory morfologiczne

Filtracja morfologiczna jest to filtracja nieliniowa, z maską zawierającą zera i je-  
dynki (nazwaną tu elementem strukturalnym), której kształt i wymiary określają  
sąsiedztwo punktu obrazu. Dla każdego punktu obrazu zbiór jego sąsiadów jest



Rysunek 2.3: Poprawa percepcji guza spikularnego. Po lewej – oryginał, po prawej – obraz po filtracji wyostrającej ekstrema. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)


porządkowany rosnąco względem poziomu szarości. Operacja dylacji wybiera sąsiada o największej wartości jasności w miejsce danego punktu, a erozja – sąsiada o wartości jasności najmniejszej.

Niech  $D(S)$  oznacza dylację obrazu źródłowego przy zadanym elemencie strukturującym  $S$ , a  $E(S)$  – erozję. Pozostałe operacje morfologiczne, to kombinacje dylacji i erozji (rys. 2.4 i 2.5):

- Otwarcie:  $O(S) = D(E(S), S)$ ,
- Zamknięcie:  $C(S) = E(D(S), S)$ ,
- White top-hat:  $WTH = Obraz - O(S)$ , gdzie *Obraz* oznacza obraz źródłowy,
- Black top-hat:  $BTH = C(S) - Obraz$ ,  
oraz stosowane do wykrywania krawędzi:
- Gradient morfologiczny:  $GM(S) = D(S) - E(S)$ ,
- Gradient wewnętrzny:  $GW(S) = Obraz - E(S)$ ,
- Gradient zewnętrzny:  $GZ(S) = D(S) - Obraz$ .


#### 2.1.4 Przetwarzanie w wielu skalach

Analiza wielorozdzielcza polega na reprezentacji obrazu w wielu skalach. Wyznaczane są wielorozdzielcze aproksymacje obrazu (sygnału wejściowego), będące aproksymacjami obrazu z różnymi rozdzielczościami (z różnymi poziomami szczegółowości). Obraz jest zwykle dekomponowany do reprezentacji niskorozdzielczej (zgrubej) oraz sekwencji reprezentacji wysokorozdzielczych (szczegółowych) [124].



Rysunek 2.4: Filtry morfologiczne na obrazie binarnym. Element strukturujący – koło o średnicy 9 pikseli, 2 powtórzenia. (a) Obraz oryginalny; (b) Dylacja; (c) Erozja; (d) Otwarcie; (e) Zamknięcie; (f) 'White top-hat'; (g) 'Black top-hat'; (h) Gradient morfologiczny; (i) Gradient wewnętrzny; (j) Gradient zewnętrzny. (Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

## 2.1. PRZETWARZANIE WSTĘPNE – POPRAWA JAKOŚCI OBRAZÓW



Rysunek 2.5: Filtry morfologiczne na regionie mammogramu, zawierającym skupisko złożonych mikrozwapnień. Element strukturujący – koło o średnicy 9 pikseli, 2 powtórzenia. (a) Obraz oryginalny; (b) Dylacja; (c) Erozja; (d) Otwarcie; (e) Zamknięcie; (f) 'White top-hat'; (g) 'Black top-hat'; (h) Gradient morfologiczny; (i) Gradient wewnętrzny; (j) Gradient zewnętrzny. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

Wielorozdzielcze metody analizy obrazów (hierarchiczne piramidy filtrów, falki z jednowymiarowym jądrem, pakiety falek oraz przekształcenia falkowe dwuwymiarowe) umożliwiają filtrację zależną od kontekstu analizowanego obszaru. Jest to przekształcenie obrazu do dziedzin, w której możliwa jest lokalna (w odniesieniu do przestrzeni obrazu) modyfikacja współczynników różnych skal.

Wysokoczęstotliwościowe cechy, takie jak krawędzie i granice struktur, niektóre tekstury mogą być skutecznie rozróżnione w dziedzinie wielorozdzielczej (szczególnie falkowej). Możliwa jest lepsza separacja cech sygnału użytecznego od energii szumu w stosunku do metod filtracji w dziedzinie obrazu. Ponadto analiza wielorozdzielcza pozwala na kształtowanie wybranych fragmentów i cech obrazu po rekonstrukcji (zastosowanie transformaty odwrotnej), np. selekcję zmian i ich uwydatnienie metodami lokalnej poprawy kontrastu, poprzez nieliniową modyfikację rozkładu współczynników wybranych regionów i skal [104, 92, 91].

W dziedzinie wielorozdzielczej poprawę percepcji można uzyskać poprzez:

1. odszumianie (wygładzanie) – wycinanie (zerowanie) lub osłabianie współczynników transformaty, odpowiadających szumowi oraz wysokoczęstotliwościowym cechom: drobnych artefaktów, załamania krawędzi, granulacji tekstury
2. poprawa lokalnego kontrastu – wzmacnianie (podbijanie) współczynników, opisujących zmiany patologiczne.


### Filtracja falkowa

Poprzez wykorzystanie wielorozdzielczej analizy falkowej sygnał (obraz) jest reprezentowany w wielu skalach (jak na rys. 2.6). Filtracja sygnału w dziedzinie transformacji falkowej polega na modyfikacji współczynników transformaty, a następnie na obliczeniu transformaty odwrotnej (rys. 2.7). Wykorzystując wielorozdzielczą analizę falkową, można lokalnie analizować i modyfikować współczynniki różnych skal (o różnej rozdzielczości), w zależności od otoczenia (sąsiedztwa najbliższego bądź o większym zasięgu). Stąd możliwe jest precyzyjne sterowanie wprowadzanymi zmianami do sygnału (obrazu lub jego wybranego fragmentu), rekonstruowanego w różnych skalach [124, 8].


Bardzo ważnym elementem dekompozycji falkowej jest możliwość doboru funkcji bazowych (podstawowej funkcji skalującej  $\phi(x)$  oraz falki podstawowej – falki matki  $\psi(x)$ ) w zależności od cech analizowanego sygnału użytecznego. Funkcje bazowe – falki ('wavelets') to rodziny funkcji, w których każda jest wyprowadzona z funkcji matki za pomocą przesunięcia i skalowania [124].

Schemat realizacji dyskretnej transformacji falkowej (rys. 2.8) stosuje kaskadowe przetwarzanie z użyciem pary filtrów (dolno- i górnoprzepustowych), których odpowiedzi impulsowe są zależne od postaci funkcji skalującej oraz falki matki. Dla sygnałów dwuwymiarowych (obrazów) transformację falkową można uzyskać za pomocą jądra separowalnego – jądra jednowymiarowego, zastosowanego niezależnie dla obu wymiarów. Tak więc dekompozycja jest przeprowadzana najpierw dla wierszy – są tworzone dwa podpasma – dolnoprzepustowe (L) i górnoprzepustowe (H), a później dla kolumn każdego podpasma (L i H) – są tworzone


## 2.1. PRZETWARZANIE WSTĘPNE – POPRAWA JAKOŚCI OBRAZÓW



Rysunek 2.6: Wielorozdzielcza transformacja falkowa: Oryginalny obraz guza i jego reprezentacja w dziedzinie falkowej – rozkłady współczynników falkowych. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)




Rysunek 2.7: Ogólny schemat filtracji w dziedzinie falkowej [8].



Rysunek 2.8: Schemat realizacji transformacji falkowej jednego poziomu dla sygnału jednowymiarowego: analiza i synteza. Oznaczenia: filtry analizy:  $h$  – dolnoprzepustowy,  $g$  – górnoprzepustowy; filtry syntezy:  $\tilde{h}$  – dolnoprzepustowy,  $\tilde{g}$  – górnoprzepustowy,  $\downarrow 2$  – decymacja – wyrzucanie co drugiej próbki, realizowane w transformacie z decymacją,  $\uparrow 2$  – uzupełnianie próbek (wstawianie zer) dla transformacji z decymacją; składowe sygnały:  $L$  – niskoczęstotliwościowa,  $H$  – wysokoczęstotliwościowa.

cztery podpasma: LL, LH, HL, HH. Dla transformacji z decymacją po każdym kroku jest wyrzucana co druga próbka. Schemat dekompozycji został przedstawiony na rys. 2.9.



Rysunek 2.9: Schemat dekompozycji falkowej dla sygnałów dwuwymiarowych – obrazów. Oznaczenia: filtry analizy:  $h$  – dolnoprzepustowy,  $g$  – górnoprzepustowy,  $\downarrow 2$  – decymacja (wyrzucanie co drugiej próbki realizowane w transformacie z decymacją), składowe sygnały:  $L$  – niskoczęstotliwościowa,  $H$  – wysokoczęstotliwościowa,  $LL$  – podpasmo niskoczęstotliwościowe, podpasma wysokoczęstotliwościowe:  $LH$  (zawiera szczegóły pionowe),  $HL$  (poziome),  $HH$  (ukośne). Rysunek zaczerpnięty z pracy [169].

Filtracja falkowa wymaga wyboru następujących parametrów przetwarzania:

- dekompozycji (z decymacją, bez decymacji, pakiety falek):
  - jądro – falka: ortogonalne z liniową i nieliniową fazą, biortogonalne, zróżnicowane nośniki filtrów od 2 do 30 współczynników, różny poziom gładkości funkcji bazowych,
  - liczba skal,
  - schemat dekompozycji (Mallata, pakiety),
- modyfikacji współczynników falkowych:
  - zerowanie wybranych podpasm,
  - progowanie (twarde, miękkie, wiele progów, liniowe, nieliniowe krzywe przekształcenia),
  - wzmocnienie współczynników (krzywe nieliniowe).

Obszerny opis różnego typu przekształceń falkowych można znaleźć w pracach [8, 80].

### 2.1.5 Ocena jakości metod poprawy percepcji

Sformułowanie optymalnych metryk oceny algorytmów poprawy percepcji zmian patologicznych w mammografii, określających: czułość, odporność (powtarzalność) oraz specyficzność jest ciągle otwartym problemem naukowym [156].

Ogólnie do określania jakości obrazów stosuje się następujące miary [8]:

- obiektywne, skalarne miary zniekształceń (miary obliczeniowe) – wyznaczone automatycznie,
- subiektywną oceną jakości (miary obserwacyjne) – psychowizualne testy oceny jakości diagnostycznej, przeprowadzane przy pomocy grona specjalistów, według ustalonych reguł, zwykle z wykorzystaniem skali ocen (najczęściej liczbowej z opisem słownym) lub też mechanizmu porządkowania według poziomu jakości,
- obiektywno-subiektywne miary jakości – miary obliczeniowe optymalizowane z wykorzystaniem subiektywnych ocen specjalistów,
- diagnostyczne testy detekcji zmian – bazujące na możliwie wiernej symulacji rzeczywistych warunków interpretacji obrazów medycznych oraz na wnikliwej analizie statystycznej odpowiednio opracowanych testów klasyfikacyjnych (analiza ROC – porównanie czułości i specyficzności radiologów diagnozujących badania mammograficzne na obrazach oryginalnych i przetworzonych).

#### Miary obliczeniowe

Skalarne miary jakości obrazów do analiz porównawczych, mówiące o stopniu wprowadzonych w obrazie zmian, to przede wszystkim [124]:

- maksymalna różnica (*maximal difference*):

$$MD = \max_{m,n} \{|f(m, n) - \tilde{f}(m, n)|\} \quad (2.10)$$

- błąd średniokwadratowy (*mean square error*):

$$MSE = \frac{1}{MN} \sum_{m,n} [f(m, n) - \tilde{f}(m, n)]^2 \quad (2.11)$$

- szczytowy stosunek sygnału do szumu (*peak signal to noise ratio*):

$$PSNR = 10 \cdot \log \frac{MN \cdot [\max_{m,n} f(m, n)]^2}{\sum_{m,n} [f(m, n) - \tilde{f}(m, n)]^2} \quad (2.12)$$

- średnia różnica (*average difference*):

$$AD = \frac{1}{MN} \sum_{m,n} |f(m, n) - \tilde{f}(m, n)| \quad (2.13)$$

- znormalizowany błąd średniokwadratowy (*correlation quality*):

$$CQ = \frac{\sum_{m,n} f(m,n) \tilde{f}(m,n)}{\sum_{m,n} f(m,n)} \quad (2.14)$$

- dokładność rekonstrukcji obrazu (*image fidelity*):

$$IF = 1 - \frac{\sum_{m,n} [f(m,n) - \tilde{f}(m,n)]^2}{\sum_{m,n} [f(m,n)]^2} \quad (2.15)$$

- miara chi-kwadrat (*chi-square measure*):

$$\chi^2 = \frac{1}{MN} \sum_{m,n} \frac{[f(m,n) - \tilde{f}(m,n)]^2}{f(m,n)} \quad (2.16)$$

gdzie  $f(m,n)$  – funkcja jasności obrazu oryginalnego o wymiarach  $M \times N$ ,  $0 \leq m < M, 0 \leq n < N$ ,  $\tilde{f}(m,n)$  – funkcja jasności obrazu przetworzonego.

Do używanych obiektywnych miar poprawy kontrastu można zaliczyć:

- indeks poprawy kontrastu CII [138, 93], obliczany na podstawie skontrastowania obiektu i tła (*DR*) [124]:

$$DR = \frac{\bar{f}_O - \bar{f}_B}{\bar{f}_O + \bar{f}_B} \quad (2.17)$$

gdzie  $\bar{f}_O$  – średni poziom szarości obiektu,  $\bar{f}_B$  – średni poziom szarości tła obiektu;

$$CII = \frac{DR_p}{DR_o} \quad (2.18)$$

gdzie  $DR_p$  i  $DR_o$  to kontrasty obiektu, liczone odpowiednio na obrazie przetworzonym i oryginalnym.

- miara separacji rozkładów DSM (*'distribution separation measure'*) [143]:

$$DSM = (|\bar{f}_O^p - \bar{f}_B^p|) - (|\bar{f}_O^o - \bar{f}_B^o|) \quad (2.19)$$

gdzie  $\bar{f}_O^p$  i  $\bar{f}_B^p$  odpowiada średniej intensywności obiektu i tła po przetworzeniu, a  $\bar{f}_O^o$  i  $\bar{f}_B^o$  to średni poziom intensywności obiektu i tła na oryginałach (przed przetwarzaniem).

- inne miary poprawy kontrastu, np.  $TBC_S$  i  $TBC_E$  to stosunki średnich intensywności obiektu i tła oraz ich odchylenia standardowe i entropie [143].

Miary obiektywne zwykle są jednak stosowane do skonstruowanych syntetycznie obiektów, np. sztucznie wygenerowanych guzków, zanurzonych w tekście tkanki mammogramu [143, 30]. Przy rzeczywistych obiektach jest potrzebna dokładna segmentacja obiektów i analiza większego obszaru tła (powiększony kontekst zmiany – zmiana na tle nawet całego obrazu medycznego).

## 2.1. PRZETWARZANIE WSTĘPNE – POPRAWA JAKOŚCI OBRAZÓW

Miary skalarne do analiz porównawczych, takie jak błąd średniokwadratowy, szczytowy stosunek sygnału do szumu mogą być stosowane jako dodatkowa informacja, opisująca stopień wprowadzanych w obrazie zmian, ale one także nie dają właściwej informacji o poprawie percepcji zmian [8] (jest to także wnioskiem z własnych doświadczeń, opisanych w p. 3.3).

### Miary obserwacyjne

Miary obserwacyjne są naturalnym sposobem oceny jakości obrazu. Opierają się na opiniach odbiorców informacji obrazowej, którzy są w stanie określić, czy oglądany obraz jest wiarygodny i czy będzie pomocny w diagnozie [8].

Podstawowymi problemami, związanymi ze stosowaniem miar obserwacyjnych, są: czasochłonność testów, subiektywizm (każdy ze specjalistów ocenia dany obraz w nieco inny sposób, brakuje obiektywnych kryteriów oceny), konieczność angażowania kilku niezależnych ekspertów, czynniki ludzkie, takie jak zmęczenie, możliwości pomyłek [8].

Skala ocen dla miar subiektywnych powinna mieć zdefiniowany zakres liczbowy oraz skojarzony z nim opis słowny. Opis ten ma charakter bezwzględny (miary absolutne) i względny (miary porównawcze). Przykłady skal z opisem podano w tabelach 2.1 i 2.2. Na podstawie ocen cząstkowych poszczególnych osób, biorących udział w teście, jest obliczana średnia ocena grup obrazów przez obserwatorów według zależności:

$$S = \frac{\sum_{k=1}^K s_k n_k}{\sum_{k=1}^K n_k} \quad (2.20)$$

gdzie  $K$  – liczba kategorii w przyjętej skali,  $s_k$  – wartość oceny, związanej z kategorią  $k$ ,  $n_k$  – liczba ocen z danej kategorii [126].

Kategoria $k$	Wartość skali ocen $s_k$	Opis słowny, charakteryzujący jakość obrazu
1	3	Zdecydowanie (bezwzględnie) lepsza
2	2	Lepsza
3	1	Nieznacznie lepsza
4	0	Porównywalna z oryginałem
5	-1	Nieznacznie gorsza
6	-2	Gorsza
7	-3	Zdecydowanie (bezwzględnie) gorsza

Tabela 2.1: Przykładowa skala ocen jakości obrazów, stosowana w psychowizualnych testach porównawczych do oceny metod poprawy percepcji. Służy do opisu ogólnego, subiektywnego wrażenia specjalistów z danej dziedziny (radiologów), porównujących obraz przetworzony z oryginalnym [124].

Kategoria $k$	Wartość skali ocen $s_k$	Opis słowny, charakteryzujący wiarygodność diagnostyczną obrazów
1	1	Brak objawów patologicznych
2	2	Nieznacznie zarysowana zmiana – przypuszczalnie patologiczna
3	3	Rozróżnialne cechy patologiczne struktur
4	4	Wyraźne cechy o charakterze patologicznym
5	5	Niewątpliwa zmiana patologiczna w obrazie

Tabela 2.2: Przykładowa skala ocen jakości obrazów, stosowana w psychowizualnych testach miar subiektywnych, przystosowana do konkretnej aplikacji medycznej. Zawiera opis słowny w kategorii bezwzględnej detekcji patologii (jedynie na podstawie obserwowanego obrazu) [124].

### Diagnostyczne testy detekcji zmian

Najczęściej stosowaną metodą opisu pracy radiologa [30, 104], polegającą na rozpoznawaniu patologii w statystycznie istotnym zbiorze badań obrazowych przez zespół specjalistów z danej dziedziny z różnych ośrodków medycznych, są testy detekcji (oceny wiarygodności) z analizą bazującą na krzywej ROC (*Receiver Operating Characteristic*) [144]. Decyzje podejmowane w trakcie trwania testu przez radiologów, dotyczące rozpoznania patologii, dzieli się na:

- poprawne:
  - potwierdzające rzeczywistą obecność patologii w prezentowanym obrazie – badaniu (decyzje prawdziwie pozytywne TP – *true positives*)
  - potwierdzające brak obecności patologii (decyzje prawdziwie negatywne TN – *true negatives*)
- wskazania błędne:
  - fałszywie negatywne FN – *false negatives*
  - fałszywie pozytywne FP – *false positives*

Liczba błędnych wskazań zwiększa się w zależności od wpływu czynników pogarszających jakość obrazów, np. ograniczenia danej metody obrazowania, wybór niewłaściwych parametrów systemu, słabe warunki obserwacji, brak doświadczenia lub nieuwaga obserwatora [124].

Krzywa ROC powstaje przez umieszczenie wyników rozpoznania w układzie współrzędnych, w którym oś rzędnych reprezentuje czułość (SE – *sensitivity*), czyli frakcję przypadków prawdziwie pozytywnych (TPF), a oś odciętych – specyficzność<sup>1</sup> (SPEC – *specificity*) lub frakcję przypadków fałszywie pozytywnych (FPF=100%-SPEC). Czułość, czyli zdolność specjalisty do wykrycia wszystkich

<sup>1</sup>Inne terminy, odpowiadające specyficzności, spotykane w literaturze to: trafność [124], swoistość.

## 2.1. PRZETWARZANIE WSTĘPNE – POPRAWA JAKOŚCI OBRAZÓW


patologii w obrazach danej jakości, jest określona jako procentowa zawartość liczby decyzji prawdziwie pozytywnych  $N_{TP}$  wśród wszystkich decyzji odnośnie obrazów zawierających patologię  $N_{pat}$ :

$$SE[\%] = \frac{N_{TP}}{N_{pat}} \cdot 100\% \quad (2.21)$$

Natomiast specyficzność, opisująca poprawność procesu detekcji, jest określona jako stosunek liczb decyzji prawdziwie negatywnych do wszystkich obrazów bez patologii, czyli pokazuje zdolność do unikania błędnych decyzji w obrazach bez oznak patologii:

$$SPEC[\%] = \frac{N_{FN}}{N_{bezpat}} \cdot 100\% = \left(1 - \frac{N_{FP}}{N_{bezpat}}\right) \cdot 100\% \quad (2.22)$$

Przykładowe krzywe ROC są pokazane na rysunku 2.10. Idealnym wynikiem testu są wszystkie wartości czułości, jak i trafności równe 100% – ocena badań z patologią i bez patologii pokrywa się dokładnie z wzorcem – „złotym standardem”.



Rysunek 2.10: Przykładowe krzywe ROC dla przypadku idealnego, testu rzeczywistego i dla przypadkowej selekcji na obecność patologii niezdeteterminowanej informacją użyteczną [124].

Naniesione na wykres punkty z poszczególnych decyzji są aproksymowane, np. funkcjami sklejanymi, rozkładami gaussowskimi itp. Na podstawie wykreślonej krzywej oblicza się różne wielkości, takie jak pole powierzchni pod krzywą,

kształt, nachylenie, które służą do porównań i ostatecznej oceny skuteczności pracy specjalistów. Są też wykorzystywane różne testy statystyczne do oceny jakości podejmowanych decyzji, a więc pośrednio wiarygodności informacji prezentowanej przez obrazy danej klasy. Ponadto jest też stosowana weryfikacja parametrycznych hipotez statystycznych z przedziałami ufności o charakterze ilościowym oraz z poziomami istotności o charakterze jakościowym, np. do porównania wartości pól pod krzywymi [124].

### 2.1.6 Uwydatnianie mikrozwapnień


Poprawę percepcji mikrozwapnień można uzyskać przez wzmacnianie kontrastu lub eliminację tła (zdrowej tkanki) wskutek odejmowania obrazu wygładzonego (estymującego rozległe struktury zdrowej tkanki, niezawierającego mikrozwapnień) od oryginalnego lub wzmocnionego.

Stosowane metody to:

- Wyrównywanie histogramu [143], adaptacyjne wyrównywanie histogramu CLAHE [114].
- Filtracja *'box-rim'*: 9x9 wzorzec z centralnym blokiem 3x3, wypełnionym jedynkami – odpowiadający mikrozwapnieniu – z wyzerowaną otoczką wokół centralnego bloku oraz z zewnętrzną otoczką o szerokości 2 pikseli, wypełnioną jedynkami – odpowiadającymi otaczającemu tłu [27].
- Eliminacja tła – obraz przetworzony filtrem wygładzającym Gaussa [27, 34].
- Eliminacja tła – modelowanie prawidłowej (zdrowej) tkanki poprzez techniki fraktalne, wykorzystujące lokalne samopodobieństwo struktur zdrowej tkanki (inaczej niż mikrozwapnienia) [93].
- Wzmacnianie oparte na sąsiedztwie: Z punktu ziarna tworzy się region za pomocą technik rozrostu regionu. Zasięg i kształt regionu dostosowuje się do lokalnej zmienności funkcji jasności. Kontrast jest wzmacniany poprzez zastosowanie transformacji, bazującej na: wartości funkcji jasności punktu ziarna, kontraście regionu i jego tła. Definicja zasięgu regionu jest tutaj kluczowym elementem [27, 105].
- Falkowe metody usuwania szumu i tła oraz poprawy kontrastu (rys. 2.11) [155, 148, 92, 104, 59],
  - usuwanie niskoczęstotliwościowych informacji (zdrowe struktury tkanki) — całkowite usuwanie współczynników z podpasz niskoczęstotliwościowych [155],
  - progowanie podpasz zawierających wysokoczęstotliwościowe współczynniki falkowe (HH,HL,LH), aby oddzielić szum od mikrozwapnień [148],
  - wzmacnianie współczynników odpowiadających za mikrozwapnienia [92].

## 2.1. PRZETWARZANIE WSTĘPNE – POPRAWA JAKOŚCI OBRAZÓW

- Morfologia — *'white top-hat'*, który uwypukla szczegóły obrazu [34, 137, 109, 14, 134], wykrywanie h-maksimów (różnica obrazu oryginalnego i rekonstrukcji z obrazu o zmniejszonych wartościach intensywności o wartość  $h$ ) [153].
- Eliminacja tła – filtracja *'round high-emphasis'* – średnia otwarcia i zamknięcia morfologicznego: filtr dolnoprzepustowy zachowujący rozległe obszary zdrowej tkanki [27, 34].
- Rozmyte adaptacyjne wzmacnianie kontrastu – analiza rozmytej reprezentacji obrazu (bazującej na analizie histogramu) [28] oraz połączona z analizą obrazu wartości własnych utworzonego za pomocą tensora strukturalnego (stworzonego na podstawie analizy gradientu obrazu wygładzonego filtrem Gaussowskim) [77].



Rysunek 2.11: Poprawa percepcji mikrozwapnień z wykorzystaniem falek bez decymacji: oryginał, uwydatnienie oraz dwa obrazy współczynników falkowych. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

## 2.2 Detekcja potencjalnych guzów i zaburzeń architektury

Metody detekcji guzów można podzielić przede wszystkim ze względu na dwa rodzaje guzów: spikularne i o gładkich zarysach. Większość zmian złośliwych to zmiany spikularne, stąd wiele algorytmów skupia się na analizie spikularności tkanki.

Detekcja guzów najczęściej składa się z dwóch etapów [138]:

- detekcja podejrzanych obiektów w mammogramie,
- klasyfikacja podejrzanych regionów na guzy i prawidłową (zdrową) tkankę.

Ogólny schemat metod detekcji guzów przedstawiony jest na rysunku 1.3. Pierwszy etap zwykle jest zaprojektowany tak, aby mieć bardzo wysoką czułość, by nie pominąć żadnego obszaru z patologią przy dopuszczalnej dużej liczbie nadmiarowych wskazań. Większość nadmiarowych wskazań powinna być usunięta w drugiej fazie algorytmów.

Algorytmy detekcji potencjalnych guzków (etap pierwszy) można podzielić na dwa rodzaje [138, 95]:

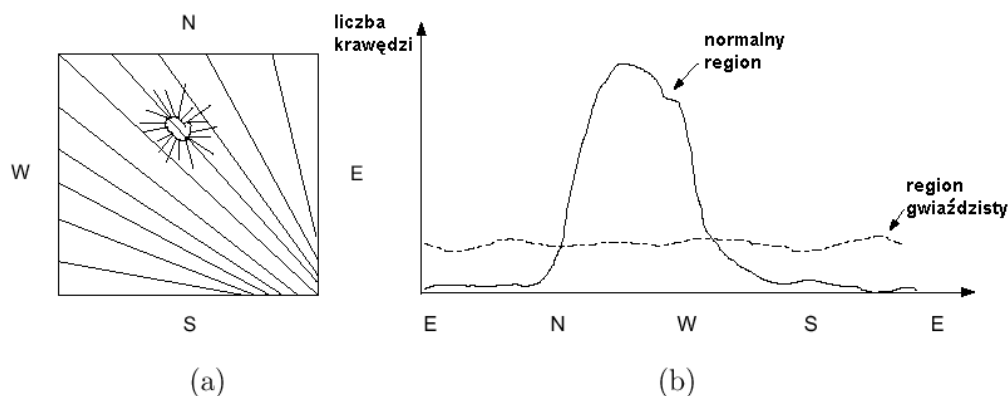
1. bazujące na analizie pojedynczych pikseli (*'pixel-based'*): Każdy piksel jest klasyfikowany jako przynależący do guza lub prawidłowy (zdrowy), na podstawie swoich cech obliczanych z lokalnego sąsiedztwa piksela. Następnie wszystkie podejrzane punkty są grupowane w regiony (np. grupowane na podstawie sąsiedztwa).
2. bazujące na analizie regionów (*'region-based'*): Najpierw jest znajdowany podejrzany region (filtracja, segmentacja). Dla każdego regionu są obliczane cechy do klasyfikacji.

### 2.2.1 Detekcja, bazująca na analizie pojedynczych pikseli

**Detekcja guzów spikularnych i zaburzeń architektury, bazująca na analizie pojedynczych pikseli** Uwidoczniona na mammogramie prawidłowa struktura tkanki promieniuje w określonym kierunku od klatki piersiowej do brodawki. W regionie zmiany spikularnej tkanka promieniuje we wszystkich kierunkach. Metody detekcji polegają na obliczaniu orientacji krawędzi w każdym punkcie.

- analiza statystyczna histogramu lokalnych orientacji krawędzi ALOE (rys. 2.12) oraz cechy tekstury Law; klasyfikacja każdego piksela – binarne drzewo decyzyjne [85],
- statystyczna analiza map orientacji pikseli (orientacje pikseli są policzone na podstawie filtrów — pochodnych kierunkowych Gaussa) [83],
- wielorozdzielcza dekompozycja falkowa w celu wychwycenia guzów różnych rozmiarów; detekcja jest przeprowadzana od skali zgrubnej (większe guzy) do coraz dokładniejszej (mniejsze zmiany); na każdym poziomie rozdzielczości zastosowano statystyczną analizę ALOE (j.w.) [98].

## 2.2. DETEKCJA POTENCJALNYCH GUZÓW I ZABURZEŃ ARCHITEKTURY



Rysunek 2.12: (a) Kierunki spikuli w guzie gwiaździstym różnią się od kierunków ułożenia zdrowej tkanki, widocznych na mammogramie. (b) Histogram orientacji gradientu rozróżnia obszar zmiany spikularnej od prawidłowego (zdrowego).

### Detekcja wszystkich rodzajów guzów, bazująca na analizie pojedynczych pikseli

- wstępna segmentacja podejrzanych regionów — adaptacyjne progowanie; iteracyjna poprawa segmentacji przy użyciu wielorozdzielczego pola losowego Markowa (*'Markov random field'*); [95],
- podział mammogramów na kategorie w zależności od rodzaju tkanki piersi (progowanie adaptacyjne); podejrzane regiony są segmentowane na podstawie różnych wartości progów, w zależności od rodzaju tkanki; [103],
- uwydatnianie morfologiczne i segmentacja, bazująca na modelu stochastycznym; model histogramu obrazu mammograficznego — uogólniony rozkład gaussowski; segmentacja poprzez klasyfikację pikseli za pomocą *'Bayesian relaxation labeling'* [94],
- przybliżenie lokalnego histogramu splajnami Beziera, próg to najmniejsze minimum histogramu lub skrajne prawe przegięcie histogramu [132].

### Charakterystyka metod, bazujących na analizie pikseli [138, 95]

- duża liczba próbek do nauki klasyfikatora (każdy piksel jest próbką dla klasyfikatora),
- inna charakterystyka pikseli wewnątrz zmiany i na obrzeżach – w rzeczywistości wymaga różnego rodzaju cech,
- inna charakterystyka różnych rodzajów guzów, tj. dobrze odgraniczonych, nieregularnych, spikularnych – wymaga różnego rodzaju grup operatorów (cech),

- duża liczba pikseli z jednego guza reprezentuje tylko jedną, szczególną zmianę (potrzeba dużej bazy, zawierającej bogaty zbiór różnorodnych przypadków patologii),
- brak analizy przestrzennego rozłożenia pikseli (bardzo ważny czynnik, różniący guzy od prawidłowej tkanki),
- duża złożoność obliczeniowa.

### 2.2.2 Detekcja, bazująca na analizie regionów

Tutaj wiele metod korzysta z idei dopasowywania wzorca. Obraz jest filtrowany maską użytą jako model guza. Wartości obrazu po filtracji będą wysokie blisko centrum guza [138].

Do metod detekcji guzów, bazujących na analizie regionów, można zaliczyć:

- filtr *Iris* – model guza: okrągły wypukły region – zastosowany do mapy gradientów obrazu (operator Prewitta); Wyjście filtru niezależne od kontrastu między patologią a tłem [87],
- filtry wykrywające krawędzie: '*Laplacian of Gaussian*', '*Difference of Gaussian*' [113, 120],
- piramida gaussowska [23],
- transformata Hougha dla okręgów, zastosowana na obrazie krawędzi (operator Canny'ego) [56],
- wielorozdzielcza i wielokierunkowa transformata falkowa [133],
- lokalna analiza tekstury oraz momentów lokalnych histogramów poziomów jasności [29].

Kształty wykrytych obiektów mogą być poprawiane z zastosowaniem technik rozrostu regionów [120].

### Charakterystyka metod, bazujących na analizie regionów [138, 95]

- analiza przestrzennego rozłożenia pikseli,
- cechy mają bezpośrednie odniesienie do ważnych informacji diagnostycznych – morfologii i geometrii wyodrębnionych regionów, np. kształt i zarysy wykrytych regionów,
- mniejsza złożoność obliczeniowa (mniejsza przestrzeń cech) niż metod, bazujących na analizie pikseli,
- można uzyskać mniej próbek do nauki klasyfikatora (W metodach na pikselach próbki oznaczały każdy piksel patologii oddzielnie, tutaj jedna patologia stanowi jedną próbkę.).

## 2.3 Detekcja potencjalnych mikrozwapnień

Ogólny schemat systemów detekcji i klasyfikacji mikrozwapnień wzoruje się na schemacie z rysunków 1.2 i 1.3 z dodanym blokiem grupowania obiektów w klastry:

1. wstępne przetwarzanie,
2. lokalizacja obiektów zainteresowania,
3. segmentacja obiektów zainteresowania,
4. ekstrakcja cech,
5. selekcja cech,
6. klasyfikacja – wskazanie zmian podejrzanych – potencjalnych mikrozwapnień.

Etap grupowania może następować już po etapie lokalizacji lub po segmentacji albo na końcu, po redukcji fałszywych wskazań w zależności od celu grupowania (np. celem może być eliminacja dużej części fałszywych wskazań) oraz od definicji i reguł grupowania.

Danymi wejściowymi komputerowej detekcji mikrozwapnień jest obraz mamograficzny z odpowiednio dobranymi parametrami akwizycji (odpowiednia rozdzielczość obrazu itp.). We wstępnej fazie obróbki obrazu następuje uwypuklenie cech charakterystycznych dla mikrozwapnień, osłabienie cech obrazu odnoszących się do prawidłowych struktur tkanki i szumu. Następnie są lokalizowane potencjalne regiony, zawierające mikrozwapnienia. Pojedyncze obiekty są grupowane w większe skupiska, według ustalonej definicji grupy, np. 5 obiektów lub 3 obiekty na obszarze o wymiarach 1x1 cm. Segmentacja mikrozwapnień to odseparowanie ich z tła (prawidłowej tkanki). W niektórych algorytmach etap lokalizacji jest połączony z etapem segmentacji. Kolejną fazą jest ekstrakcja różnorodnych cech, charakteryzujących pojedyncze mikrozwapnienia oraz ich skupiska. Selekcja polega na wybraniu tych cech, które najlepiej charakteryzują poszczególne grupy klastrów mikrozwapnień. Klasyfikacja jest uzupełnieniem detekcji – rozpoznaniem potencjalnych mikrozwapnień wśród wcześniej wybranych obiektów zainteresowania. Po fazie detekcji mogą następować etapy diagnozy, ekstrakcji i selekcji cech różnicujących skupiska złośliwych i łagodnych mikrozwapnień, a następnie klasyfikacji obiektów na te o zwiększonym prawdopodobieństwie złośliwości i typowo łagodne [27].

### 2.3.1 Lokalizacja

Metody lokalizacji regionów, potencjalnie zawierających skupiska mikrozwapnień, to statystyczna analiza tekstury – cechy macierzy SRDM 'Surrounding Region-Dependance' [86] lub też obliczanie wymiaru fraktalnego [37] (określającego „chropowatość” obszaru dla ustalonego podobrazu). W [1] błąd predykcji


służyć do lokalizacji pojedynczych obiektów mikrozwapnień. Przyjęto tam założenie, że mikrozwapnienia – punkty niestacjonarności – są zanurzone w przybliżeniu jednorodnym tle, a więc nie mogą być przewidziane przez liniowy predyktor, co prowadzi do dużego błędu predykcji.

Inne metody lokalizacji pojedynczych obiektów zainteresowania są zwykle realizowane przez poszukiwanie lokalnych maksimum na obrazach przetworzonych różnego typu operatorami. Lokalnych maksimum poszukuje się m.in. na:

- obrazie oryginalnym [7],
- obrazach po filtracji *LoG* ('*Laplacian-of-Gaussian*') w różnych skalach [108] – skalowalne filtry *LoG*,
- wybranych podpasmach, zawierających wysokoczęstotliwościowe współczynniki falkowe [167],
- obrazie po operacji morfologicznej 'white top-hat' [160].

### Skalowalne filtry *LoG*

Realizacja reprezentacji wielorozdzielczej obrazu za pomocą skalowalnych filtrów '*Laplacian-of-Gaussian*' (*LoG*) polega na filtracji obrazu za pomocą filtrów *LoG* o różnych skalach (rys. 2.13, 2.14)(podobnie do [108]). Reprezentacja taka może służyć na przykład wyszukiwaniu jasnych (o nieco wyższej jasności od otoczenia), małych, w przybliżeniu okrągłych plam (o rozkładzie funkcji jasności w przybliżeniu gaussowskim) na obrazie – będą to lokalne maksima przy skali filtru dobranej odpowiednio do rozmiaru plamki.




Rysunek 2.13: Wielorozdzielcza reprezentacja obrazu, zrealizowana za pomocą skalowalnych filtrów *LoG*: Oryginalne skupisko złośliwych mikrozwapnień i wielorozdzielcza reprezentacja jego obrazu – obrazy po filtracji za pomocą filtrów *LoG* o skalach  $h$  odpowiednio: 7, 10, 20 (od lewej do prawej). (Obraz źródłowy pochodzi z własnej, eksperymentalnej bazy obrazów. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

**Definicja filtrów dopasowujących *LoG*:** Dwuwymiarowy rozkład Gaussa, to:

$$G_{\sigma}(x, y) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2} \quad (2.23)$$

gdzie  $\sigma > 0$  jest odchyleniem standardowym oraz  $x, y \in \mathbb{R}$ .

### 2.3. DETEKCJA POTENCJALNYCH MIKROZWAPNIEŃ



Rysunek 2.14: Wielorozdzielcza reprezentacja obrazu, zrealizowana za pomocą skalowalnych filtrów *LoG*: Oryginalny fragment mammogramu (ze skupiskiem złośliwych mikrozwapnień, dwoma łagodnymi dużymi makrozwapnieniami oraz z widocznymi licznymi włóknami) i jego wielorozdzielcza reprezentacja – obrazy po filtracji za pomocą filtrów *LoG* o skalach  $h$  odpowiednio: 7, 10, 20 (od lewej do prawej). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

Dwuwymiarowe filtry *Laplacian-of-Gaussian* [108] są zdefiniowane poprzez zastosowanie operatora różniczkowego drugiego rzędu – operatora Laplace’a  $\Delta$  do rozkładu Gaussa (2.23):

$$LoG_{\sigma}(x, y) = -n(\sigma)(\Delta G_{\sigma}(x, y)) = n(\sigma)\frac{1}{\pi\sigma^4}\left(1 - \frac{x^2 + y^2}{2\sigma^2}\right)e^{-(x^2+y^2)/(2\sigma^2)} \quad (2.24)$$

gdzie  $n(\sigma)$  – mnożnik normalizujący,  $x, y \in \mathbb{R}$ ,  $\sigma$  jest ciągłą skalą filtru  $LoG_{\sigma}$ .

W celu zastosowania w cyfrowym przetwarzaniu obrazów jest przydatna skala filtrów  $LoG$ , mierzona w liczbie pikseli: skalę tę można zdefiniować jako średnicę rzutu centralnego piksu (dodatniej części funkcji  $LoG$ ) na płaszczyznę.

Stąd:

$$\sigma = \frac{1}{2\sqrt{2}}h \quad (2.25)$$

Natomiast mnożnik  $n(\sigma)$  niezależnie odpowiada filtru od skali, tak aby można było porównywać odpowiedzi filtru między skalami. Mnożnik jest równy odwrotności objętości centralnego piksu (szczytu) funkcji  $LoG_{\sigma}(x, y)$ .

$$n(\sigma) = \frac{e\sigma^2}{2} \quad (2.26)$$

Stosując wzór (2.25), mamy:

$$n(h) = \frac{eh^2}{16} \quad (2.27)$$

Rozmiar filtru dyskretnego wynosi  $3h$  albo  $3h + 1$ , jeśli  $h$  jest parzyste. W [108] zostały dodatkowo wprowadzone współczynniki relaksacyjne dla masek filtrów  $LoG$  o skali  $h = 1, 2$ .

Współczynniki znormalizowanych filtrów laplasjanowych są pokazane na rys. 2.15.

Jasne plamki odpowiadają lokalnym maksimum w obrazach przefiltrowanych laplasjanem, jeśli rozmiar jądra filtru jest odpowiednio wybrany [108]. Filtr dopasowujący (*‘matched filter’*) ma maksymalną odpowiedź w położeniu wzorca nawet w zaszumionym obrazie.

**Wielorozdzielcza reprezentacja obrazu:** Wielorozdzielczą reprezentację obrazu uzyskuje się poprzez splot filtrów laplasjanowych o różnych  $h$  z obrazem:

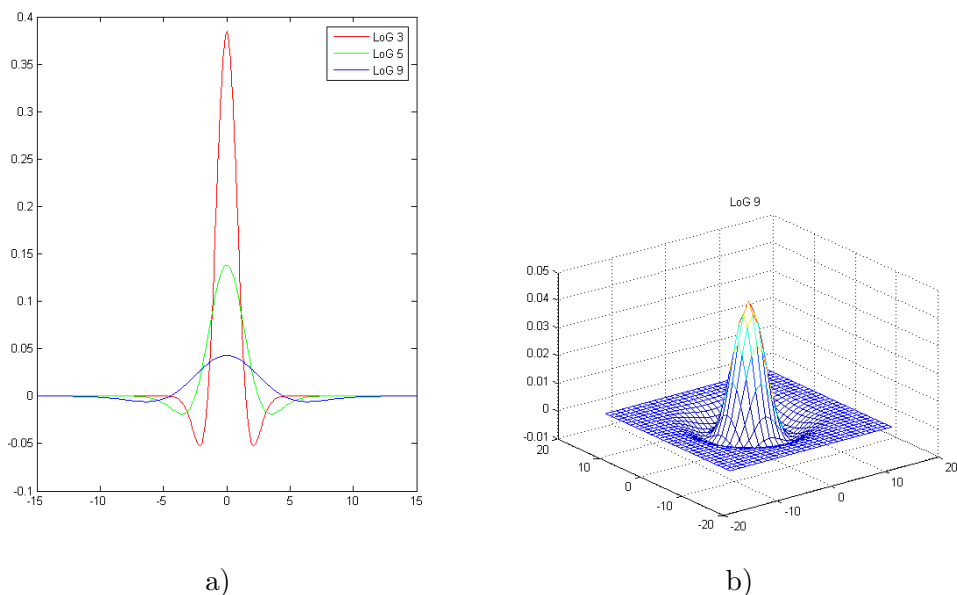
$$[LoG_h * f](x, y) \quad (2.28)$$

gdzie skala  $h = 1, \dots, h_{max}$ .

### **Lokalizacja pojedynczych obiektów mikrozwapnień za pomocą skalowalnych filtrów $LoG$**

Lokalizacja pojedynczych obiektów potencjalnych mikrozwapnień jest realizowana przez skalowalne filtry  $LoG$  (*‘Laplacian-of-Gaussian’*) [108]. Na początku potencjalne obiekty mikrozwapnień są identyfikowane (wskazanie położenia) jako lokalne maksima w mammogramie przefiltrowanym za pomocą filtrów  $LoG$

### 2.3. DETEKCJA POTENCJALNYCH MIKROZWAPNIĘĆ



Rysunek 2.15: (a) Zrutowane na płaszczyznę z-x współczynniki trzech filtrów  $LoG$  o różnych skalach  $h$ , gdzie  $h=3, 5, 9$ . (b) Współczynniki filtru  $LoG$  o skali  $h = 9$ .

o różnych skalach. Dla każdego znalezionej obiektu są estymowane jego rozmiar i lokalny kontrast za pomocą skali i odpowiedzi wybranego filtru  $LoG$ . Obiekt klasyfikowany jest jako obiekt zainteresowania (OZ), jeśli estymowany kontrast jest większy od predefiniowanego progu zależnego od rozmiaru obiektu.

**Założenia:** Mikrozwapnienia są widoczne na mammogramach jako małe, jasne okrągłe lub lekko wydłużone plamki (obszary) o średnicach kilku pikseli (ich rzeczywiste wymiary to ok. 0,1-0,3 mm).

**Przyjęty wzorzec kandydata na mikrozwapnienie:** Średni profil mikrozwapnienia może być opisany przez okrągłą – symetryczną funkcję Gaussa [108][148] (wzór funkcji: 2.23).

#### Algorytm 2.1. Lokalizacja pojedynczych mikrozwapnień

1. Znalezienie jasnych, prawie okrągłych plamek na obrazie – wieloskalowy detektor plamek (*'multiscale spot detector'*).
2. Oszacowanie rozmiaru  $D$  i lokalnego kontrastu  $C$  każdej plamki.
3. Pozostawienie plamki – oznaczenie plamki jako mikrozwapnienia, jeśli  $C > T(D)$ , gdzie  $T(D)$  jest predefiniowanym progiem, zależnym od estymowanego rozmiaru plamki. Próg  $T(D)$  kontroluje czułość detekcji, np. jeśli  $T(D)$

jest niski, to nawet słabe i niewyraźne plamki są identyfikowane jako mikrozwapnienia.

**Wieloskalowy detektor plamek** Jasne plamki są identyfikowane za pomocą detektora, korzystającego z wielorozdzielczej reprezentacji, bazującej na skalowalnych filtrach *LoG*.

**Algorytm 2.2.** *Wieloskalowy detektor plamek*

1. Znalezienie lokalnych maksimumów w obrazie po filtracji *LoG* o najniższej skali  $h_{MIN}$ .
2. Inicjalizacja ścieżek w hierarchicznej strukturze dekompozycji dla każdego znalezionego maksimum oraz kontynuacja poszukiwania lokalnych maksimumów aż do najwyższej skali  $h_{MAX}$ .
3. Zidentyfikowanie największej odpowiedzi filtru na każdej ścieżce i oznaczenie odpowiadającego jej punktu jako centrum optymalnego kandydata.


Lokalne maksimum to piksel, którego wartość jest największa w swoim sąsiedztwie (np. kwadratowym o wymiarach 3x3). Takie lokalne maksima w obrazie po filtracji *LoG* o odpowiedniej skali są oznaczane jako piksele – kandydaci (centra plam). Kandydaci dla najniższej skali  $h_{MIN}$  to lokalne maksima o bardzo małym lokalnym kontraście. Dla większych skal filtru *LoG* szum oraz mniejsze plamki zostają usunięte oraz zdarza się, że kandydaci są przesunięci z prawdziwych centrów plamek. Jednak, aby można było wiarygodnie określić rozmiar oraz lokalny kontrast poszukiwanych jasnych plamek, powinny być one oznaczone przez ich prawdziwe centra.

Dlatego też lokalizacja prawdziwych kandydatów (centrów plamek) przebiega poprzez śledzenie odpowiedzi filtrów *LoG* od najmniejszej skali do największej w sąsiedztwie początkowego kandydata (z najniższej skali). Taka ścieżka rozpoczyna się dla najniższej skali i kończy dla kolejnej wyższej skali, jeśli odpowiadający kandydat nie zostaje znaleziony w najbliższym sąsiedztwie kandydata z niższej skali.

Kandydaci z tej samej ścieżki należą do jednej jasnej plamki na obrazie oryginalnym, ale ich związek z prawdziwym jej centrum jest różny. Ponieważ jądra filtrów *LoG* są znormalizowane ze względu na centralny szczyt, największa odpowiedź filtru na ścieżce wskazuje obiekt najlepiej dopasowany do wybranego wzorca – optymalnego kandydata, reprezentującego plamkę (rys 2.16).

**Estymacja rozmiaru i lokalnego kontrastu plamki** W [108] jasne plamki są przybliżone przez cylindry o środku w punkcie optymalnego kandydata ze ścieżki oraz średnicy równej skali filtru *LoG* dla tego kandydata. Natomiast lokalny kontrast plamki jest estymowany przez odpowiedź filtru *LoG* dla tego kandydata. Udowodniono także podobieństwo pomiędzy modelami cylindrycznym i gaussowskim mikrozwapnienia:

### 2.3. DETEKCJA POTENCJALNYCH MIKROZWAPNIENÍ



Rysunek 2.16: Gaussowski model mikrozwapnienia: (a) Mikrozwapnienie na obrazie. (b) Współczynniki filtru  $LoG7$ .

Pojedyncze mikrozwapnienie można przybliżyć cylindrem o środku w centrum mikrozwapnienia (to punkt  $M = (0, 0)$  w modelu) oraz o średnicy  $D$  i wysokości  $C$ , które odpowiadają średnicy plamki na obrazie oraz jej lokalnemu kontrastowi:

$$f(x, y) = \begin{cases} C & \text{jeśli } x^2 + y^2 \leq \frac{D^2}{4}, \\ 0 & \text{w przeciwnym przypadku.} \end{cases} \quad (2.29)$$

Analogiczny model gaussowski to:

$$f(x, y) = C e^{-(4/D^2)(x^2+y^2)} \quad (2.30)$$

Wyprowadzono wzory odpowiedzi filtrów  $LoG$  na modelach w zależności od skali filtru  $LoG$ :

$$r(h) = [LoG_h * f](x, y) |_{M=(0,0)} \quad (2.31)$$

dla modelu cylindrycznego:

$$r_{cyl}(h) = C e^{\frac{D^2}{h^2}} e^{-(D^2/h^2)} \quad (2.32)$$


dla modelu gaussowskiego:

$$r_{Gauss}(h) = C e^{\frac{D^2 h^2}{(D^2 + h^2)^2}} \quad (2.33)$$

Stąd funkcja przyjmuje lokalne maksimum dla:

model cylindryczny:  $h_{MAX} = D, r_{cyl}(h_{MAX}) = C$ ,

model gaussowski:  $h_{MAX} = D, r_{Gauss}(h_{MAX}) = \frac{e}{4} C$ . W centrum obiektu – modelu mikrozwapnienia największą wartość przyjmuje filtr, którego skala  $h_{MAX}$  odpowiada średnicy obiektu  $D$  (rys. 2.17). Wartość ta (odpowiedź filtru) odpowiada lokalnemu kontrastowi modelu. W pracy zaproponowano także korektę



Rysunek 2.17: Odpowiedzi filtrów LoG o różnych skalach  $h$  (na osi X) w punkcie centrum dla modeli mikrozwapnienia: cylindrycznego (krzywa ciągła) dla  $C=100$  i  $D=7$  oraz gaussowskiego (krzywa z kropek) dla przeskalowanej wartości  $C$  oraz  $D=7$ .

modelu mikrozwapnienia ze względu na szum w obrazie (przyjęto gaussowski model szumu o średniej równej zero  $N(0, \sigma_r)$ ):

$$r_{noise}(h) = r_{cyl}(h) + \sigma(h) = C e^{\frac{D^2}{h^2}} e^{-(D^2/h^2)} + \sigma_r \frac{e}{\sqrt{\pi}} \frac{1}{h} \quad (2.34)$$

gdzie szum po splocie z filtrem LoG w skali  $h$ :

$$\sigma(h) = \sigma_r \frac{e}{\sqrt{\pi}} \frac{1}{h} \quad (2.35)$$

W algorytmie zaproponowano korekcję odpowiedzi filtru dla każdej skali o  $1/h$  [108].

### 2.3.2 Segmentacja

Część metod segmentacji mikrozwapnień operuje na zlokalizowanych wcześniej obiektach (znalezionych punktach – centrach potencjalnych mikrozwapnień lub określonym regionie zwiększonego występowania mikrozwapnień). Inne łączą dwie fazy lokalizacji i segmentacji, np. w [167] detekcja potencjalnych mikrozwapnień polega na klasyfikacji czterech cech każdego punktu w obrazie (cechy to współczynniki z wybranych poziomów transformaty falkowej oraz aproksymacja lokalnego kontrastu), tak wybrane punkty są łączone w obiekty wynikowe.

W algorytmach segmentacji mikrozwapnień z tła bazujących na lokalnym progowaniu parametrami krytycznymi są rozmiar okna – sąsiedztwo zlokalizowanego

### 2.3. DETEKCJA POTENCJALNYCH MIKROZWAPNIENÍ

obiektu i próg, np. próg adaptacyjny, zależny od statystyk z okna. Metody rozrostu regionu (*'region growing'*), służące także do segmentacji mikrozwapnień polegają na grupowaniu pikseli o właściwościach podobnych do startowego (ziarna — *'seed'*) według podanego kryterium intensywności [27]. W algorytmie *multitolerance region growing* [7] kryterium zaliczania nowego punktu do obiektu zależy od maksymalnej  $F_{max}$  i minimalnej  $F_{min}$  wartości pikseli w rozrastającym się regionie oraz od wartości parametru „tolerancji”  $\tau \in [0.01, 0.4]$  (wyznaczanego automatycznie poprzez wielokrotną segmentację). Każdy nowy punkt (będący sąsiadem według 4-spójnego sąsiedztwa przynajmniej jednego punktu, należącego do rozrastającego się obszaru) jest dodawany do obiektu, jeśli jego wartość funkcji jasności należy do przedziału  $[(1 - \tau)(F_{max} + F_{min})/2, (1 + \tau)(F_{max} + F_{min})/2]$ .

Inne metody segmentacji, to znajdowanie krawędzi zlokalizowanego obiektu w kilku kierunkach od punktu ziarna, a następnie rozwinięcie ich do pełnego konturu obiektu, np. poszukiwanie lokalnych minimów w zadanych kierunkach najbliższych ziarnu. Kolejnym algorytmem tego typu jest *'hill climbing'* – metoda, polegająca na znajdowaniu największego spadku w 16 kierunkach wokół punktu ziarna (lokalnego maksimum w obrazie) [7], gdzie spadek można zdefiniować jako:

$$s(x, y) = (f(x_0, y_0) - f(x, y))/d(x_0, y_0, x, y) \quad (2.36)$$

gdzie  $s(x, y)$  — spadek w danym kierunku,  $(x_0, y_0)$  — lokalne maksimum funkcji jasności,  $f(x_0, y_0)$  — wartość funkcji jasności w punkcie  $(x_0, y_0)$ ,  $d(x_0, y_0, x, y)$  — odległość Euklidesowa pomiędzy  $(x_0, y_0)$  a analizowanym punktem  $(x, y)$ . Po znalezieniu 16 punktów konturu region rozrasta się do wewnątrz według określonych reguł.


Do segmentacji mikrozwapnień stosowano także metodę aktywnych konturów [7], która minimalizuje energię, związaną z konturem. Energia wpływająca na kształt i położenie konturu jest sumą energii wewnętrznej i zewnętrznej. Energia wewnętrzna jest minimalna, gdy zachowany jest właściwy kształt obiektu z ograniczeniami wymuszającymi gładkość i regularność kształtu. Natomiast energia zewnętrzna osiąga minimum, gdy kontur jest we właściwym miejscu obiektu. Kontur jest przyciągany do obszarów obrazu o wysokich intensywnościach oraz do miejsc krawędzi w obrazie.

#### 2.3.3 Klasteryzacja

W zagadnieniu grupowania (klasteryzacji) skupisk (klastrów) mikrozwapnień pierwszorzędne znaczenie ma definicja skupiska mikrozwapnień. Autorzy przyjmują różne definicje mniej lub bardziej dokładne, np. co najmniej 3 albo 5 obiektów znajdujących się wewnątrz okna o wymiarach 1x1 cm [89], każdy klastery powinien zawierać co najmniej 3 obiekty w kwadracie 1x1  $cm^2$  (jądro klastra), a każde z mikrozwapnień przynależących do tego klastra powinno mieć co najmniej jednego sąsiada oddalonego najwyżej o  $\sqrt{2}$  cm [81]. Poważnym problemem z zastosowanie takich kryteriów klasteryzacji jest niekontrolowany rozrost powierzchni klastra, ponieważ mogą zostać do niego dołączone liczne artefakty i inne fałszywe obiekty (patrz rys. 2.18). W [154] zdefiniowano matematyczną definicję

klastra wyznaczającego grupę mikrozwapnień, z których każde 3 obiekty znajdują się w oknie o wymiarach 1x1 cm, a każde z mikrozwapnień posiada dwóch lub więcej sąsiadów w odległości nie większej niż  $\sqrt{2}$  cm. Podano także ograniczenie zabezpieczające przed nadmiernym rozrostem klastrów (klastr może składać się z co najwyżej 3 połączonych okien o wymiarach 1x1 cm).

Proste (standardowe) algorytmy klasteryzacji polegają na przesuwaniu po obrazie okna o wymiarach 1x1 cm w poszukiwaniu 3 lub 5 obiektów znajdujących się wewnątrz okna [89] (rys. 2.18).



Rysunek 2.18: Wynik standardowej klasteryzacji (okno przesuwane po obrazie). Pokazano odręcznie zaznaczone przez radiologa kontury dwóch skupisk mikrozwapnień (kolor zielony). Obraz źródłowy pochodzi z bazy DDSM [64].

W ocenie algorytmów detekcji i klasteryzacji mikrozwapnień definicja klastra, uznanego za prawdziwie pozytywny, jest kluczowa. W niektórych pracach za prawdziwie pozytywny klastr uznano klastry, które zawierają co najmniej 3 mikrozwapnienia, przynależące do referencyjnego regionu, zaznaczonego jako pozytywny klastr [89]. Szczegółowo opracowane kryterium określające prawdzi-

### 2.3. DETEKCJA POTENCJALNYCH MIKROZWAPNIENÍ

wie pozytywny klaster można znaleźć w [154, 81]. Klaster jest oceniany na podstawie zajmowanej powierzchni. Wykryty klaster uznaje się za prawdziwie pozytywny, jeśli zajmuje co najmniej 1 do 50% powierzchni prawdziwego klastra (figury wypukłej, zawierającej wszystkie mikrozwapnienia, przynależące do klastra) i jest nie większy niż 4-krotna powierzchnia prawdziwego klastra. Poza tym w klastrze powinny być co najmniej 3 mikrozwapnienia, leżące w kwadratowym oknie o boku 1 cm.

## 2.4 Ekstrakcja i selekcja cech

Detekcja i klasyfikacja zmian uwidocznionych na mammogramach bazuje na analizie informacji zawartej w obrazie. Dlatego też najpierw należy określić zbiór właściwości, charakteryzujących szukane zmiany i zakres wartości (cech), jakie poszczególne właściwości mogą przyjmować. Od strony wiedzy medycznej zagadnienie to jest przedstawione w p. 1.7.2. Kolejnym etapem jest zbudowanie modułu, dokonującego ekstrakcji tych cech z obrazu rentgenowskiego. Ważnym elementem jest także selekcja zbioru właściwości, szczególnie istotnych z punktu widzenia danego problemu. Zagadnienie selekcji właściwości występuje na etapie detekcji potencjalnych mikrozwapnień (bądź klastrów), albo na etapie diagnozy, czyli klasyfikacji na zmiany podejrzone (potencjalnie złośliwe) lub niepodejrzone (z dużą pewnością uznane za łagodne). Następnie stosuje się klasyfikator matematyczny do oszacowania złośliwości podejrzonej zmiany. Wielu lekarzy radiologów, interpretując badania mammograficzne, stosuje podobne systematyczne podejście [78].

Metody selekcji (redukcji) właściwości, dobrze reprezentujących obiekty wybranego typu i różnicujących je od pozostałych analizowanych obiektów, powinny uwzględniać wiedzę z danej dziedziny. Tutaj mogą to być właściwości obrazu, naśladujące sposób obserwacji zmian patologicznych i właściwości interpretowanych przez radiologów w mammografii. Ponadto istnieje wiele automatycznych algorytmów redukcji właściwości działających na zbiorze ich wartości, czyli cechach. Są to, np.: analiza składowych głównych (PCA), analiza dyskryminacyjna, metody bazujące na optymalizacji marginesu – *simba* (SIM) [54], metody porównywania efektywności klasyfikacji poprzez: dokładanie kolejnych właściwości – SFS (*sequential forward selection*) oraz wyrzucanie właściwości, niedających istotnej informacji z początkowego zestawu cech – SBS (*sequential backward selection*) [167].

### 2.4.1 Właściwości zaczerpnięte bezpośrednio z wiedzy medycznej oraz danych klinicznych

Najbardziej naturalnym przejściem od interpretacji badania mammograficznego, wykonanej przez samego radiologa, do systemu, wspomagającego ten proces diagnostyczny jest zbudowanie systemu, w którym etap identyfikacji zmiany i przypisania wartości właściwościom jest wykonany przez lekarza. Podejście to wykorzystuje bezpośrednio wiedzę lekarza. Niezbędne do tego jest stworzenie zbioru właściwości patologii, które są zrozumiałe i łatwe do oceny przez lekarza. Ważne jest także sporządzenie standardowego modelu opisu tych właściwości – nadawania im wartości (cech), aby program komputerowy mógł zinterpretować i zaklasyfikować opisy różnych lekarzy.

Próby standaryzacji opisu zmian w mammografii, podjęte w roku 1988, wskazały następujące właściwości zmian [52]:

- właściwości guzów:
  - rozmiar guza: projekcja CC,
  - rozmiar guza: projekcja MLO,

## 2.4. EKSTRAKCJA I SELEKCJA CECH

- kształt guza,
- gwiaździstość (spikularność) zmiany,
- stopień inwazyjności guza,
- pojedynczość guza,
- jednorodność tkanki miękkiej (poza guzem),
- właściwości zwapnień w skupiskach:
  - liczba zwapnień w skupisku,
  - rozmiar skupiska zwapnień: projekcja CC,
  - rozmiar skupiska zwapnień: projekcja MLO,
  - gładkość brzegu typowego zwapnienia w skupisku,
- dodatkowe oznaki raka:
  - oznaki zaburzenia architektury,
  - oznaki wciągnięcia skóry lub brodawki.

Rozwijając tę metodologię *American College of Radiology* zestandaryzował opis patologii piersi (BI-RADS) [2]. Baker i in. rozwinął tę technologię klasyfikacji, stosując właściwości z BI-RADS [5]. Użył do opisu patologii 18 właściwości:

- właściwości mikrozwapnień:
  - rozłożenie zwapnień (rozproszone, regionalne, segmentarne, liniowe, w skupisku),
  - liczba zwapnień (<5, 5-10, >10),
  - opis zwapnień (kształt),
- właściwości guzów:
  - zarys guza (dobrze odgraniczony, spikularny, itd.),
  - kształt guza (okrągły, owalny, policykliczny, nieregularny),
  - gęstość guza (zawierający tłuszcz, niskiej, średniej, dużej gęstości),
  - rozmiar guza (mm),
- inne:
  - położenie zmiany w piersi,
  - dodatkowe oznaki raka (zgrubienie skóry, wciągnięcie brodawki lub skóry, zaburzenie architektury),
  - szczególne przypadki (asymetria pomiędzy obydwoma piersiami),
- dane osobowe pacjentki i jej rodziny:
  - wiek (lata),

- osobista historia raka (był, nie był),
- czy była już biopsja ? (tak / nie),
- wywiad rodzinny (daleka, bliższa, najbliższa rodzina),
- czy pacjentka jest po okresie menopauzy? (tak / nie),
- hormonalna terapia zastępcza (tak / nie).

Każda z wyżej wymienionych cech otrzymała wartość z przedziału  $[0, 1]$ . Cechy charakterystyczne dla zmian złośliwych otrzymały wartości bliższe jedynki, np. właściwość – kształt guza ma wartości (cechy): nie ma – 0, okrągły – 0,25, owalny – 0,5, policykliczny – 0,75, nieregularny – 1. Dla tak uzyskanych cech można bezpośrednio zastosować klasyfikator matematyczny.

Jednak podejście, w którym etap identyfikacji zmiany i ekstrakcji cech wykonany jest całkowicie przez lekarzy, jest czasochłonne. W dodatku, pomimo ujednoczenia cech opisujących patologie, w dalszym ciągu wyniki komputerowej klasyfikacji są zależne od subiektywnej interpretacji mammogramów dokonywanej przez różnych radiologów (oceny potrafią różnić się w szerokich granicach [5]).

#### 2.4.2 Właściwości obrazu zmian patologicznych, wyznaczane automatycznie

<sup>2</sup> Poprzez automatyczną ekstrakcję cech cyfrowego obrazu mammograficznego oraz cech widocznych w nim zmian patologicznych, radiolog w momencie interpretacji zdjęcia rentgenowskiego ma dostępne wyniki komputerowej klasyfikacji. Omija go żmudny proces wprowadzania do programu wielu cech służących opisowi przypadku. Poza tym to zautomatyzowane podejście może eliminować subiektywizm diagnozy. Czasem program może wyodrębnić nawet takie właściwości, których ludzkie oko nie jest w stanie oszacować (np. odchylenie standardowe wartości poziomów jasności). Jednak to lekarz musi zdecydować, jak dalece można zaufać wynikom tej automatycznej analizy, gdyż on jest ostatecznym weryfikatorem i interpretatorem informacji obrazowej.

##### Właściwości guzów

Ogólnie właściwości, charakteryzujące różnego typu guzki, można podzielić na [96, 95]:

- właściwości geometryczne:
  - miary rozmiaru: powierzchni, najdłuższa średnica,
  - miara okrągłości,
  - „chropowatość” granicy/brzegu,
- właściwości intensywności (poziomów jasności):

---

<sup>2</sup>Większość metod opisu właściwości, podanych w tym punkcie, zostało zdefiniowanych w dokumentacji systemu *Mammo Viewer*, dostępnej w załączniku E.

## 2.4. EKSTRAKCJA I SELEKCJA CECH

- miary kontrastu,
- miary gradientu brzegu regionu,
- średnia, odchylenie standardowe i inne statystyki regionu,
- właściwości tekstury:
  - miara energii,
  - cechy macierzy zdarzeń: korelacja, moment bezwładności, entropia, odwrotny moment różnicowy itd.,
  - wymiar fraktalny powierzchni regionu,
- położenie.

Właściwości stosowane do klasyfikacji patologia-norma (brak patologii):

- powierzchnia regionu [95],
- miary kształtu:
  - zwartość [95, 103],
  - „chropowatość” kształtu krawędzi – odchylenie standardowe odległości pikseli, należących do konturu obiektu od jego centroidu [95],
- właściwości krawędziowe [120, 23], m.in. średnia siła (gradient) krawędzi (do obliczania gradientu użyto operatora Sobela) [95],
- statystyki poziomów jasności i tekstury regionu [103]:
  - kontrast – średnia różnica intensywności pomiędzy wysegmentowanym obiektem a jego sąsiedztwem [95],
  - „gładkość tekstury” – odchylenie standardowe poziomów jasności pikseli, należących do regionu [95],
  - cechy tekstury, liczone na podstawie macierzy zdarzeń,
  - cechy tekstury Law [120, 23],
- położenie.

Właściwości stosowane do klasyfikacji na guzki łagodne i złośliwe:

- powierzchnia regionu [95],
- właściwości kształtu:
  - zwartość [3],
  - względny stopień wklęsłości – stosunek sumy długości wklęsłych fragmentów konturu do długości konturu regionu [3, 135],
  - indeks spikularności, liczony na podstawie wielobocznego modelu, konturu [135],

- cechy tekstury, liczone na podstawie macierzy zdarzeń, m.in. liczone z najbliższego sąsiedztwa zmiany, tj. marginesu – „wstażki” okalającej region [3] (macierz liczona w 4 kierunkach, odległość  $d = 1$ ): entropia, energia, moment różnicowy, odwrotny moment różnicowy, korelacja,
- średnia siła krawędzi guza [107].

### Właściwości mikrozwapnień i ich skupisk

Właściwości charakteryzujące mikrozwapnienia można podzielić na cztery grupy [27]:

- Właściwości pojedynczych mikrozwapnień:
  - miary kształtu: powierzchnia, zwartość, momenty kształtu, momenty geometryczne [34],
  - inne miary morfologii, związane z wysyceniem mikrozwapnień: właściwości bazujące na analizie statystycznej histogramu rozkładu jasności (średni poziom jasności, odchylenie standardowe rozkładu jasności) oraz wyrazistość krawędzi, lokalny kontrast [14, 167].
- Statystyczne właściwości tekstury regionu sąsiedniego, zawierającego mikrozwapnienia, bazujące na analizie macierzy: powinowactwa (zdarzeń) GLCM 'Gray Level Co-occurrence Matrix', GLRLM 'Gray Level Run-Length Matrix', SRDM 'Surrounding Region-Dependence Matrix', GLDM 'Gray Level Difference' oraz właściwości energii tekstury Law, wymiar fraktalny [37, 82],
- Wielorozdzielcze właściwości tekstury: cechy falkowe, filtry Gabora [167],
- Właściwości klastrów mikrozwapnień: powierzchnia, liczba mikrozwapnień, średni poziom jasności mikrozwapnień w klastrze itp. [137, 14, 157].

Właściwości różnicujące normy od mikrozwapnień (za [7]):

- kontrast: różnica pomiędzy najwyższą wartością jasności pikseli, należących do obiektu i średnią jasności punktów konturu obiektu,
- względny kontrast: stosunek kontrastu (z poprzedniego punktu) do najwyższej wartości jasności w obiekcie,
- powierzchnia obiektu,
- ostrość krawędzi – średnia siła krawędzi, gradient punktów konturu (do obliczania gradientu zastosowano operator Sobela).

Właściwości różnicujące łagodne pojedyncze mikrozwapnienia od złośliwych (za [139, 140]):

- miary kształtu:

## 2.4. EKSTRAKCJA I SELEKCJA CECH

- zwartość,
- „chropowatość” – miara nieregularności granicy obiektu: odchylenie standardowe kwadratu odległości punktów konturu od centroidu obiektu,
- różnica trzeciego i pierwszego momentu centralnego kształtu,
- miara kształtu, obliczana na podstawie deskryptora fourierowskiego,
- siła gradientu granicy (wyrazistość krawędzi),
- lokalny kontrast – różnica średniej jasności obiektu i średniej jasności tła,
- cechy tekstury w sąsiedztwie analizowanego mikrozwapnienia:
  - energia obiektu (liczona w najmniejszym kwadracie zawierającym obiekt),
  - energia tła,
  - odchylenie standardowe jasności,
  - entropia,
  - energia, kontrast, entropia z macierzy zdarzeń.

Inny zestaw 10 właściwości podano w [167] – został on przetestowany w pracy, opis znajduje się w rozdziale 3.


Właściwości klastrów mikrozwapnień, różnicujące łagodne skupiska od złośliwych (opisane dość niejednoznacznie w [139]):

- masa klastra,
- średnia masa mikrozwapnień w klastrze,
- średnia odległość mikrozwapnień od centrum masy klastra,
- odchylenie standardowe mas mikrozwapnień,
- odchylenie standardowe odległości mikrozwapnień od centrum masy.

Inny zestaw właściwości różnicujący złośliwe skupiska od łagodnych [78, 97] dla mikrozwapnień odręcznie zaznaczonych przez radiologów, to:

- okrągłość skupiska (kształt): większość złośliwych skupisk ma kształt trójkąta lub innych figur kanciastych,
- powierzchnia skupiska: obwód skupiska jest wyznaczany za pomocą filtracji morfologicznej,
- liczba mikrozwapnień w skupisku,

- średnia efektywna objętość mikrozwapnień: efektywna grubość mikrozwapnienia to aproksymacja długości mikrozwapnienia wzdłuż linii projekcyjnej promieni rentgenowskich, czyli w płaszczyźnie prostopadłej do płaszczyzny mammogramu – szacowana z histogramu jasności mikrozwapnienia (np. największa wartość jasności) [79], efektywna objętość to iloczyn grubości i powierzchni,
- odchylenie standardowe efektywnej grubości mikrozwapnień w skupisku: mierzy niejednorodność w skupisku,
- odchylenie standardowe efektywnej objętości mikrozwapnień w skupisku: mierzy niejednorodność w skupisku,
- średnia powierzchnia mikrozwapnień w skupisku (mniejsze mają większe prawdopodobieństwo raka),
- druga najwyższa miara nieregularności kształtu mikrozwapnienia w skupisku: odchylenie standardowe 12 indeksów kształtu (rys. 2.19); Cztery indeksy reprezentują odległość pomiędzy centroidem i krawędziami najmniejszego prostokąta, zawierającego mikrozwapnienie. Następnymi osiem indeksów to długość linii z centroidu zmiany do brzegów obiektu w ośmiu kierunkach (0, 45, 90, 135, 180, 225, 270, 315 stopni).



Rysunek 2.19: Indeksy kształtu dla pojedynczego mikrozwapnienia. (a) Cztery indeksy kształtu reprezentują odległość pomiędzy centroidem i krawędziami najmniejszego prostokąta, zawierającego mikrozwapnienie. (b) Osiem indeksów kształtu reprezentuje długość linii z centroidu do brzegów obiektu w ośmiu kierunkach.

## 2.5 Klasyfikatory

Celem klasyfikacji obiektów jest stwierdzenie na podstawie zestawu cech, do jakiej klasy należy badany obiekt. Zestaw cech może być zbiorem wybranych cech obliczonych dla każdego wysegmentowanego obiektu lub danymi pikselowymi z podobrazów, czyli fragmentami obrazu. Klasy przynależności może być tutaj klasą zmian patologicznych (guzów, mikrozwapnień, klastrów mikrozwapnień) albo prawidłowych tkanek lub też klasą zmian łagodnych albo złośliwych.

Klasyfikatory stosowane do zagadnienia klasyfikacji zmian patologicznych w mammografii to, m.in.:

- metoda  $k$  najbliższych sąsiadów ( $k - NN$ ) [140] – wyznaczanie przynależności do klasy na podstawie analizy przynależności  $k$  najbliższych sąsiadów,
- binarne drzewo decyzyjne [149] – hierarchia reguł umożliwiających stopniowe eliminowanie przypadków, co do których nie ma wątpliwości, aby ostatecznie wyznaczyć przynależność do odpowiedniej klasy; reguły tworzone są na podstawie istotnych cech oraz odpowiednio dobranych wartości progowych,
- rozmyte binarne drzewo decyzyjne [95, 27] – hierarchia reguł, wyznaczających przynależność do klas z zastosowaniem rozmytej funkcji prawdopodobieństwa w każdym węźle drzewa (jednej regule),
- sieci neuronowe jednokierunkowe trójwarstwowe SNN [167, 86, 79, 5],
- sieci neuronowe o radialnej funkcji bazowej [29],
- maszyna wektorów nośnych i jej modyfikacje [1, 12, 43].

### 2.5.1 Sieci neuronowe jednokierunkowe trójwarstwowe

#### Struktura i przepływ sygnału


Wektor cech jest sygnałem wejściowym sieci  $x = [1, F_1, F_2, \dots, F_n]$  (rys. 2.20). Wszystkie te cechy są znormalizowane przez średnie próbkowe i odchylenia standardowe zbioru trenującego:

$$F_j = \frac{F_j^{wej} - m_j}{\sigma_j} \quad (2.37)$$

gdzie  $j = 1, \dots, n$ , a  $n$  – jest liczbą wejść sieci, czyli cech podawanych na wejście,

$$m_j = \frac{1}{P} \sum_{i=1}^P F_i^{wej}, \sigma_j = \sqrt{\frac{1}{P} \sum_{i=1}^P (F_i^{wej} - m_i)^2} \quad (2.38)$$

gdzie  $P$  jest liczbą wzorców zbioru uczącego, a  $F_i^{wej}$  są cechami przed normalizacją. Warstwa ukryta neuronów pośredniczy w przekazywaniu sygnałów między węzłami wejściowymi a warstwą wyjściową. Sygnały wejściowe są podawane



Rysunek 2.20: Struktura sieci neuronowej trójwarstwowej jednokierunkowej.

na warstwę ukrytą neuronów, a te z kolei stanowią sygnały źródłowe dla warstwy wyjściowej. Wyjście sieci daje odpowiedź, czyli określa przynależność do klasy wektora wejściowego.

Funkcja aktywacji neuronu jest funkcją sigmoidalną, np.

$$f(x) = \frac{1}{1 + \exp(-ax)} \quad (2.39)$$

dla  $a > 0$ . Sygnał wejściowy  $j$ -tego neuronu w warstwie  $k$ -tej to:

$$e_j^k = \sum_{i=1}^N w_{ij}^k o_i^{k-1} + w_{0j}^k = \sum_{i=0}^N w_{ij}^k o_i^{k-1} \quad (2.40)$$

dla  $k = 1, 2$  (odpowiednio warstwa ukryta i wyjściowa), ponadto  $o_0^k = 1$  dla  $k = 0, 1$  (0 - warstwa wejściowa) i  $o_l^0 = F_l$  dla  $l = 1, \dots, n$ ,  $o_i^{k-1}$  - wyjście  $i$ -tego neuronu w  $(k-1)$  warstwie,  $N$  - liczba neuronów w  $(k-1)$  warstwie (bez neuronu z pobudzeniem jednostkowym),  $w_{ij}^k$  - waga połączenia  $i$ -tego neuronu w  $(k-1)$  warstwie z  $j$ -tym w  $k$ -tej warstwie;  $w_{0j}^k$  - próg  $j$ -tego neuronu z  $k$ -tej warstwy (sygnał wyjściowy neuronu z  $(k-1)$  warstwy z pobudzeniem jednostkowym). Wyjście  $j$ -tego neuronu w warstwie  $k$ -tej, to:

$$o_j^k = f(e_j^k) \quad (2.41)$$

dla  $k = 1, 2$ .

### Algorytmy uczenia

Celem uczenia sieci jest określenie wartości wag połączeń między neuronami wszystkich warstw sieci w taki sposób, aby przy zadanym wektorze wejściowym uzyskać na wyjściu sieci wartości sygnałów wyjściowych, równające się z dostateczną dokładnością wartościom żądanym [112]. Do podstawowych metod uczenia sieci jednokierunkowych wielowarstwowych należą algorytm propagacji wstecznej błędu oraz inne metody minimalizacji funkcji celu – algorytmy gradientowe optymalizacji, m.in.: algorytm największego spadku, wykorzystujący informację o gradiencie funkcji celu, algorytm zmiennej metryki (informacja o gradiencie i hesjanie, czyli krzywiznie funkcji celu), metoda regularyzacyjna Levenberga-Marquardta (użycie aproksymowanej wartości hesjanu), czy metoda gradientów sprzężonych (wymusza kierunek poszukiwań, wyznaczany na podstawie gradientu, ortogonalny do kierunków z poprzednich iteracji) [112].

#### 2.5.2 Sieć neuronowa o radialnej funkcji bazowej

W [29] zastosowano trójwarstwową sieć neuronową o radialnej funkcji bazowej do klasyfikacji podobrazów mammogramu w celu lokalizacji regionów, zawierających guzy. Na wejście sieci są podawane 4 cechy histogramu podobrazu: średnia, wariancja, skośność, kurtoza.

W sieci o radialnej funkcji bazowej neurony ukryte realizują funkcję zmieniającą się radialnie wokół wybranych centrów  $c^{(j)}$ . Postać ogólna funkcji radialnych to:

$$\phi_j(\|x - c^{(j)}\|) \quad (2.42)$$

gdzie  $x$  to wektor wejściowy (tutaj 4 wejściowe cechy).

Wyjście neuronów ukrytych, to:

$$R_j = \frac{1}{1 + \sum_{i=1}^n (c_i^{(j)} - f_i)^2} \quad (2.43)$$

gdzie  $j = 1, \dots, K$  – numer neuronu ukrytego,  $c^{(j)}$  – centrum  $j$ -tego neuronu radialnego,  $f_i$  – sygnał wejściowy w węźle wejściowym  $i$ ,  $n$  – liczba wejść sieci (tutaj  $n = 4$ ).

Wyjście sieci stanowią dwa neurony, oznaczające obecność patologii lub jej brak. Warstwa wyjściowa realizuje liniową filtrację wyjść warstwy ukrytej:


$$o_k = w_{k0} + \sum_{j=1}^K w_{kj} R_j \quad (2.44)$$

gdzie  $k$  – numer neuronu wyjściowego,  $w_{k0}$  – wymuszenie podawane na neuron,  $w_{kj}$  – waga połączenia między węzłem  $k$ -tym warstwy ukrytej a neuronem  $j$ -tym warstwy wyjściowej.

W fazie uczenia do określania wag warstwy ukrytej sieci radialnej stosuje się np. algorytm samoorganizujący K-średni, a do wag warstwy wyjściowej jeden z algorytmów, stosowanych przy nauce sieci jednokierunkowych wielowarstwowych, np. algorytm propagacji wstecznej [112].

### 2.5.3 Maszyny wektorów nośnych

Podstawą metody wektorów nośnych SVM (*Support Vector Machine*) jest koncepcja przestrzeni decyzyjnej, która dzieli się, tworząc granicę separującą obiekty o różnej przynależności klasowej. Optymalną hiperpłaszczyznę separującą określa się w iteracyjnym algorytmie uczącym, który minimalizuje dobraną funkcję błędu. Celem uczenia jest maksymalizacja marginesu separacji klas przy jednoczesnej minimalizacji przekroczeń granic tego marginesu (rys. 2.21). Klasyfikator ten jest szczególnie przydatny, gdy dane nie są separowalne – przenikają się.



Rysunek 2.21: Separacja dwóch klas przy pomocy maszyny wektorów nośnych: prosta separująca (linia ciągła) i margines błędu (linia przerywana). Wektory nośne to próbki, znajdujące się wewnątrz marginesu błędu.

Podczas uczenia modelu jest minimalizowana funkcja błędu:

$$\Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad (2.45)$$

podlegająca następującym ograniczeniom:

$$y_i(w^T \psi(x_i) + b) \geq 1 - \xi_i \quad (2.46)$$

gdzie  $\xi_i$  – parametry obsługujące przypadki nakładające się,  $\xi_i \geq 0$ ,  $i = 1, 2, \dots, l$ ,  $w$  – wektor współczynników,  $x_i$  – wektor danych wejściowych,  $y_i$  – etykiety klas separowanych,  $y_i \in \{-1, +1\}$ ,  $\psi(x_i)$  – funkcja przekształcająca dane wejściowe do nowej przestrzeni cech,  $b, C$  – stałe.

Główną rolę w przekształceniu danych wejściowych do nowej przestrzeni w metodzie wektorów nośnych pełni funkcja jądra, np. funkcje wielomianowe, radialna funkcja bazowa RBF, funkcja falkowa.

## Rozdział 3

---

# System wspomagania diagnostyki mammograficznej – MammoViewer

---

W rozdziale zaprezentowano własną koncepcję systemu wspomagania obrazowej diagnostyki mammograficznej. Na podstawie analizy literaturowej, a także licznych własnych opracowań cząstkowych (algorytmy, implementacje) i eksperymentów, wybrano metody najbardziej obiecujące. Dokonano ich modyfikacji w celu poprawy efektywności, dodano własne pomysły i udoskonalenia, zaczynając od poziomu drobnych algorytmów, a kończąc na własnej koncepcji zintegrowanego wspomagania. Zbudowano narzędzie *MammoViewer* o zastosowaniu szerszym niż mammografia (także do analizy badań USG, tomografii komputerowej oraz podstawowych operacji na obrazach).

Na początku prac badawczych skupiono się przede wszystkim na metodach detekcji i segmentacji mikrozwapnień. Kolejnym obszarem prac były metody grupowania mikrozwapnień. Podjęto także próby analizy i klasyfikacji cech obrazowych: zaimplementowano szereg numerycznych metod opisu właściwości pojedynczych obiektów oraz ich grup – klastrów. Dalej, we współpracy z radiologami, rozbudowano narzędzia analizy wielorozdzielczej, służące przede wszystkim do tworzenia metod poprawy percepcji zmian patologicznych. Niezbędna przy tym okazała się optymalizacja metod segmentacji regionu tkanki piersi. Następnie, przygotowując się do testów klinicznych na większej liczbie przypadków (opisanych w rozdziale 4), rozbudowano interfejs, skierowany do ostatecznego użytkownika systemu – specjalisty radiologa, zawierając w nim wiele narzędzi doboru prezentacji obrazu medycznego. Powyższe metody są opisane w kolejności bloków narzędziowych, przyjętych w systemach detekcji i diagnozy zmian patologicznych.

Ponadto, wykorzystując system *MammoViewer*, prowadzono inne prace badawcze, krótko opisane w p. 3.8. Wynikiem przeprowadzonych badań i wykonanych implementacji jest koncepcja zintegrowanej stacji diagnostycznej, wykorzystująca *MammoViewer* jako moduł opisu właściwości zmian w bazie obrazów mammograficznych, indeksowanych zawartością oraz współpracę z systemem ontologii mammografii. Została ona zarysowana także w ostatnim paragrafie rozdziału.

\* \* \*

*MammoViewer* jest narzędziem, służącym wspomaganie diagnostyki obrazowej poprzez wykorzystanie efektywnych metod: prezentacji, przetwarzania, analizy i interpretacji obrazów [163, 164, 131, 130]. Początkowo przeznaczony do zastosowań mammografii rentgenowskiej, *MammoViewer* okazał się użyteczny także w obróbce obrazów medycznych innych modalności. Był implementowany w warunkach klinicznych, w Szpitalu Wolskim w Warszawie, testowany przez kilkunastu radiologów z 4 ośrodków medycznych, a kolejne jego wersje są dostępne w Internecie: <http://www.ire.pw.edu.pl/MammoViewer>.


Procedury dostępne w systemie wykorzystano: do poprawy percepcji zmian patologicznych w mammografii [161, 10, 11, 162, 129, 119, 158], w badaniach tomografii komputerowej mózgu [8] oraz obrazów USG [9, 10], detekcji guzków [20], mikrozwapnień [160, 166, 165, 161], zaburzeń architektury [76] w mammografii oraz klasyfikacji mikrozwapnień [160, 19, 159]. Ponadto *MammoViewer* został wykorzystany w module indeksowania bazy obrazów mammograficznych [17]. Są prowadzone badania współpracy z systemem ontologii mammografii [118, 119]. Testy kliniczne wykonano w celu oceny skuteczności detekcji mikrozwapnień oraz poprawy percepcji guzków i mikrozwapnień w mammogramach [158]. Schemat funkcjonalny systemu z dziedzinami, w których znalazł zastosowanie, jest przedstawiony na rysunku 3.1.

System *MammoViewer* jest cały czas rozwijany, są dodawane kolejne opcje, algorytmy. Zaprojektowany został jako system o otwartej architekturze z możliwością dołączania nowych procedur przetwarzania obrazów przez różne grupy badawcze. Szczegółowy opis strukturalny systemu, z opisem opcji dostępnych w menu oraz struktura oprogramowania znajdują się w jego dokumentacji załączonej do rozprawy (załącznik E).

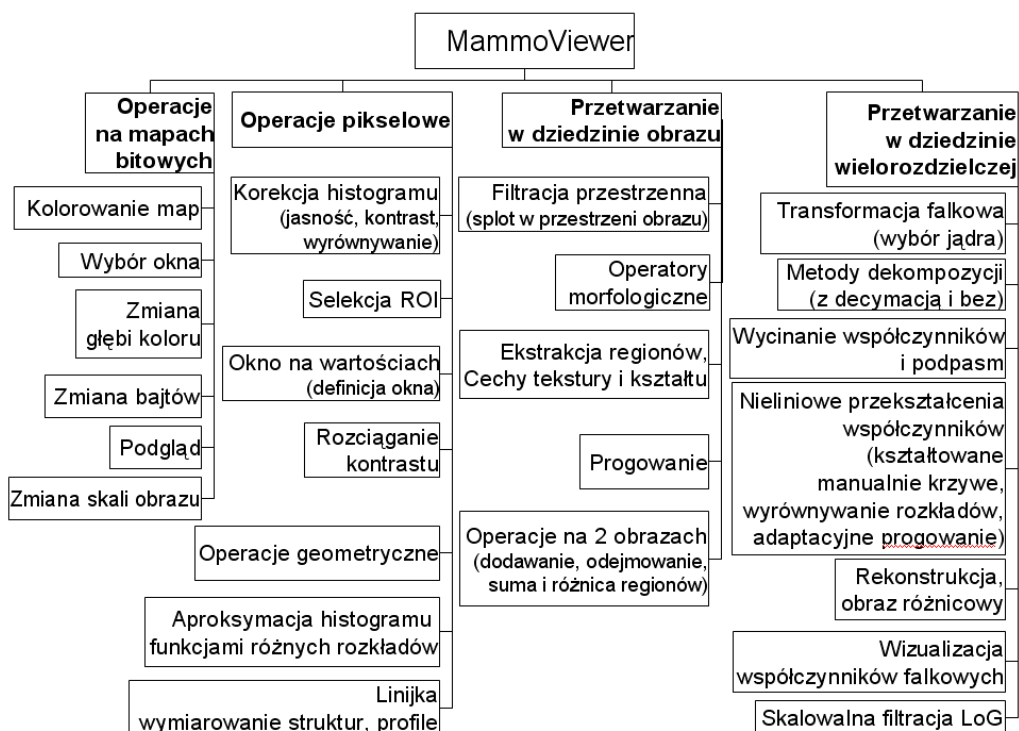
### 3.1 Opis narzędziowy systemu

*MammoViewer* zawiera różnorodne metody i algorytmy, służące wsparciu procesu interpretacji badań obrazowych. Pod względem strukturalnym można podzielić je na następujące grupy: operacje na mapach bitowych, operacje pikselowe (punktowe, kontekstowe), przetwarzanie w dziedzinie obrazu i w dziedzinie wielorozdzielczej (rys. 3.2).

### 3.1. OPIS NARZĘDZIOWY SYSTEMU



Rysunek 3.1: Schemat funkcjonalny systemu *MammoViewer* – obszary zastosowań systemu *MammoViewer*.



Rysunek 3.2: Schemat strukturalny systemu *MammoViewer* – narzędzia dostępne w systemie.

### 3.1.1 Proste operacje na obrazach

#### Interfejs wejścia/wyjścia

Program umożliwia otwieranie i zapis obrazów ze skalą szarości, obsługuje standardowe formaty graficzne z: 1-, 4-, 8-bitową głębią kolorów (BMP, GIF, TIFF, JPG, PNG, PGM) oraz formaty 2-bajtowe (obrazy z 10-, 12-, 14- i 16-bitową głębią kolorów) PGX, DCM oraz RAW. Sukcesywnie są dołączane inne formaty danych, użyteczne w różnych systemach obrazowania medycznego.

Ponadto możliwe jest dodawanie i wyświetlanie opisu tekstowego obrazu oraz oznaczanie regionów zainteresowań na obrazie (dodatkowe pliki tekstowe).

#### Prezentacja obrazów i standardowe operacje

Przy otwieraniu pliku danych obrazowych są dostępne: podgląd, zmniejszanie, zwiększanie i dopasowanie do wymiarów okna wyświetlanego obrazu oraz jego parametry (szerokość, wysokość, rozdzielczość przestrzenna) i opis tekstowy.

Pracę z obrazami o dużych wymiarach (np. mammogramami o 20 Mpikselach) znacznie ułatwia okienko (*'thumbnail'*), w którym można określić część obrazu, aktualnie widoczną w dużym oknie (rys. 3.5).

Zaimplementowano standardowe opcje: doboru kontrastu, jasności, prezentacji i korekcji histogramu, obrotów, zamiany bajtów, zmiany głębi koloru, kolorowanie map obrazu, itd.

Możliwe jest także definiowanie parametrów okna przesuwnego, określającego zakres wyświetlanych bitów (z maksymalną szerokością okna równą 8 bitów) albo okna z zakresem widocznych wartości pikseli (ustawianie profilów). Ma to szczególne zastosowanie w przypadku danych 2-bajtowych.


Ponadto są dostępne: linijka (wymiarowanie struktur i wizualizacja poziomów jasności wzdłuż linijki – profile), także operacje na regionach zainteresowań oraz aproksymacja histogramu funkcjami różnych rozkładów.

### 3.1.2 Przetwarzanie i analiza w dziedzinie obrazu

Są dostępne następujące funkcje: operacje geometryczne (obroty, lustrzane odbicia obrazu), progowanie (binaryzacja) obrazu, filtracja przestrzenna (metodą splotu w przestrzeni obrazu, z bogatą możliwością doboru ustalonych postaci filtrów oraz definiowaniem własnych), filtracja operatorami morfologicznymi (z możliwością interakcyjnego definiowania elementu strukturującego i określania liczby iteracji dla filtracji, z całym zakresem typowych oraz przydatnych w analizie obrazów medycznych operatorów – rys. 2.4 i 2.5), operacje na dwóch obrazach (dodawanie, odejmowanie, iloczyn i różnica regionów na obrazach binarnych itp.), ekstrakcja regionów (obiektów) z obrazu binarnego (po segmentacji), poprawianie kształtów wyekstrahowanych obiektów technikami rozrostu regionów oraz obliczanie cech z zastosowaniem szeregu numerycznych metod opisu właściwości kształtu i tekstury regionów oraz ich sąsiedztwa. Zaimplementowano także skalarne miary jakości obrazu do porównywania stopnia intensywności wprowadzanych zmian (maksymalna różnica, błąd średniokwadratowy, szczytowy

### 3.1. OPIS NARZĘDZIOWY SYSTEMU

stosunek sygnału do szumu, szczytowy błąd średniokwadratowy, znormalizowany błąd średniokwadratowy, dokładność rekonstrukcji obrazu, miara chi-kwadrat) oraz miara dokładności diagnostycznej obrazu HVM ('*Hybrid Vector Measure*')<sup>1</sup> [125]. Procedury te mogą być zastosowane do podstawowych operacji na obrazach w różnych formatach graficznych, w szczególności medycznych: do uwydatniania różnego typu zmian patologicznych, detekcji i klasyfikacji zdefiniowanych obiektów oraz do porównywania skutków przetwarzania (rys. 3.3).



Rysunek 3.3: Przetwarzanie w dziedzinie obrazu w celu uwydatnienia guza: (a) oryginalny region, zawierający guza oraz dwa profile wzdłuż zaznaczonych na obrazie linijek i histogram regionu, zawierającego guz, (b) obraz po wyrównywaniu histogramu, (c) obraz po lokalnej binaryzacji histogramu. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

#### 3.1.3 Wielorozdzielcza analiza obrazów

W [147, 130] pokazano, że: opis, modelowanie, przetwarzanie i analiza informacji obrazowej w wielu skalach, z podziałem na podpasma częstotliwościowe, zachowujące orientację przestrzenną oraz kierunkową pozwala efektywnie wspomagać diagnostykę obrazową.

Bazując na kodzie *Wavelet Image Compression Construction Kit* [32] oraz implementacji filtrów z [124] w *MammoViewerze* opracowano wygodne narzędzia (rys. 3.4) do kształtowania informacji obrazowej w dziedzinie falkowej:

<sup>1</sup>Procedura oryginalnie napisana przez A. Przelaskowskiego została dołączona do systemu.

- metody liczenia transformacji falkowej z wyborem:
  - filtrów – jąder transformaty (ortogonalne z liniową i nieliniową fazą, biortogonalne, zróżnicowane rozmiary nośników filtrów od 2 do 30, różny poziom gładkości funkcji bazowych),
  - metody dekompozycji (z decymacją lub bez decymacji – współczynniki falkowe dla każdego podpasma pokrywają całą przestrzeń obrazu),
  - liczby poziomów dekompozycji (skal),
- procedury progowania i przekształceń współczynników transformaty falkowej:
  - dobór podpasm i operacji, wykonywanych na ich współczynnikach,
  - wycinanie (zerowanie) współczynników lub całych podpasm,
  - adaptacyjne progowanie w podpasmach z wyborem funkcji progowania (m.in. twarde, miękkie),
  - kształtowane manualnie nieliniowe krzywe przekształceń,
  - automatyczny dobór progu lub parametrów krzywych w zależności m.in. od odchylenia standardowego z wybranego podpasma lub z podpasma HH na danym poziomie,
  - korekcja (w tym wyrównywanie) rozkładu współczynników w podpasmach,
- rekonstrukcję oraz wizualizację obrazu różnicowego,
- wizualizację rozkładu współczynników falkowych z przeskalowaniem do pełnego zakresu wartości (rys. 2.6 i 2.11),
- skalowalną filtrację Laplacian-of-Gaussian z tworzeniem ścieżek lokalnych maksimów dla obrazów po filtracji LoG w wielu skalach (rys. 3.5).

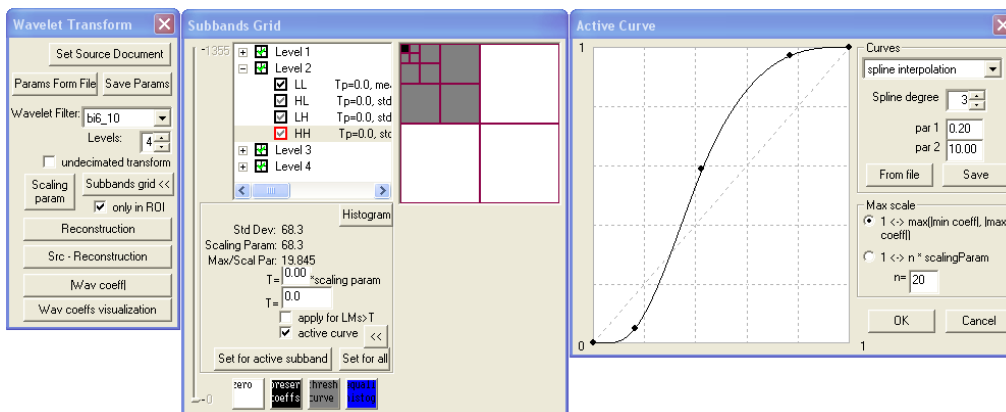
Wykorzystanie przekształceń wielorozdzielczych w analizie mammogramów w większości ma charakter nowatorski, z dostosowaniem parametrów przekształceń do konkretnych zastosowań.

Stworzony system *MammoViewer* służy przede wszystkim do: analizowania, rozwijania i testowania metod, dotyczących poprawy percepcji zmian patologicznych różnych modalności, algorytmów poszczególnych faz detekcji i klasyfikacji mikrozwapnień (rys. 1.2 i 1.3) oraz sposobów połączenia i wzajemnego wpływu rezultatów poszczególnych bloków funkcjonalnych (przykład na rys. 3.6).

### 3.2 Dobór warunków prezentacji – interfejs dla radiologa


MammoViewer może być używany jako program graficzny. Jednakże jest zaprojektowany szczególnie do wizualizacji obrazów medycznych (rys. 3.7 i 3.8). Posiada interfejs, dostosowany do interpretacji badań mamograficznych (rys. 3.9): wizualizacja obrazów obydwu piersi (mammografia jest badaniem porównawczym),

### 3.2. DOBÓR WARUNKÓW PREZENTACJI – INTERFEJS DLA RADIOLOGA




Rysunek 3.4: Interfejs oprogramowania *MammoViewer* do kształtowania informacji obrazowej w dziedzinie falkowej: wybór jądra transformacji, liczby poziomów dekompozycji, przekształceń, które zostaną zastosowane do wybranych podpasem (progowanie, nieliniowe krzywe przekształceń, wyrównywanie histogramu).

możliwość automatycznego przetrzucania projekcji CC i MLO, możliwość wizualizacji 4 obrazów na jednym ekranie, możliwość zmiany zakresu widzianych wartości (okna) za pomocą zdefiniowanych profili (dodawanie nowych profili) lub płynnej regulacji, możliwość powiększania fragmentów obrazów, wskazania automatyczne potencjalnych klastrów mikrozwapnień itp.




Rysunek 3.5: Wielorozdzielczy detektor plamek – użycie skalowalnych filtrów LoG do wykrywania potencjalnych mikrozwapnień (białe plamki wskazań). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)


### 3.2. DOBÓR WARUNKÓW PREZENTACJI – INTERFEJS DLA RADIOLOGA



Rysunek 3.6: Przetwarzanie w celu poprawy efektywności detekcji: (a) oryginalny region z mikrozwapnieniami i poniżej detekcja potencjalnych mikrozwapnień na tym oryginale (białe plamki wskazań), (b) przetworzony obraz (operatory morfologiczne) i na nim poniżej detekcja potencjalnych mikrozwapnień (białe plamki wskazań). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)



Rysunek 3.7: Wizualizacja badania tomografii komputerowej mózgu. (Źródłowy obraz CT pochodzi z własnej, eksperymentalnej bazy.)



Rysunek 3.8: Wizualizacja mikrozwapnień: dobór okna – zakresu widzianych wartości. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

### 3.2. DOBÓR WARUNKÓW PREZENTACJI – INTERFEJS DLA RADIOLOGA



Rysunek 3.9: *MammoViewer* – interfejs dla radiologa, dostosowany do interpretacji cyfrowych badań mammograficznych. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

### 3.3 Metoda poprawy percepcji guzów i mikrozwapnień

Wykorzystując selektywność reprezentacji w wielu skalach, *Mammo Viewer* – poprzez prezentację rozkładu wartości współczynników falkowych – pozwala lepiej zlokalizować patologie, dobrać parametry algorytmu progowania bądź uwydatniania np. małych współczynników. Modyfikacja współczynników w dziedzinie transformacji falkowej skutkuje (po rekonstrukcji) poprawą percepcji uwydatnionego sygnału użytecznego – guzów i mikrozwapnień.

Procedura doboru parametrów przetwarzania w dziedzinie falkowej przebiegała w kilku etapach eksperymentalnych. W pierwszym etapie eksperymentowano na małych regionach, zawierających patologie [162]. Kolejnym etapem były testy porównawcze obrazów oryginalnych patologii w kontekście całej piersi (całe obrazy mammograficzne) [158, 119]. Ostatnim etapem były testy detekcji, przeprowadzone przy pomocy trzech radiologów, opisane w rozdziale 4.

#### 3.3.1 Optymalizowane parametry przetwarzania w dziedzinie falkowej

Metoda wymaga wyboru następujących parametrów przetwarzania:

- falki – jąder transformaty (ortogonalne z liniową i nieliniową fazą, biortogonalne, zróżnicowane nośniki filtrów od 2 do 30 współczynników, różny poziom gładkości funkcji bazowych),
- typu transformacji (z decymacją lub bez decymacji),
- liczby poziomów dekompozycji (1–10),
- rodzaju przekształcenia współczynników:
  - wycinanie (zerowanie) lub osłabianie współczynników: wycinanie całych podpasm, typ progowania (twarde, miękkie, nieliniowe krzywe przekształcenia), automatyczny dobór progu, typ zależności wybranego progu od współczynników transformaty, rodzaj filtracji wygładzającej (filtry uśredniające, medianowe),
  - wzmacnianie współczynników: dobór podpasm do wzmacniania, dobór zakresu wzmacniania współczynników i automatycznej zależności wzmacniania w różnych podpasmach, nieliniowe krzywe przekształcenia, wyrównywanie histogramu, typ filtracji wyostrzającej.

#### 3.3.2 Cel eksperymentów

Wynikiem wstępnego przetwarzania mammogramów ma być poprawa percepcji (uwydatnienie) guzków i mikrozwapnień:

- odszumienie – usunięcie lub redukcja (stłumienie) szumów, ograniczających jakość diagnostyczną obrazów,

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ

- poprawa lokalnego kontrastu – wzmocnienie konturów zmian oraz podkreślenie innych cech zmian patologicznych (tekstury wewnątrz patologii, spikule w guzach).

Należy tutaj zauważyć, że parametry były optymalizowane tak, aby obraz był „przyjazny” dla oka radiologa. Kryterium, jakie stosowano, to opinie ekspertów, eksperymentalnie weryfikowane wrażenie percepcji wszystkich istotnych treści diagnostycznych. Ponieważ badania mammograficzne są obrazami bardzo dużymi, lekarze nie akceptowali dużych zmian obrazu, które prowadziły do całkowitej zmiany ogólnego odbioru obrazu, np. niedozwolone było usuwanie rozległych obszarów prawidłowej tkanki, które nie mają szczególnego wpływu na interpretację wybranych zmian patologicznych.

#### 3.3.3 Wstępne testy doboru parametrów

##### Kryteria oceny poprawy percepcji w pierwszej fazie testów

Miarą poprawy percepcji zmian były:

1. obiektywne obliczeniowe miary lokalnego kontrastu oraz skalarne miary do analiz porównawczych,
2. subiektywna ocena poprawy percepcji (szum – kontrast) – subiektywne kryterium postrzegania informacji obrazowej przez inżynierów - specjalistów w dziedzinie przetwarzania obrazów (byli oni poinformowani o typie i lokalizacji patologii),
3. subiektywna ocena lekarza radiologa w kategoriach diagnostycznych.

**Ad. 1)** Zastosowano następujące estymatory lokalnego kontrastu:

- Skontrastowanie (DR), dane wzorem 2.17, gdzie do obliczenia tła obiektu jest dobrany najmniejszy prostokąt, zawierający obiekt, którego powierzchnia tła jest 2 razy większa niż powierzchnia obiektu.
- Wyrazistość (siła) krawędzi (ESM): Średnia wartości gradientów w punktach konturu obiektu. Wektor gradientu wskazuje kierunek największej zmiany jasności obrazu. Wartość tego wektora dla danego punktu obrazu jest proporcjonalna do różnic jasności, występujących w otoczeniu tego punktu. Gradient został obliczony przy użyciu filtru gradientowego Prewitta.

Dodatkowo zastosowano miary skalarne do analiz porównawczych (opisujące stopień wprowadzanych w obrazie zmian):

- błąd średniokwadratowy (MSE), dany wzorem 2.11,
- średnia różnica (AD), dana wzorem 2.13

**Ad. 2)** Inżynierowie porównywali wyniki kolejnych metod za pomocą prostego kryterium: lepszy – gorszy kontrast, była to ogólna ocena postrzegania zmian, określonych ich cech.

**Ad. 3)** Radiolog porównywał obrazy oryginalne (regiony zawierające patologie) z przetworzonymi, oceniał jakość widzianych zmian patologicznych. Do przeprowadzenia testu wykorzystano subiektywną porównawczą (względna) skalę ocen od -3 (zdecydowanie gorzej) do +3 (zdecydowanie lepiej) (tab. 2.1).

### Realizacja eksperymentu

We wstępnych przygotowawczych testach doboru parametrów kierowano się obiektywnymi miarami kontrastu oraz subiektywną oceną inżynierów. Na początku eksperymentu wybrano pewne parametry początkowe, które wydawały się optymalne, a następnie dobierano jeden parametr, tak aby zachować konsensus pomiędzy najlepszymi wynikami miar skalarnych a wizualnym wrażeniem poprawy jakości obrazu. Potem w ten sam sposób dobierano kolejne parametry. Po zmianie wszystkich parametrów następowała kolejna ich modyfikacja.

Wstępną weryfikację efektywności zastosowanych metod przeprowadzono podczas subiektywnych testów z udziałem lekarza radiologa Specjalisty<sup>2</sup>, porównując uzyskane wyniki z praktyczną oceną przetwarzania. Testy zostały przeprowadzone na 19 obrazach mammograficznych (ucyfrowionych, z rozdzielczością 43,5 oraz 45,5 mikrometrów z 12-bitową głębią koloru), pochodzących z bazy [64]<sup>3</sup>. Podczas testów wybrano regiony zainteresowania, zawierające zmiany patologiczne: mikrozwapnienia, guzy dobrze odgraniczone oraz guzy spikularne. Lekarz oglądał fragmenty mammogramów na monitorze laptopa.

### Wyniki wstępnych testów doboru parametrów

Podczas wstępnych testów wybrano dwa zestawy parametrów:


- zestaw 1 – falka: biortogonalna 6/10; transformacja z decymacją; 4 poziomy dekompozycji; na 1. i 2. poziomie zastosowano nieliniowe usuwanie szumów (krzywa przekształcenia, widoczna na rys. 3.10a), na 3. i 4. poziomie zastosowano nieliniowe wzmacnianie współczynników (krzywa pokazana na rys. 3.10b).
- zestaw 2 – j.w., na 3. i 4. poziomie zastosowano nieliniowe tłumienie oraz wzmacnianie współczynników (krzywa pokazana na rys. 3.10c).

Jednakże należy zauważyć, że bardzo zbliżone efekty dawały te same przekształcenia z falkami *Taswell Biortogonal Symmetric Most-Regular* (10), *Villasenor* 18/10, *Coiflet* 22/14. Współczynniki filtrów podano w załączniku C.

<sup>2</sup>Opis lekarzy radiologów biorących udział w testach został zamieszczony w p. 4.4.3.

<sup>3</sup>Dokładniejszy opis bazy DDSM podano w p. 4.1.

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ



Rysunek 3.10: Krzywe przekształceń współczynników falkowych w wybranych podpasmach: (a) nieliniowe usuwanie szumów; punkty przegięcia krzywej na poziomie:  $2\sigma_{HH}$  (odchylenie standardowe podpasma  $HH$  na wybranym poziomie) i  $3\sigma_{HH}$ ; (b) wzmacnianie współczynników; (c) wzmacnianie współczynników z najmniejszymi niezmiennymi.

W tabeli 3.1 pokazano wyniki eksperymentów dla wybranych obrazów mikrozwapnień (pojedyncze mikrozwapnienia zostały zaznaczone automatycznie za pomocą systemu *Mammo Viewer*). Na obrazach została policzona średnia z wartości skontrastowania obiektu i tła ( $K$ ) oraz wyrazistości krawędzi ( $WK$ ) obiektów, należących do klastra mikrozwapnień, a następnie stosunek tych wartości na obrazie przetworzonym i oryginalnym (nazwano to indeksem poprawy). W tabeli podano nazwy obrazów z bazy [64] oraz subtelność zmian, tzn. ich widoczność w skali od 1 – najslabiej widoczne zmiany do 5 – najwyraźniejsze. Przykładowy obraz mikrozwapnień z zaznaczonymi konturami pojedynczych obiektów jest pokazany na rys. 3.11.

Wyniki wstępnych testów z udziałem lekarza radiologa Specjalisty zostały zamieszczone w tabelach: 3.2, 3.3, 3.4, 3.5 i 3.6. Przykładowe patologie – obrazy oryginalne i po przetwarzaniu są pokazane na rysunkach 3.12, 3.13 i 3.14.

#### Dyskusja i wnioski z testów wstępnych

We wstępnych testach doboru parametrów miary numeryczne potwierdzały subiektywną ocenę, wydawaną przez inżynierów, którzy jednakże zwracali szczególną uwagę na zmiany w obrębie samych patologii i w ich bezpośrednim sąsiedztwie, nie brali pod uwagę zmian struktury dalszych obszarów otaczającej tkanki. Stwierdzono zauważalną poprawę widoczności guzków (szczególnie spikul) i mikrozwapnień z zastosowaniem transformacji za pomocą obydwu zestawów parametrów. Zestaw 2. okazał się nieco lepszy.

Ogólnie zaobserwowano następujące reguły przetwarzania:

- lepsze są falki biortogonalne o średnim nośniku (rozmiar sprzężonych filtrów w granicach 6-14 współczynników) i poziomie gładkości,

ROZDZIAŁ 3. SYSTEM WSPOMAGANIA DIAGNOSTYKI MAMMOGRAFICZNEJ  
– MAMMOVIEWER

Obraz	Subtelność	Zestaw parametrów	MSE	AD	Indeks poprawy ESM	Indeks poprawy DR
1214 LCC	4	1	212,11	11,19	1,36	1,39
		2	250,77	10,40	1,56	1,60
1283 LMLO	1	1	269,28	12,92	1,31	1,39
		2	293,86	12,47	1,48	1,57
1201 RMLO	2	1	255,58	12,62	1,38	1,39
		2	250,89	11,63	1,57	1,59
1201 RCC	2	1	213,39	11,56	1,31	1,30
		2	212,67	10,82	1,43	1,42
1220 RCC	3	1	188,15	10,83	1,36	1,42
		2	168,08	9,64	1,49	1,56
1214 LMLO	4	1	183,00	10,48	1,40	1,41
		2	180,75	9,24	1,64	1,66

Tabela 3.1: Wyniki – miary obliczeniowe dla obrazów mikrozapnień.

Mikrozapnienia										
Obraz	1283 LCC	1283 LMLO	1201 RCC	1201 RMLO	1220 RCC	1220 RMLO	1257 LCC	1257 LMLO	1212 LCC	
Subtelność	1	1	2	2	2	3	1	1	5	
Zestaw parametrów	1	+1	+1	+2	+2	+1	+1	+1	+2	+1
	2	+2	+2	+2	+2	+2	+1	+1	+2	+3

Tabela 3.2: Wyniki testu subiektywnego dla obrazów mikrozapnień – ocena radiologa.


Guzy spikularne								
Obraz	3047 LCC	3047 LMLO	3006 LCC	3006 LMLO	3023 LCC	3023 LMLO		
Subtelność	3	2	3	3	2	3		
Ocena radiologa	Zestaw parametrów	1	+1	-1	+3	+2	+1	+2
		2	+2	+2	+3	+3	+2	+3

Tabela 3.3: Wyniki testu subiektywnego dla obrazów guzów spikularnych – ocena radiologa.

Guzy dobrze odgraniczone						
Obraz	0212 LCC	0025 RCC.ROI1	0025 RCC.ROI2	0025 LMLO		
Subtelność	5	5	5	5		
Ocena radiologa	Zestaw parametrów	1	0	+1	+1	+2
		2	0	+2	+2	+3

Tabela 3.4: Wyniki testu subiektywnego dla obrazów guzów dobrze odgraniczonych – ocena radiologa.

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ




Rysunek 3.11: Region zawierający mikrozwapnienia – Obraz z bazy DDSM: 1283 LMLO. Na górze: oryginalny obraz i obok zaznaczone automatycznie kontury mikrozwapnień. Na dole: obraz przetworzony za pomocą dwóch zestawów parametrów: Zestaw 1 i Zestaw 2. (Rysunek wykonany w systemie *MammoViewer*.)

Średnia ocena radiologa		Ogólnie	Mikrozwapnienia	Guzy spikularne	Guzy dobrze odgraniczone
Zestaw parametrów	1	+1,26	+1,34	+1,34	+1,00
	2	+1,95	+1,67	+2,50	+1,75


Tabela 3.5: Sumaryczne wyniki testu subiektywnego.

Średnia ocena radiologa		Subtelność (widoczność) zmiany			
		1	2	3	5
Zestaw parametrów	1	+1,25	+1,00	+1,80	+1,00
	2	+1,75	+2,00	+2,40	+2,00

Tabela 3.6: Sumaryczne wyniki testu subiektywnego.




Rysunek 3.12: Przykład poprawy percepcji guza dobrze odgraniczzonego (obraz 0025.LMLO): po lewej – oryginał; po prawej – obraz przetworzony za pomocą transformacji z drugim zestawem parametrów. Komentarz lekarza: na obrazie przetworzonym wyraźniejsze kontury, zdecydowanie lepiej widać spikule, wrastające w tkankę (prawy dolny róg).



Rysunek 3.13: Przykład poprawy percepcji guza spikularnego (obraz 3047.LMLO): po lewej – oryginał; po prawej – obraz przetworzony za pomocą transformacji z drugim zestawem parametrów. Komentarz lekarza: na obrazie przetworzonym widać mikrozwapnienia na środku guza, przeszkadza „duże ziarno” – szum na obrazie.

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ



Rysunek 3.14: Przykład poprawy percepcji klastra mikrozwapnień (obraz 1212.LCC): po lewej – oryginał; po prawej – obraz przetworzony za pomocą transformacji z drugim zestawem parametrów. Komentarz lekarza: na obrazie przetworzonym – wyraźniejsze kształty mikrozwapnień, tekstura niemiła dla oka – „duże ziarno”.

- transformacja z decymacją (transformacja bez decymacji wprowadza zbyt mało zmian i trzeba by zastosować dużo więcej poziomów dekompozycji, aby osiągnąć podobny efekt, wymaga wyraźnie większych nakładów obliczeniowych),
- optymalna liczba poziomów to 4-5, w zależności od falki, na niższych poziomach dekompozycji znajduje się więcej szumu (1-2), a na wyższych (powyżej 5) widać rozległe struktury tkanki - nie ma już cech odpowiadających mikrozwapnieniom i spikulom,
- lepsze są nieliniowe przekształcenia współczynników z możliwie łagodnymi zaokrągleniami. Progowanie i ostre przejścia między wartościami współczynników skutkują dodatkową teksturą, bardzo nieprzyjemną dla oka. Podobnie wyrównywanie histogramu na większych obszarach powoduje powstanie drobnej przydymionej siatki (sformułowanie lekarza radiologa).  
Usuwanie całych podpasm także powoduje zbyt duże zmiany w obrazie.

Lekarz radiolog potwierdził skuteczność wybranych metod wstępnego przetwarzania. Przeglądając się obrazom przetworzonym, lekarz na czterech mammogramach zauważył towarzyszące guzom mikrozwapnienia. Na dwóch zdecydowanie wyraźniej (w ocenie lekarza) zarysowywały się spikule. Jednak przeszkadzała lekarzowi tekstura, pojawiająca się na większości obrazów po przetworzeniu – określona przez niego jako duże ziarno. W jednym przypadku nasuwała ona podejrzenie dodatkowej zmiany, której nie było.

Należy tutaj zauważyć, że w testach subiektywnych inżynierom nie wydawała się znacząca zmieniona tekstura w dalszym sąsiedztwie zmian na obrazie.

Stąd nasuwa się wniosek, że same testy doboru parametrów także powinny być przeprowadzane z możliwie jak największym udziałem lekarza.

Ogólnie podsumowując wstępne testy: przekształcenia wielorozdzielcze umożliwiając selektywną ingerencję w wybrane fragmenty obrazu, analizę cech obiektów, efektywne wydzielenie i redukcję szumów, wzmocnienie walorów semantycznych. Możliwa jest poprawa diagnostycznie istotnych cech obrazów, zwiększająca czułość i trafność decyzji radiologów. Przetwarzanie wstępne w dziedzinie falkowej jest przydatne w metodach detekcji zmian różnych rozmiarów i właściwości, co jest szczególnie ważne w badaniach mammograficznych. Optymalizacja metod wstępnego przetwarzania jest ważnym czynnikiem poprawy efektywności systemów CAD.

### Uwagi krytyczne dotyczące wstępnych testów

- Mammogramy powinny być oglądane przez lekarza radiologa na monitorze medycznym (lepsze skontrastowanie, większa stabilność wyświetlania, automatyczna kontrola jakości, stabilność temperaturowa, głębina koloru 10-bitowa itd.<sup>4</sup>).
- Miary obliczeniowe nie oddają w pełni sposobu patrzenia radiologa na zmiany patologiczne w mammografii. Miary obliczeniowe działają tylko w małym kontekście zaznaczonych patologii. Lekarz patrzy w kontekście całego obrazu. Indeks poprawy kontrastu czy wyrazistości krawędzi ocenia tylko zmiany lokalnego kontrastu obiektów. Dla radiologa nie zawsze bardziej skontrastowana zmiana to zmiana lepiej widoczna – pojawia się problem artefaktów w pobliżu zmiany, utrudniających jej percepcję i ocenę. Natomiast miary skalarne, takie jak MSE dają informację o zmianach w obrazie, uśrednioną z całego obrazu (lub wybranego większego regionu), co nie jest wyznacznikiem jakości pożądaných zmian w strukturze obrazowanej tkanki (objawy patologiczne powinny być bardziej skontrastowane, a prawidłowe struktury nie).
- Należy wybrać strategię poprawy percepcji, tzn. zdecydować, czy celem jest obraz przyjazny dla lekarza („miły dla oka”), czy też możliwe są mocne zmiany struktury tkanki, tak aby uwypuklić same patologie. W pierwszej strategii test powinien dotyczyć tylko widoczności patologii, tzn. skala powinna być od +3 (zdecydowanie lepiej widoczna patologia) do -3 (zdecydowanie gorzej widoczna patologia), a przy drugim typie przetwarzania – ogólnej widoczności całego mammogramu i patologii na jego tle oraz ewentualnie pojawiających się nowych patologii (wynik testu niekorzystny), kiedy tekstura obrazu tak się zmienia, że sugeruje dodatkowe podejrzane zmiany.
- Na etapie wstępnych testów pojawiły się problemy, związane z rozumieniem przyjętej skali oceny porównawczej zarówno przez przeprowadzających testy, jak i lekarza. W przypadku gdy lekarz stwierdza, że część zmian się

---

<sup>4</sup>monitory medyczne EIZO: <http://www.eizo.pl/pl/medyczne.html>

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ

poprawia, a część zaciera (np. tak było przy jednym guzie w testach: lepiej widoczne spikule, a gorzej tekstura wewnątrz guza), trzeba ustalić, co jest ważniejsze pod względem widoczności patologii i na tej podstawie dać ogólną ocenę.

- Lekarz powinien oglądać powiększone fragmenty, zawierające patologię w szerszym kontekście – mogą to być większe regiony z ocenianą zmianą patologiczną lub całe mammogramy (zmniejszone do rozmiarów ekranu) i dodatkowo powiększona część obrazu, zawierająca taką zmianę.

#### 3.3.4 Kolejne testy optymalizacyjne porównawcze z udziałem radiologa

##### Wybrane zestawy parametrów

Wykorzystując: wyniki, wnioski i uwagi krytyczne z wstępnych testów, przygotowano kilka zestawów parametrów do oceny przez lekarza radiologa Eksperta. Kierowano się przy tym subiektywną oceną czterech inżynierów doświadczonych w metodach przetwarzania obrazów oraz wspierano się wynikami miar skalarnych.


Obrazy (całe mammogramy) były przetworzone 2-etapowo: 1) odszumianie (metoda: odszumianie6) – lekarz ocenił obrazy oryginalny i po odszumianiu jako porównywalne; 2) poprawa kontrastu (metody: zg1, kontrast6, kontrast6a, kontrast7, kontrast8, kontrast\_zestaw2).

**Opis metody odszumiania: odszumianie6** Użyte jądro falkowe to *'Taswell 10/10 biorthogonal symmetric most-regular'* (współczynniki filtru są dostępne w załączniku C).

Odszumianie zrealizowano poprzez wycinanie wysokoczęstotliwościowych podpasm na pierwszym poziomie transformaty oraz usuwanie najmniejszych współczynników transformaty w podpasmach 2 do 6 (według rys. 3.15).

**Opis wybranych metod: kontrast6 i kontrast7** Użyte jądro falkowe to *'Taswell 10/10 biorthogonal symmetric most-regular'*. Odszumianie zrealizowano według metody odszumianie6 (według rys. 3.15). Zmodyfikowane dane falkowe są rekonstruowane w procesie syntezy obrazu. Następnie w odszumionym obrazie jest wzmacniany lokalny kontrast – poprzez zastosowanie nieliniowych krzywych przekształceń w wysokoczęstotliwościowych podpasmach na poziomie 3 do 6 (kontrast6 – według rys. 3.16a, kontrast7 – według rys. 3.16b).

**Opis pozostałych metod poprawy kontrastu** Odszumianie zrealizowano według metody odszumianie6 (według rys. 3.15). Następnie w odszumionym obrazie jest wzmacniany lokalny kontrast poprzez zastosowanie nieliniowych krzywych przekształceń w wysokoczęstotliwościowych podpasmach na różnych poziomach dekompozycji przy zastosowaniu różnych jąder transformaty i różnych rodzajów skalowania krzywych według rysunku 3.17.



Rysunek 3.15: Siatki i krzywe transformacji użyte do odszumiania w metodzie odszumiania6: (a) krzywa zastosowana do wycinania współczynników w podpasmach HL i LH na poziomie 2 transformaty falkowej (*soft-hard thresholding* z parametrami: 0,9 i 20), (b) manualnie kształtowana krzywa, zastosowana w podpasmach wysokoczęstotliwościowych HH, HL i HH na poziomie 3,4,5 i 6 transformacji. Siatki są wizualizacją rodzaju przetwarzania w podpasmach transformaty falkowej (metoda z decymacją): **białe** bloki oznaczają wycinanie całych podpasów – współczynniki są ustawiane na zero, a **szare** oznaczają zastosowanie pokazanych krzywych przekształceń (podpasmo 2: **jasno szary**).  $D_n$  oznacza współczynniki transformaty w przetwarzanym podpaśmie.

### Procedura testu

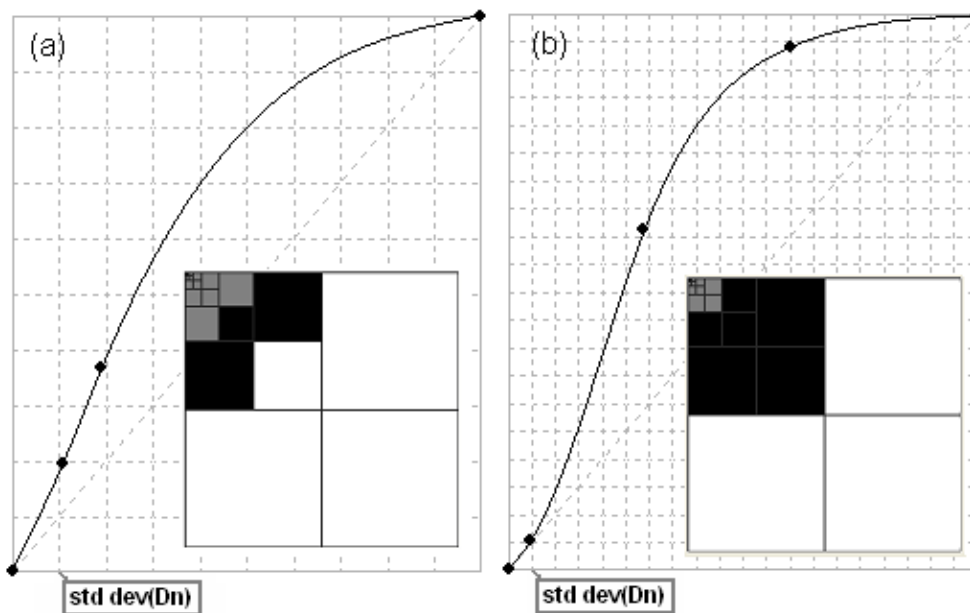
Testy zostały przeprowadzone z lekarzem radiologiem Ekspertem. Obrazy mamograficzne oglądano na monitorze medycznym EIZO (pokazuje głębię koloru 10-bitową). Test dotyczył widoczności patologii w kontekście całego obrazu mamograficznego, tzn. skala powinna być od +3 (zdecydowanie lepiej widoczna patologia) do -3 (zdecydowanie gorzej widoczna patologia) (tabela 2.1).

Lekarz oglądał obrazy w skali około 33%, zmniejszone do rozmiarów ekranu monitora. Miały wtedy w przybliżeniu wymiary kliszy rentgenowskiej 18cm x 24 cm, czyli wymiar zbliżony do naturalnego obrazu, oglądanego przez radiologa diagnozującego mammografię. Jeśli zmiana na mammogramie budziła wątpliwości, obraz był odpowiednio powiększany – tak, aby zmiana była dobrze widoczna. Dla niektórych obrazów litych guzów lepiej było widać zmiany patologiczne na obrazie pomniejszonym (nawet do 13%).


Pierwszy pokaz miał na celu wybranie dwóch najbardziej obiecujących (najlepszych) metod przetwarzania spośród sześciu zestawów: zg1, kontrast6, kontrast6a, kontrast7, kontrast8, kontrast\_zestaw2.

Podczas dalszych testów lekarz oglądał tylko wybrane dwa rodzaje obrazów (przetworzone za pomocą dwóch wybranych metod: kontrast6 i kontrast7) i obrazy oryginalne. Baza testowa to 16 obrazów (z bazy DDSM o rozdzielczości 43,5 mikrometrów/piksel z 12-bitową głębią koloru), zawierających guzy spikularne i dobrze odgraniczone z towarzyszącymi mikrozwapnieniami w dwóch przy-

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ



Rysunek 3.16: Siatki i krzywe transformacji użyte do poprawy kontrastu mammogramów: (a) metoda kontrast6, (b) metoda kontrast7. Siatki są wizualizacją rodzaju przetwarzania w podpasmach transformaty falkowej (metoda z decymacją): **białe** bloki oznaczają wycinanie całych podpasm – współczynniki są ustawiane na zero, **czarne** podpasma nie są zmieniane, a **szare** oznaczają zastosowanie pokazanych krzywych przekształceń.  $D_n$  oznacza współczynniki transformaty w przetwarzanym podpaśmie.



Rysunek 3.17: Siatki i krzywe transformacji użyte do poprawy kontrastu mammogramów: (a) metoda zg1 z falką *Daubechies8*, (b) metoda kontrast6a z falką *Villasenor 18/10*, (c) metoda kontrast8 z falką *Villasenor 18/10*, (d) metoda kontrast\_zestaw2 z falką biortogonalną 6/10. Siatki są wizualizacją rodzaju przetwarzania w podpasmach transformaty falkowej (metoda z decymacją): **białe** bloki oznaczają wycinanie całych podpasm – współczynniki są ustawiane na zero, **czarne** podpasma nie są zmieniane, a **szare** oznaczają zastosowanie pokazanych krzywych przekształceń.  $D_n$  oznacza współczynniki transformaty w przetwarzanym podpaśmie, a  $HH_n$  współczynniki transformaty na danym poziomie dekompozycji w podpaśmie  $HH$ .

padkach. Radiolog porównywał obrazy przetworzone z oryginalnym – analizował objawy patologii i oceniał je według skali z tabeli 2.1.

Na końcu pokazano lekarzowi serię regionów (fragmentów mammogramów), zawierającą mikrozwapnienia. Obrazy te były przetworzone innymi metodami, tj. wzmacnianie kontrastu także w podpasmie LL, algorytm CLAHE [8].

### Otrzymane wyniki

Pierwszy pokaz miał na celu wybranie dwóch najbardziej obiecujących (najlepszych) metod przetwarzania spośród sześciu zestawów: zg1, kontrast6, kontrast6a, kontrast7, kontrast8, kontrast\_zestaw2. W czasie pierwszego pokazu radiolog Ekspert oglądał oryginalny fragment obrazu 3006\_LEFT\_CC z bazy DDSM, zawierający guz spikularny z mikrozwapnieniami oraz obrazy przetworzone wyżej wymienionymi metodami (rys. 3.18). Oglądając sam obraz odsumiony (przetworzony metodą odsumianie6), lekarz ocenił go jako porównywalny z oryginałem, niewnoszący żadnych zmian do obrazu. Radiolog ocenił skontrastowane obrazy, ustawiając je w kolejności od najgorszego do najlepszego: kontrast8, kontrast\_zestaw2, zg1, kontrast6a, kontrast7 i kontrast6. Potem wskazał 2 obrazy, które spodobały mu się najbardziej (były ostrzejsze, lepiej było widać guzy i mikrozwapnienia). Były to zestawy kontrast6 i kontrast7. Lekarz stwierdził, że są to inne obrazy (różniące się od siebie), jednak skutkują poprawą widoczności patologii.

Wyniki testów zostały zamieszczone w tabelach: 3.7, 3.8, 3.9, 3.10 i 3.11. Przykładowe patologie – obrazy oryginalne i po przetworzeniu – są pokazane na rysunkach 3.19, 3.21 i 3.20.


Guzy spikularne									
Obraz		3006 LCC	3006 LMLO	3023 LCC	3023 LMLO	3026 RCC	3026 RMLO	3051 RCC	3051 RMLO
Subtelność		3	3	3	2	3	3	3	3
Zestaw parametrów	k6	+3	+2	+3	+2	+2	+3	+3	+3
	k7	0	0	+2	+2	+2	+2	+1	+2

Guzy spikularne					
Obraz		0006 LCC	0006 LMLO	0006 RCC	0006 RMLO
Subtelność		1	1	5	5
Zestaw parametrów	k6	+3	+2	+3	+3
	k7	+2	+2	+2	+2

Tabela 3.7: Wyniki testu subiektywnego dla obrazów guzów spikularnych – ocena radiologa Eksperta. Metody przetwarzania: k6 – kontrast6; k7 – kontrast7.

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ



Rysunek 3.18: Fragment obrazu 3006\_LEFT\_CC z bazy DDSM, zawierający guz spikularny z mikrozwapnieniami: od góry od lewej: oryginał, odszumianie metodą odszumianie6, a następnie przetworzone obrazy (obraz odszumianie6 przetworzony kolejnymi metodami poprawy kontrastu) w kolejności pokazywanej w teście.

Guzy spikularne z mikrozwapnieniami				
Obraz		3006	3026	
		LCC	RCC	
Subtelność		3	3	
Ocena radiologa	Zestaw parametrów	k6	+3	+3
		k7	0	+2

Tabela 3.8: Wyniki testu subiektywnego dla obrazów guzów spikularnych z mikrozwapnieniami – ocena radiologa Eksperta, dotycząca widoczności mikrozwapnień. Metody przetwarzania: k6 – kontrast6; k7 – kontrast7.

Guzy dobrze odgraniczone						
Obraz			0025 LCC	0025 LMLO	0025 RCC	0025 RMLO
Subtelność			5	5	5	5
Ocena radiologa	Zestaw parametrów	k6	+3	+2	+2	+2
		k7	0	0	0	0


Tabela 3.9: Wyniki testu subiektywnego dla obrazów guzów dobrze odgraniczonych – ocena radiologa Eksperta. Obrazy w sumie zawierały 6 zmian, określonych w DDSM jako guzy dobrze odgraniczone. Metody przetwarzania: k6 – kontrast6; k7 – kontrast7.

Średnia ocena radiologa		Ogólnie	Mikrozwapnienia	Guzy spikularne	Guzy dobrze odgraniczone
Zestaw parametrów	k6	+2,5	+3 (*)	+2,58	+2,25
	k7	+1,19	+1 (*)	+1,58	0

Tabela 3.10: Sumaryczne wyniki testu subiektywnego z radiologiem Ekspertem. Dane z gwiazdką dotyczą tylko 2 obrazów. Metody przetwarzania: k6 – kontrast6; k7 – kontrast7.


Średnia ocena radiologa		Subtelność (widoczność) zmiany			
		1	2	3	5
Zestaw parametrów	k6	+2 (*)	+2 (*)	+2,62	+2,5
	k7	+2 (*)	+2 (*)	+1,34	+0,67

Tabela 3.11: Sumaryczne wyniki testu subiektywnego z radiologiem Ekspertem. Dane z gwiazdką dotyczą tylko 2 obrazów. Metody przetwarzania: k6 – kontrast6; k7 – kontrast7.



Rysunek 3.19: Przykład poprawy percepcji guza spikularnego (obraz 3051.RMLO): od lewej do prawej: oryginał, obraz przetworzony za pomocą transformacji z zestawem parametrów kontrast6, obraz po przetworzeniu metodą kontrast7. Komentarz Eksperta: Zarysy odcinkowo nieostre. Metoda kontrast6 wychwytuje minimalne różnice.

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ



Rysunek 3.20: Przykład poprawy percepcji guza spikularnego, zawierającego mikrozwapnienia (obraz 3026.RCC): od lewej do prawej – oryginał, obraz przetworzony za pomocą transformacji z zestawem parametrów kontrast6, obraz po przetworzeniu metodą kontrast7.



Rysunek 3.21: Przykład poprawy percepcji guza spikularnego o wysokiej gęstości (obraz 0006.RCC): od lewej do prawej – oryginał, obraz przetworzony za pomocą transformacji z zestawem parametrów kontrast6, obraz po przetworzeniu metodą kontrast7. Komentarz lekarza: W obrazie przetworzonym metodą kontrast6 widoczne szczegóły struktury wewnętrznej guza.

### **Analiza kolejnych testów porównawczych**

Radiolog potwierdził skuteczność zaproponowanych metod przetwarzania.

**Metoda kontrast6** znacznie lepiej od oryginałów pokazuje: szczegóły, zarysy i kontury zmian, wewnętrzną strukturę guzów, efekt namiotowy. Obraz jest dużo ostrzejszy, co znacznie ułatwia w wielu przypadkach właściwą ocenę zmian, a niekiedy pozwala dostrzec zmiany pominięte w interpretacji oryginałów (mikrozwapnienia, zarysy odcinkowo spikularne). Istnieje jednak obawa, że niekiedy utrudni to ocenę guzów poprzez zbyt dokładne pokazanie zróżnicowanej struktury wnętrza guza (dokładniejszy obraz tekstury powoduje utratę jednolitości zmiany, co utrudnia jej detekcję – zanotowano jeden taki przypadek podczas testu).

**Metoda kontrast7** lepiej eksponuje guzy, rozjaśnia lite struktury, wyróżniając je z tła, nie daje wrażenia wzrostu dokładności i wydobycia szczegółów jak kontrast6, w zamian powoduje poprawę lokalnego kontrastu, co lepiej uwidacznia zmiany.

W przypadku obrazów, zawierających same skupiska mikrozwapnień bez guzów, obie metody dawały zaskakująco odmienne efekty – przede wszystkim na niedopuszczalnym poziomie były widoczne zniekształcenia obrazu, co psuło efekt rozjaśnienia samych mikrozwapnień. Radiolog wyraził podejrzenia, że użyto tutaj metod innych niż kontrast6 i kontrast7. Z drugiej strony, w pierwszej grupie obrazów z guzami niekiedy także występowały mikrozwapnienia i tutaj ocena efektów przetwarzania była jednoznacznie pozytywna dla obu metod.

W teście tym przetwarzania obrazów dokonywano na całym obrazie z zaszumionym tłem. Nie przeprowadzano wstępnej segmentacji tkanki gruczołu piersiowego. Wybrane obrazy testowe, zawierające mikrozwapnienia, miały bardzo dużo tła, natomiast sam region tkanki zajmował mniejszy obszar. Zauważono, że było to głównym problemem złej widoczności mikrozwapnień w teście, prawdopodobnie stąd przetworzone obrazy budziły podejrzenia.

W dodatkowej ocenie ROI ze skupiskiem mikrozwapnień przetworzonego kilkoma metodami najlepszy efekt dało jedynie lokalne wyrównanie histogramu (CLAHE) w dziedzinie obrazu. Silne odsumienie dało niekorzystny efekt nie-naturalności wygładzania nieistotnych fragmentów obrazu, podbicie kontrastu (włącznie z pasmem LL) silnie uwidocznilo mikrozwapnienia, jednak silniejsze skontrastowanie tła (a więc miejscowe rozjaśnienie) rodziło obawy o ograniczone możliwości detekcji mikrozwapnień w obszarach rozjaśnionych.

### **3.3.5 Ogólne wnioski i dalsze konsultacje z radiologami**

Trzech lekarzy radiologów podczas testów oraz indywidualnych konsultacji zauważyło poprawę jakości obrazów przetworzonych wybranymi metodami, szczególnie podobała się im metoda poprawy kontrastu kontrast6. Zauważono, że dla mikrozwapnień metoda odsumiania odsumianie6 czasami wprowadza niepożądane zaburzenia. Radiolodzy niechętnie oglądali obrazy przetworzone w sposób zmieniający gruntownie strukturę tkanki, oceniali go jako „niemiły dla oka”. Stąd

### 3.3. METODA POPRAWY PERCEPCJI GUZÓW I MIKROZWAPNIENÍ

nasuwa się wniosek, że w przypadku badań mammograficznych, które składają się z 4 bardzo dużych obrazów, rzeczywiście trudno jest oglądać obrazy ze znacznie zmienioną naturalną strukturą tkanki, nawet jeśli dają dużą poprawę w percepcji samych patologii (które we wczesnym stadium są niewielkie).

Zauważono, że dla algorytmów poprawy percepcji niezbędna jest uprzednia segmentacja tkanki gruczołu piersiowego, ponieważ metody poprawy percepcji powinny korzystać ze statystyk obliczanych z tkanki gruczołu (co wzięto pod uwagę w dalszej fazie weryfikacji algorytmów). Statystyki obliczane z całego obrazu, gdzie jest dużo ciemnego zaszumionego tła, wprowadzają dużo przekłamań w zależności od obszaru tła (który jest też różny na poszczególnych obrazach).

Dodatkowo przed fazą weryfikacji na dużej grupie obrazów przeprowadzono wstępną próbę testów detekcji na 20 badaniach mammograficznych z radiologiem Ekspertem. Lekarz interpretował tylko obrazy przetworzone (całe badania po 4 obrazy) z trudno uchwytnymi zmianami (o subtelności 1, 2 i 3 w bazie DDSM). Po pięć badań zostało przetworzonych metodami: `odszumianie6.kontrast6` (wcześniej opisanej jako `kontrast6`), `kontrast6`, `odszumianie6.kontrast7` (wcześniej opisanej jako `kontrast7`), `kontrast7`. Dla tych trudnych badań lekarz zaakceptował i za każdym razem określał jako dobre tylko badania przetworzone samą metodą `kontrast6`, bez wcześniejszego odszumiania. Obrazy przetworzone innymi metodami określał jako podobne do niewłaściwie wykonanych badań (niedoeksponowanych).

Dalsze testy weryfikacyjne wybranej metody przetwarzania (`kontrast6`) na większym zbiorze badań zostały przedstawione w p. 4.4.

## 3.4 Segmentacja gruczołu piersiowego

Pierwszym etapem metod poprawy percepcji czy detekcji zmian patologicznych powinna być segmentacja tkanki piersi od tła obrazu. Ten wstępny etap wykorzystuje się jako ograniczenie regionu analizy algorytmów (czasem powodujące znaczne przyspieszenie algorytmów), albo jest niezbędne do otrzymania prawidłowych parametrów obrazowanej tkanki (co wykazały badania nad poprawą percepcji patologii).

W systemie *MammoViewer* do segmentacji tkanki piersiowej zaimplementowano algorytm, bazujący na technikach rozrostu regionów<sup>5</sup>. Przyjęto wstępne założenie, że obszar tkanki piersi w obrazie jest spójny i możliwe jest określenie względnie prostych kryteriów przynależności piksela do gruczołu.

### 3.4.1 Wstępny algorytm segmentacji tkanki piersi

<sup>6</sup> Algorytm proponowanej metody segmentacji tkanki gruczołu piersiowego składa się z następujących kroków:

1. Określenie, czy na obrazie mamy prawą, czy lewą pierś.
2. Określenie dolnego  $T_d$  i górnego  $T_g$  progu przynależności do gruczołu.
3. Wybór punktu startowego do segmentacji.
4. Segmentacja z wykorzystaniem wyznaczonego punktu startowego i progów.

Opis poszczególnych punktów przedstawia się następująco:

**Ad. 1.** Krok ten służy optymalizacji wydajności metody. Określenie, czy mamy w obrazie pierś prawą, czy lewą umożliwia prawidłowy wybór punktu startowego i rozpoczęcie segmentacji z miejsca należącego do gruczołu. Jest to ważne, gdyż gdyby punkt startowy był poza gruczołem, kryterium zakończenia pracy algorytmu zostałyby spełnione bardzo szybko – zaraz po rozpoczęciu (wartość funkcji jasności punktu startowego nie zawiera się w przedziale pomiędzy progami  $T_d$  i  $T_g$ ) ze zdecydowanie błędnym wynikiem.

Decyzja jest podejmowana na podstawie analizy średniej jasności dwóch regionów obrazu: pierwszego, obejmującego 100% wysokości i 20% szerokości obrazu, licząc od lewej krawędzi oraz drugiego, obejmującego 100% wysokości i 20% szerokości obrazu, licząc od prawej krawędzi. Większy poziom średniej jasności w pierwszym regionie oznacza pierś lewą, w drugim – prawą.

---

<sup>5</sup>Wstępny algorytm segmentacji piersi został napisany w systemie *MammoViewer* przez Piotra Bonińskiego (wykorzystujący stworzone wcześniej elementy systemu, tj.: operacje na histogramach, procedury progowania, wizualizacja granicy wysegmentowanego regionu itp.), a następnie zoptymalizowany przez autorkę.

<sup>6</sup>autor: Piotr Boniński [16]

### 3.4. SEGMENTACJA GRUCZOŁU PIERSIOWEGO

- Ad. 2.** Progi do segmentacji są wyznaczone eksperymentalnie z histogramu obrazu. Dolny próg  $T_d$  jest wyznaczony poprzez określenie średniego poziomu jasności całego obrazu, pomniejszony o 15%, górny  $T_g$  – jako 97,5 percentyl histogramu.
- Ad. 3.** Punkt startowy do segmentacji jest wyznaczony jako odległy o 10% szerokości obrazu od prawej bądź lewej krawędzi (w zależności od wyniku kroku 1) oraz będący w połowie wysokości.
- Ad. 4.** Sam proces segmentacji bazuje na metodzie rozrostu obszaru (*region growing*). Metoda ta polega na łączeniu punktów lub fragmentów obrazu w większe [168]. W sąsiedztwie wybranego punktu (w ogólniejszym przypadku punktów początkowych może być więcej) poszukuje się takich punktów, które będą spełniały określone kryterium przynależności (dotyczące np.: poziomu jasności, koloru, tekstury). W tym przypadku wykorzystano kryterium stałego przedziału jasności, wyznaczonego na podstawie histogramu całego obrazu. Piksele sąsiednie o jasności, należącej do ustalonego przedziału, są dołączane do tworzonego obszaru. Proces dołączania jest rekurencyjnie powtarzany dla kolejnych, dodawanych punktów. Jeśli żaden z sąsiednich punktów nie spełnia zadanego kryterium, rozrost obszaru w danym kierunku jest zatrzymany.

#### 3.4.2 Uzasadnienie potrzeby optymalizacji algorytmu

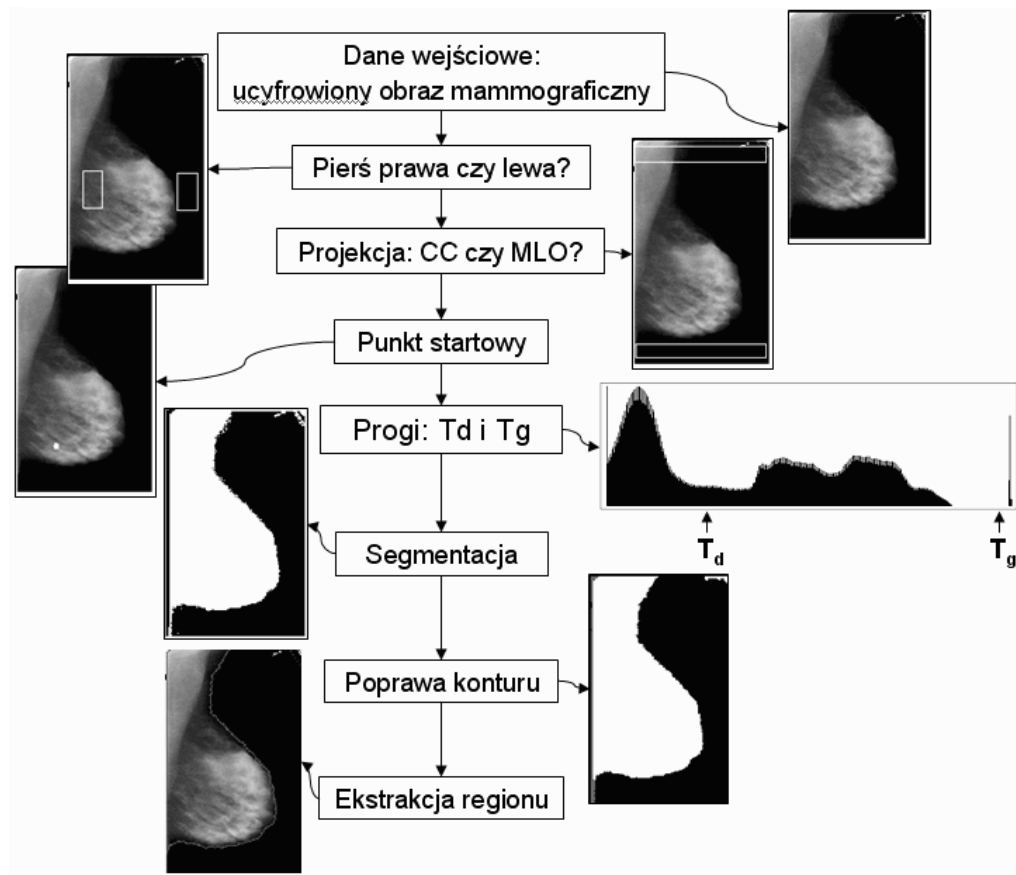
Zauważono dużą zmienność w dostępnych obrazach mammograficznych pod kątem położenia obszaru tkanki względem całej, zobrazowanej kliszy. Zaobserwowano różnice pomiędzy mammogramami w projekcjach CC i MLO. W projekcji CC najjaśniejsze obszary (należące najczęściej do stożka gruczołowego) znajdują się w górnej połowie obrazu, a w projekcji MLO w dolnej połowie. Czasem punkt startowy, pomimo rzeczywistej przynależności do tkanki gruczołu, nie spełniał kryterium przynależności do przedziału, wyznaczonego górnym i dolnym progiem. Zdarzało się też, że pierś zajmowała zaledwie mały procent obszaru obrazu, a wtedy punkt startowy algorytmu nie należał do obszaru tkanki. Czasem na obrzeżach mammogramów są widoczne jasne fragmenty tła, poza zeskanowaną kliszą rentgenowską. Progi wyznaczone na podstawie średniej i percentyla histogramu czasem dołączały zbyt dużo tego jasnego tła, a czasem nie zaliczały jaśniejszych obszarów tkanki, znajdujących się przy brzegu obrazu. Ponadto wstępny algorytm segmentacji dołączał czasami (szczególnie w projekcji MLO) fragmenty opisu obrazu jako należące do tkanki gruczołu.

#### 3.4.3 Optymalizacja algorytmu segmentacji gruczołu piersiowego

Zoptymalizowany algorytm segmentacji tkanki gruczołu piersiowego (razem z obszarem mięśnia w projekcji MLO) składa się z kroków, przedstawionych w algorytmie 3.1. Schemat tego algorytmu jest przedstawiony na rysunku 3.22.

**Algorytm 3.1.** *Zoptymalizowany algorytm segmentacji tkanki od tła*

1. Określenie strony obrazowanego gruczołu (lewa lub prawa).
2. Określenie projekcji (CC lub MLO).
3. Wybór punktu startowego do segmentacji.
4. Określenie dolnego  $T_d$  i górnego  $T_g$  progu przynależności do gruczołu za pomocą analizy histogramowej i procedury wyznaczania optymalnych progów.
5. Segmentacja na obrazie pomniejszonym o 20% względem oryginału z wykorzystaniem wyznaczonych progów – stworzenie mapy tkanki.
6. Poprawa zarysu granicy tkanki za pomocą operacji morfologicznych.
7. Ekstrakcja regionu tkanki.



Rysunek 3.22: Schemat algorytmu segmentacji tkanki gruczołu piersiowego (razem z mięśniami na obrazach w projekcji MLO) od tła na ucyfrowionych obrazach mammograficznych. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

### 3.4. SEGMENTACJA GRUCZOŁU PIERSIOWEGO

**Ad. 1.** Analizy średniej jasności dwóch małych regionów obrazu (o wymiarach 5% wysokości i szerokości obrazu): pierwszego, znajdującego się w małej odległości od brzegu obrazu (10% szerokości) i w połowie jego wysokości, licząc od lewej krawędzi oraz drugiego, w odległości 10% od prawego brzegu obrazu i także w połowie wysokości. Większy poziom średniej jasności w pierwszym regionie oznacza pierś lewą, w drugim - prawą.

Zmiana ta powoduje właściwie określenie strony piersi (lewej lub prawej), nawet pomimo białych brzegów obrazu poza zeskanowaną kliszę.

**Ad. 2.** Ta sama pierś w różnych projekcjach ma inne ułożenie względem obrazu. Automatyczne określenie projekcji odbywa się na podstawie analizy histogramu dwóch prostokątnych regionów: pierwszego w górnej części obrazu, w odległości od górnego brzegu 1% wysokości i o wymiarach 100% szerokości i 5% wysokości, a drugiego według lustrzanego odbicia względem środka, czyli znajdującego się przy dolnym brzegu obrazu. Cztery razy większa średnia jasności górnego prostokąta oraz skośność mniejsza od 1 i kurtoza mniejsza od zera oznaczają projekcję MLO. Jeśli powyższe warunki nie są spełnione, przyjmuje się, że pierś na obrazie jest w projekcji CC.

**Ad. 3.** Jeśli mamy do czynienia z piersią lewą, współrzędna pozioma punktu startowego jest ustalana jako 25% szerokości, a jeśli z piersią prawą – 75% szerokości. Jeśli obrazowany narząd jest w projekcji MLO, to współrzędna pionowa jest ustalana jako 5/8 wysokości, licząc od góry obrazu, a w projekcji CC jest to 3/8 wysokości. Czasem jest potrzebna korekta współrzędnych poziomych, tak aby punkt startowy znajdował się w zakresie dalej wybranych progów. Jest ona wykonywana w sąsiedztwie tutaj wybranego punktu startowego.

**Ad. 4.** Dolny próg  $T_d$  jest to optymalny próg (algorytm 3.2), wyznaczany z histogramu.

**Algorytm 3.2.** *Procedura wyznaczania optymalnego progu [145]*

Algorytm zakłada, że na obrazie są obecne dwa rozdzielne obszary, każdy wewnątrz siebie, o zbliżonych wartościach funkcji jasności, których rozkład jasności w histogramie można przybliżyć rozkładami Gaussowskimi. W przypadku segmentacji piersi to założenie jest spełnione: rozkład funkcji jasności w histogramie obszaru tkanki i tła można przybliżyć dwoma rozkładami Gaussa (dwie „górkę” w histogramie).

1. Jest wyznaczane pierwsze przybliżenie progu pomiędzy obiektem i tłem (tutaj: najniższa wartość funkcji jasności w obrazie).
2. W kroku  $n$ , są obliczane średnia jasność obiektu  $\mu_O^n$  i tła  $\mu_B^n$ , gdzie segmentacja tła i obiektu jest dokonywana na podstawie progu  $T^n$ , wyznaczonego w poprzednim kroku.

3. Ustawianie progu jako:

$$T^{(n+1)} = \frac{\mu_B^n + \mu_O^n}{2} \quad (3.1)$$

4. Jeśli  $T^{(n+1)} = T^n$ , koniec algorytmu, w przeciwnym wypadku powrót do punktu 2.

Próg górny  $T_g$  to drugi optymalny próg, wyznaczany z analizy części histogramu powyżej  $T_d$  do 99,5 percentyla histogramu. Tutaj zakładamy, że w zakresie funkcji jasności powyżej progu  $T_d$  mamy w przybliżeniu 3 rozkłady Gaussa. Tkanka piersi obejmuje 2 rozkłady: obszar ciemniejszy – tkanka tłuszczowa gruczołu – oraz obszar jaśniejszy – często albo mięsień w projekcji MLO lub stożek gruczołowy. Pozostały jeden rozkład Gaussa to bardzo jasny obszar tła – zwykle brzegi obrazu poza zeskanowaną kliszą. Wyznaczanie górnego progu jako drugiego optymalnego progu jest dokonywane analogicznie do  $T_d$ , na podstawie procedury optymalnego progowania, przy założeniu trzech obszarów do segmentacji, czyli dwóch progów, z czego wyższy będzie progiem  $T_g$ . Jeśli jednak wyznaczony próg  $T_g$  znajduje się poniżej 92 percentyla histogramu lub zakres pomiędzy progami  $T_d$  i  $T_g$  to mniej niż 35 percentyl histogramu (obraz bez białego brzegu, bez wyraźnego stożka gruczołowego i zwykle w projekcji CC), wartość  $T_g$  jest poprawiana jako 99,7 percentyl histogramu.

**Ad. 5.** Progowanie obrazu przy zastosowaniu progów  $T_d$  i  $T_g$ .

**Ad. 6.** Wyznaczone granice piersi są poszarpane, ponadto zawierają często jasny brzeg obrazu. Region ten jest poprawiany przy użyciu morfologicznego zamknięcia.

**Ad. 7.** W pamięci oraz plikach tekstowych region tkanki gruczołu jest przechowywany jako ciąg współrzędnych jego granicy na obrazie. Algorytm ekstrakcji regionu z mapy binarnej (algorytm 3.3) polega na nadaniu każdemu obiektowi (regionowi) obecnemu na mapie unikalnej etykiety. Wtedy jest możliwa jego identyfikacja jako oddzielnego obiektu. Jako obszar tkanki jest wyznaczany ten obiekt, który będzie zawierał punkt startowy. Algorytm ten jest szybszy od zastosowanego wcześniej algorytmu rozrostu regionów (struktury danych i czas obliczeń zostały zoptymalizowane).

**Algorytm 3.3.** *Ekstrakcja regionów z binarnej mapy [145]*

Algorytm identyfikacji regionów (Kolejne kroki algorytmu są pokazane na rysunku 3.23.): Wejściem dla algorytmu etykietującego jest obraz binarny – zerowe tło i niezerowe obiekty.

1. Pierwsze przejście:


Przeszukiwanie całego obrazu  $I$  wiersz po wierszu i przypisanie niezerowej etykiety  $v$  każdemu niezerowemu punktowi  $I(i, j)$ . Wartość  $v$  jest wybierana zgodnie z etykietami sąsiadów punktu. (Sąsiedzi punktu są zdefiniowani na rysunku 3.24.)

### 3.4. SEGMENTACJA GRUCZOŁU PIERSIOWEGO

- Jeśli wszyscy sąsiedzi punktu są tłem (wartość pikseli wynosi zero), punktowi  $I(i, j)$  jest przypisana nowa jeszcze nieużywana etykieta.
- Jeśli jest tylko jeden sąsiad z niezerową wartością, jego etykieta jest przypisana punktowi  $I(i, j)$ .
- Jeśli jest więcej niż jeden niezerowy sąsiad, etykieta jednego z nich zostaje przypisana punktowi  $I(i, j)$ . Jeżeli etykiety sąsiadów różnią się (kolizja etykiet – rys. 3.24c), zapamiętuje się te pary etykiet jako równoważne. Pary równoważności są przechowywane w oddzielnej strukturze danych.

#### 2. Drugie przejście:


Wszystkim regionom zostały nadane etykiety podczas pierwszego przejścia, ale niektóre z nich zawierają piksele z różnymi etykietami (z powodu kolizji etykiet). Cały obraz jest skanowany ponownie i pikselom są nadawane nowe etykiety, przy użyciu par równoważności – wszystkie równoważne etykiety są zastąpione przez jedną niepowtarzającą się etykietę.



Rysunek 3.23: Identyfikacja obiektów (sąsiedztwo 8-spójne): (a),(b),(c) kroki algorytmu. Pary równoważności po kroku (b): 2-5, 5-6, 2-4. (Rysunek zaczerpnięty z pracy [145])

Zaimplementowany algorytm wykazuje dużą efektywność działania. Został przetestowany na około tysiącu obrazów, wykazując się dobrą segmentacją tkanki. Czasem w projekcji MLO, gdy klisza rentgenowska została zeskanowana w taki sposób, że na górze obrazu pozostało dużo jasnego tła, było ono dołączane do wysegmentowanego regionu. W celu poprawy segmentacji wystarczyło wyciąć fragment obrazu bez większości jasnego tła poza kliszą, jak pokazano na rysunku 3.25. Ponadto w nielicznych przypadkach w projekcji CC, metoda nie dołączała jaśniejszych fragmentów tkanki znajdujących się przy brzegu obrazu po stronie klatki piersiowej. Poprawę segmentacji w tej sytuacji można osiągnąć poprzez wymuszanie, aby fragment konturu od strony klatki piersiowej był linią prostą równoległą do właściwego brzegu obrazu.

Na podstawie algorytmu segmentacji tkanki gruczołu piersiowego stworzono także prosty algorytm segmentacji stożka gruczołowego (jaśniejszego obszaru




Rysunek 3.24: Sąsiedztwo punktu  $(i, j)$ : (a) sąsiedztwo 4-spójne (b) sąsiedztwo 8-spójne (c) Kolizja etykiet zdarza się bardzo często. Przykładami kształtów, których ona dotyczy, są obiekty w kształcie litery U, odwróconego E, itd. (Rysunek zaczerpnięty z pracy [145])

w tkance piersiowej bez mięśnia). W zasadzie jest on analogiczny z tą różnicą, że analizowany histogram to histogram liczony tylko w obszarze wysegmentowanej tkanki, a nie histogram całego obrazu. Jednak taki algorytm segmentacji stożka działa tylko dla badań z wyraźnie zaznaczonym obszarem stożka, który jest oddzielony od mięśnia w projekcji MLO.

Takie algorytmy segmentacji stożka mogą przydać się do tworzenia map narządu piersi (użytecznych na przykład przy porównywaniu piersi lewej z prawą) oraz do automatycznego określania położenia wykrywanych patologii, które – jeśli leżą poza obszarem stożka – są uznawane od razu za podejrzane.

### 3.4. SEGMENTACJA GRUCZOŁU PIERSIOWEGO



Rysunek 3.25: Przykład nieprawidłowej segmentacji tkanki z dołączonymi obszarami jasnego tła – po prawej obraz oryginalny z zaznaczonym niebieskim konturem wysegmentowanej tkanki, po lewej mapa wysegmentowanej tkanki. Na dole przykład poprawy segmentacji poprzez wycięcie właściwego regionu kliszy rentgenowskiej, bez jasnego tła obrazu. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

### 3.5 Detekcja klastrów potencjalnych mikrozwapnień

Celem opracowanej metody detekcji jest wskazanie regionów, zawierających klastry mikrozwapnień. Zaproponowano metodę: lokalizacji, klasteryzacji i segmentacji nadmiarowego zbioru obiektów zainteresowania – potencjalnych mikrozwapnień. Wykorzystano elementy analizy wielorozdzielczej obrazów, metody grupowania i morfologii matematycznej, zwracając szczególną uwagę na jakość wykrywanych klastrów [160, 161, 165, 166]. Zaproponowana metoda detekcji klastrów mikrozwapnień składa się z etapów przedstawionych w algorytmie 3.4. Schemat jest pokazany na rysunku 3.26.

**Algorytm 3.4.** *Detekcja klastrów mikrozwapnień*

1. Wstępne przetwarzanie – segmentacja tkanki gruczołu piersiowego.
2. Lokalizacja jasnych plamek – potencjalnych mikrozwapnień (skalowalne filtry *LoG*).
3. Grupowanie w klastry.
4. Segmentacja obiektów w klastrach.
5. Opis kształtu klastrów — otoczki wypukłej zlokalizowanych grup.

#### 3.5.1 Lokalizacja jasnych plamek

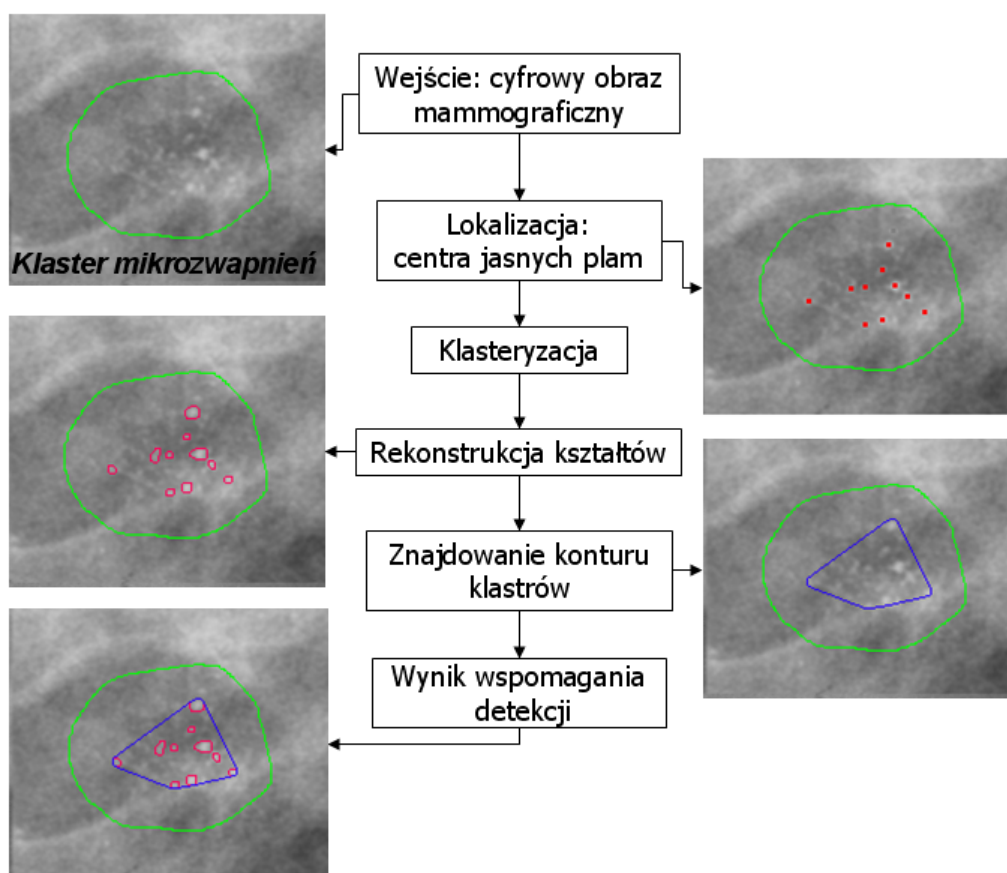
Założeniem była wstępna detekcja nadmiarowego zbioru kandydatów – potencjalnych mikrozwapnień, który jest redukowany w znacznym stopniu w procesie klasteryzacji i rekonstrukcji kształtu.

Lokalizacja jasnych plamek – pojedynczych obiektów potencjalnych mikrozwapnień jest realizowana przez skalowalne filtry *LoG* ('Laplacian-of-Gaussian') – poszukiwanie największych lokalnych maksimów na ścieżkach utworzonych na podstawie obrazów po filtracji *LoG* w różnych skalach (rys. 3.5). Wykorzystano metodę opisaną w p. 2.3.1, optymalizując ją oraz dostosowując do konkretnych potrzeb.

**Algorytm 3.5.** *Lokalizacja jasnych plamek*

1. Detekcja jasnych plamek:
  - znalezienie lokalnych maksimów w obrazie po filtracji *LoG* o najniższej skali  $h_{MIN}$ ,
  - inicjalizacja ścieżek dla każdego znalezionej maksimum oraz kontynuacja poszukiwania lokalnych maksimów aż do najwyższej skali  $h_{MAX}$ ,
  - zidentyfikowanie największej odpowiedzi filtru na każdej ścieżce i oznaczenie odpowiadającego jej punktu jako optymalnego kandydata.
2. Estymacja rozmiaru i lokalnego kontrastu plamki.

### 3.5. DETEKCYA KLASTRÓW POTENCJALNYCH MIKROZWAPNIEŃ



Rysunek 3.26: Schemat zaproponowanej metody detekcji klastrów potencjalnych mikrozwapnień.

#### 3. Progowanie — wybranie plamek

Jeśli lokalny kontrast jest większy od ustalonego progu, jednakowego dla każdego rozmiaru plamek, taka plamka jest pozostawiana na obrazie.

Optymalizowane parametry to:

- najniższa skala filtru  $LoG - h_{MIN}$ ,
- najwyższa skala filtru  $LoG - h_{MAX}$ ,
- zmiana skali w każdym kroku tworzenia ścieżki -  $h_{INC}$ ,
- rozmiar sąsiedztwa dla sprawdzania, czy punkt jest lokalnym maximum -  $n_{LM}$ ,
- rozmiar sąsiedztwa dla szukania największego lokalnego maximum w otoczeniu kandydata z niższej skali -  $n_{WP}$ ,
- próg, powyżej którego wykryta plamka jest uznawana jako potencjalne mikrozwapnienia -  $T$ , jego zależność adaptacyjna od statystyk z sąsiedztwa,

zależność progu od skali filtru  $LoG$ , dającego najwyższą odpowiedź dla analizowanej plamki.

Wybrane parametry to:

- $h_{MIN} = 3$  – w klastrach złośliwych mikrozwapnień czasem nie ma wyraźnie wyodrębnionych mikrozwapnień, ale często jest wokół nich dużo punktowych mikrozwapnień,
- $h_{MAX} = 9$ ,
- $h_{INC} = 2$  – zmniejsza czas obliczeń,
- $n_{LM} = 3$ ,
- $n_{WP} = 5$  – większy obszar poszukiwania, ponieważ algorytm przeskakuje co dwie skale filtrów,
- próg –  $T$  oraz zależność, według której jest wybierany:

$$T = n \cdot \sigma \quad (3.2)$$

gdzie  $\sigma$  – odchylenie standardowe obrazu bądź regionu, podejrzanego o występowanie mikrozwapnień,  $n$  – parametr: dla małego regionu zawierającego skupisko mikrozwapnień  $n = 6$  lub dla słabo wysyconych mikrozwapnień  $n = 5$ , dla regionu całej tkanki (całego wysegmentowanego regionu piersi)  $n = 10$ .

**Ocena działania detekcji** Metoda działa prawidłowo na mniej więcej jednorodnym tle (tkance). Dla obszarów o różnej gęstości, np. stożek gruczołowy i fragmenty tkanki tłuszczowej, metoda może znajdować dużo fałszywych wskazań w ciemniejszych obszarach lub nie znajdować mikrozwapnień w jaśniejszych obszarach, w zależności od progu. Przyczyną tego jest fakt, że mikrozwapnienia w tkance gruczołowej (jaśniejsze obszary obrazu) mają znacznie mniejszy lokalny kontrast niż w tkance tłuszczowej (ciemniejsze obszary). Algorytm można poprawić poprzez zastosowanie identyfikacji obszarów o podobnym utkaniu (jednorodnych): o podobnym zakresie jasności lub o podobnym wskaźniku kontrastu. Następnie próg – inny dla każdego wybranego obszaru – uzależnić od statystyk obszarowych.

**Opis wyników lokalizacji potencjalnych obiektów mikrozwapnień** Metoda identyfikuje małe, w przybliżeniu okrągłe obszary (plamki), nieco jaśniejsze niż otaczające je tło (tkanka). Na mammogramach mogą to być:

- mikrozwapnienia:
  - mikrozwapnienia złośliwe i mniejsze łagodne (rys. 3.27 i 3.28),
  - mikro- lub makrozwapnienia naczyniowe – oczywiste łagodne, w ścianach naczyń, z jednej strony mają większą siłę krawędzi (bardziej ostry gradient),

### 3.5. DETEKcja KLASTRÓw POTENCJALNYCH MIKROZwAPNIENÍ

- duże, okrągłe „pojedyncze” łagodne, skorupkowate (w środku z cieniem – środek mniej wysycony niż obrzeża) wysycone makrozwapnienia lub ich fragmenty, jeśli zwapnienia są nierównomiernie wysycone – o nierównomiernej teksturze (rys. 3.29),
- mikrozwapnienia łagodne dysplastyczne,
- fałszywe wskazania:
  - włókna – fragmenty struktury zdrowej tkanki, mają większą powierzchnię i niski gradient,
  - skrzyżowania włókien (rys. 3.31),
  - tekstura – małe przejaśnienia na obrazie „udające” mikrozwapnienia, zwykle jednak o niższym lokalnym kontraście (rys. 3.32),
- artefakty: bardzo wysokie piki z dużym gradientem o małej powierzchni, czasem wyglądają jak nitka – są lekko wydłużone (rys. 3.30). Wysokie piki są trudne, prawie niemożliwe do rozróżnienia, z bardzo małymi mikrozwapnieniami punktowymi. Kryterium odróżniającym mogłoby być położenie na gruczole piersiowym, np. bliżej ściany klatki piersiowej często zbiera się kurz.

**Wskazania fałszywie negatywne – brak właściwych wskazań** Mikrozwapnienia szczególnie amorficzne. Klastry takich mikrozwapnień wyglądają jak niewielkie zmiany kontrastu w pewnym obszarze. Niektóre takie zwapnienia mają bardzo rozmyte krawędzie. Są to przypadki dla których trudno wyodrębnić i opisać kształt.


Wniosek – tekstura wewnątrz klastra powinna być inaczej oceniona niż na zewnątrz. W przypadku szczególnie trudnych klastrow mikrozwapnień często można wyodrębnić zaledwie jeden lub dwa obiekty, reszta mikrozwapnień jest widoczna jako „szorstka tekstura” (na co najmniej jednej projekcji). Dlatego też dla takich przypadków powinna być inna metoda detekcji, która analizuje teksturę, ponieważ nie można wysegmentować oddzielnych obiektów.

#### 3.5.2 Klasteryzacja

Danymi wejściowymi klasteryzacji są punkty – centra (ziarna) wykrytych jasnych plam (potencjalnych mikrozwapnień). Grupowanie w klastry jest bazuje na przestrzennym rozmieszczeniu i gęstości obiektów (wykrytych ziaren). Dostosowano tutaj algorytm klasteryzacji, opartej na gęstości obiektów, z uwzględnieniem szumu – DBSCAN [47].


#### Zarys algorytmu DBSCAN

W algorytmie DBSCAN (*'Density Based Spatial Clustering of Applications with Noise'*) klastery definiuje się jako grupę obiektów, połączonych z zadaną gęstością [47].




Rysunek 3.27: Obiekty wykrywane przez algorytm lokalizacji: mikrozwapnienia. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)


### 3.5. DETEKCYJA KLASTRÓW POTENCJALNYCH MIKROZWAPNIEŃ



Rysunek 3.28: Obiekty wykrywane przez algorytm lokalizacji: bardzo subtelne mikrozwapnienia. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)



Rysunek 3.29: Obiekty wykrywane przez algorytm lokalizacji: makrozwapnienia – duże, nierównomiernie wysyczone (o nierównomiernej teksturze) zwapnienia wykrywane jako kilka oddzielnych obiektów, w zależności od zmian tekstury. Algorytm segmentacji powinien łączyć te obiekty w jeden duży obszar. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)



Rysunek 3.30: Obiekty wykrywane przez algorytm lokalizacji: artefakty – małe (o powierzchni kilku pikseli) bardzo jasne (duży gradient) piki lub rysy – powstałe w wyniku zarysowań kliszy i osiadania pyłków na zdjęciach rentgenowskich podczas skanowania itp. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)


Do definicji klastra są potrzebne dwa parametry (rys. 3.34):

- *Eps* — promień sąsiedztwa punktu określonego według przyjętej metryki (tutaj euklidesowa),
- *MinPts* — minimalna liczba punktów w klastrze oraz w sąsiedztwie punktów leżących wewnątrz klastra (Sąsiedztwo punktów brzegowych klastra może być mniej liczne.)


Definicja klastra jest oparta na obiektach wzajemnie osiągalnych lub połączonych z pewną zadaną gęstością (o parametrach *Eps* i *MinPts*). Punkt bezpośrednio osiągalny z zadaną gęstością z innego punktu to taki, który znajduje się w *Eps*-sąsiedztwie tego punktu, dodatkowo w sąsiedztwie tym musi zawierać się co najmniej *MinPts* innych punktów. Punkt osiągalny z zadaną gęstością z innego punktu, to punkt, dla którego istnieje ścieżka punktów bezpośrednio osiągalnych z punktu startowego do końcowego.

Każde dwa obiekty należące do klastra są połączone wzajemnie z zadaną gęstością (łączność) oraz wszystkie punkty osiągalne (z zadaną gęstością) z punktów


### 3.5. DETEKCYJA KLASTRÓW POTENCJALNYCH MIKROZWAPNIEŃ



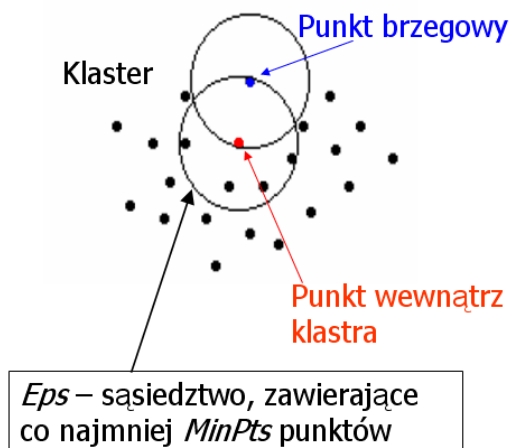
Rysunek 3.31: Obiekty wykrywane przez algorytm lokalizacji: jasne włókna i ich skrzyżowania – bardzo długie struktury (krzywe) nieco jaśniejsze od tła (większa powierzchnia i niski gradient), wykrywane jako kilka oddzielnych obiektów, w zależności od zmian wysycenia i tekstury. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)



Rysunek 3.32: Obiekty wykrywane przez algorytm lokalizacji: tekstura „udająca” mikrozwapnienia (słabo wysyciona). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)



Rysunek 3.33: Obiekty wykrywane przez algorytm lokalizacji: tekstura „udająca” mikrozwapnienia lub łagodne mikrozwapnienia (obiekty nie były oznaczone w bazie, stąd weryfikacja jest niemożliwa). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)



Rysunek 3.34: Schemat przyłączania nowych punktów do klastra. Różne kryterium dla punktów wewnątrz klastra i punktów brzegowych [47].

### 3.5. DETEKcja KLAstrÓw POTENCJALNYCH MIKROZwAPNIENÍ

leżących wewnątrz klastra także należą do klastra (maksymalność). Dla punktu należącego do klastra najpierw jest rozwijany cały klaster. Później algorytm przechodzi do analizy kolejnych punktów, nienależących do żadnego klastra. Dokładny opis algorytmu można znaleźć w [47].

#### Modyfikacje algorytmu DBSCAN dla grupowania potencjalnych mikrozwapnień

Jako parametry tworzonego klastra przyjęto:

- średnicę klastra:  $CD = 2 * Eps$  (domyślnie  $CD = 1cm$ ),
- minimalną liczbę obiektów w klastrze  $MinPts$  (domyślnie  $MinPts = 3$ ).

Do algorytmu dodano możliwość odrzucania klastrów (lub części obiektów należących do klastrów pod warunkiem, że pozostałe obiekty nadal spełniają kryterium przynależenia do klastra), w których obiekty są oddalone od siebie o więcej niż określona średnica zasięgu. Parametry odrzucanych klastrów (lub obiektów w klastrach):

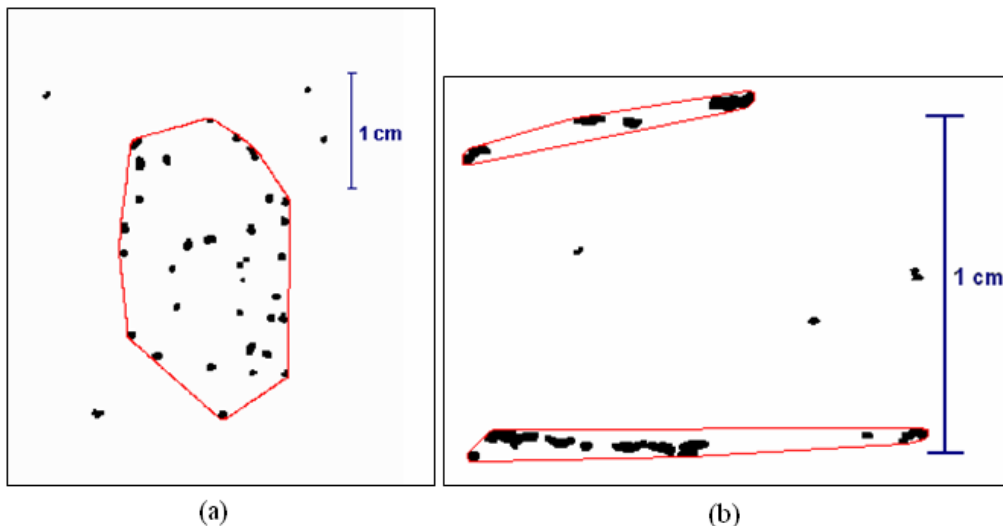
- średnica zasięgu wokół obiektu:  $SD$  (np.  $SD = CD/2$ ),
- minimalna liczba obiektów, które muszą znajdować się w zasięgu obiektu  $MSP$  (np.  $MSP = 2$ ).

Dla przykładu w poprzednich implementacjach *ImageChecker R2* program wskazywał takie klastry mikrozwapnień, w których były co najmniej 3 obiekty na obszarze  $1 cm^2$ , ale odrzucał te, w których każdy obiekt jest oddzielony o więcej niż  $2,5 mm$ . Jednakże modyfikacja ta, pomimo potencjalnej zalety odrzucania nadmiarowych klastrów, okazała się nieistotna w fazie testów (opisanych w p. 4.2).

**Zalety algorytmu klastrowania DBSCAN w zagadnieniu klasteryzacji mikrozwapnień** Algorytm DBSCAN okazał się szybszy i bardziej efektywny niż standardowa klasteryzacja. Jego złożoność obliczeniowa to ok.  $k * \text{złożoność znalezienia } Eps\text{-sąsiedztwa}$  dla analizowanego punktu (w najgorszym przypadku jest to  $O(k)$ , gdzie  $k$  jest liczbą kandydatów — obiektów do grupowania. Jest to znacznie lepsza złożoność niż innych algorytmów  $O(nxm)$ , gdzie  $n$  i  $m$  to wymiary obrazu. Zwykle  $k^2 \ll nxm$ , ponieważ nawet przy niskim progu detekcji rząd wielkości  $k$  osiąga około 500, a wielkość macierzy obrazu to około  $6000 \times 4000$  pikseli. W standardowych algorytmach czasem kwant przesunięcia okna sąsiedztwa jest większy — ok.  $0,5 cm$  (złożoność jest niższa niż  $O(nxm)$ ). Jednak wtedy wyniki są mniej dokładne — nie są rozpatrywane wszystkie konfiguracje punktów i niektóre klastry mogą zostać pominięte, w przeciwieństwie do DBSCAN. Ponadto czas działania algorytmu DBSCAN można zmniejszyć, stosując zoptymalizowane struktury danych, takie jak drzewa czwórkowe.

Inną zaletą algorytmu DBSCAN jest znajdowanie klastrów, posiadających mniej więcej równomierne rozłożenie obiektów (rys. 3.35a). Algorytm ten jest

mniej czuły na łączenie klastrów (rys. 3.35b), tzn. nieprawidłowej redukcji fałszywych wskazań — głównego problemu standardowej klasteryzacji — patrz rys. 2.18. Artefakty nieco oddalone od centrum klastra nie są dołączane do klastra. W ten sposób kształty klastrów są dokładniejsze i bardziej odpowiednie do dalszej analizy cech kształtu i tekstury wykrytych grup.



Rysunek 3.35: Standardowe algorytmy zaliczają do jednego klastra wszystkie czarne obiekty. (a) DBSCAN wykrywa jako klaster zgrupowanie równomiernie rozrzuconych obiektów, nie dołączając artefaktów. (b) DBSCAN dzieli obiekty na dwie grupy, wzdłuż przewodów mlecznych, bez dołączania artefaktów. (Rysunek wykonany w systemie *MammoViewer*.)

### Problemy klasteryzacji

W zagadnieniu klasteryzacji mikrozwapnień kluczową sprawą jest zaliczanie do klastra. Teoretycznie powinno ono być zgodne z percepcją radiologa. Problemy pojawiają się jednak przy metodach automatycznych. Tak więc czasem mikrozwapnienia punktowe powinny być zaliczane (np. tworzące gałązki w klastrze rozgałęzionym), a czasem powinny być odrzucane (jeśli jest ich bardzo dużo i tworzą dużą „chmurę” w okolicy większych mikrozwapnień). Kłopotliwe jest też oddzielenie od mikrozwapnień złośliwych pobliskich łagodnych mikrozwapnień – selekcja powinna się odbywać według charakteru obiektów (należy tutaj określić i rozróżnić charakter obiektów).

Na obecnym etapie kryterium zaliczania do klastra zostało określone na podstawie wzajemnych odległości i gęstości obiektów. Ponadto nie można założyć, że wszystkie mikrozwapnienia w każdym klastrze są dobrze dobrane (całkowity brak fałszywych pojedynczych obiektów). Należy natomiast przyjąć, że w klastrze są wykryte tylko niektóre obiekty (najbardziej „dominujące” według kryterium lokalnego kontrastu). Dlatego w metodach analizy mikrozwapnień warto analizować teksturę wewnątrz wyznaczonego klastra. Klastry bardziej niejednorodny powinny mieć bardziej chropowatą teksturę wewnątrz.

Dla klastrów liniowych parametr  $Eps$  w kryterium zaliczania do klastra powinien być większy – większa odległość (np.  $\sqrt{2}$  cm, jak w [81]), ponieważ układają się w linie i są dalej od siebie rozłożone.

#### 3.5.3 Segmentacja obiektów potencjalnych mikrozwapnień

Danymi wejściowymi segmentacji są punkty – w przybliżeniu centra obiektów (zlokalizowanych jasnych plam) oraz przybliżona średnica (skala w filtracji  $LoG$ , parametr nieużywany w każdym przypadku).

##### Algorytm progowania 'white top-hat' (PWTH)

Algorytm polega na progowaniu obrazu po filtracji morfologicznej 'white top-hat' [160, 159]. Próg metody jest wybierany na podstawie lokalnego histogramu, modelowanego rozkładem normalnym według reguły:  $T = \bar{x} + n\sigma$ , gdzie  $\bar{x}$  i  $\sigma$  to średnia i odchylenie standardowe liczone z modelu. Następnie piksele są grupowane w większe obiekty, a pojedyncze piksele i małe obiekty – usuwane.

##### Algorytm maksymalnego spadku (MS)


**Założenie:** Krawędzie mikrozwapnienia lub innego obiektu stanowią zamknięty kontur wokół wejściowego punktu centrum.

Znajdowanie krawędzi zlokalizowanego obiektu w kilku kierunkach od punktu ziarna, a następnie rozwinięcie ich do pełnego konturu obiektu – 'hill climbing'. Metoda ta polega na znajdowaniu największego spadku [7], gdzie spadek można zdefiniować jak w równaniu (2.36), gdzie  $f(x_0, y_0)$  można także zdefiniować jako wartość funkcji jasności w punkcie w dziedzinie obrazu lub w dziedzinie wielorozdzielczej (np. po filtracji  $LoG$  w wielu skalach).

W pierwszym kroku punkty krawędzi obiektu są znajdowane w wybranych kierunkach (równomiernie rozłożonych na okręgu o środku w punkcie centrum w każdym kierunku). Dla każdego kierunku piksel jest uznawany za punkt krawędzi, jeśli dostarcza największą wartość spadku. Następnie wybrane punkty zostają połączone.

##### Parametry algorytmu

- liczba kierunków, w których szukamy maksymalnego spadku,
- maksymalne okno sąsiedztwa, w którym poszukujemy maksymalnego spadku,
- obraz wejściowy: oryginalny, obraz po operacji morfologicznej 'white top-hat' lub przetworzony obraz po filtracji  $LoG$  w wielu skalach: Dla każdego ziarna (punktu centrum) i w jego otoczeniu obraz jest przefiltrowany filtrem  $LoG$  o odpowiedniej skali, dobranej w algorytmie lokalizacji: maksimum na ścieżce filtrów  $LoG$  – odpowiadające w przybliżeniu średnicy obiektu.



Rysunek 3.36: Fragment obrazu mammograficznego z mikrozwapnieniami (powiększony): (a) oryginalny obraz, (b) histogram poziomów szarości obrazu oryginalnego (a), (c) obraz po filtracji 'white top-hat', (d) histogram poziomów szarości obrazu (c). Część pikseli o wyższej intensywności stanowi około 3% wybranego fragmentu obrazu. Czerwoną linią jest zaznaczony dobrany model statystyczny histogramu. 145 – próg dobrany według reguły doboru progu. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

### Algorytm lokalnego minimum najbliższego centrum (LM)

Analogiczny do algorytmu maksymalnego spadku, ale poszukuje się najbliższego lokalnego minimum w danym kierunku.

### Algorytm bazujący na lokalnych statystykach w sąsiedztwie punktu (LS)

W oknie sąsiedztwa są obliczane lokalne statystyki. Następnie piksele o wartościach funkcji jasności powyżej adaptacyjnego progu (obliczanego na podstawie statystyk) oraz tworzące spójny obszar wokół punktu wejściowego są zaliczane do obiektu.

### Parametry algorytmu:

### 3.5. DETEKCJA KLASTRÓW POTENCJALNYCH MIKROZWAPNIEŃ

- maksymalne okno sąsiedztwa, na podstawie którego są obliczane statystyki: średnia  $\bar{x}$  i odchylenie standardowe  $\sigma$ ,
- parametr  $n$  w zależności wyznaczającej próg:

$$T = \bar{x} + n\sigma \quad (3.3)$$

- obraz wejściowy: oryginalny lub przetworzony (jak w algorytmie maksymalnego spadku).

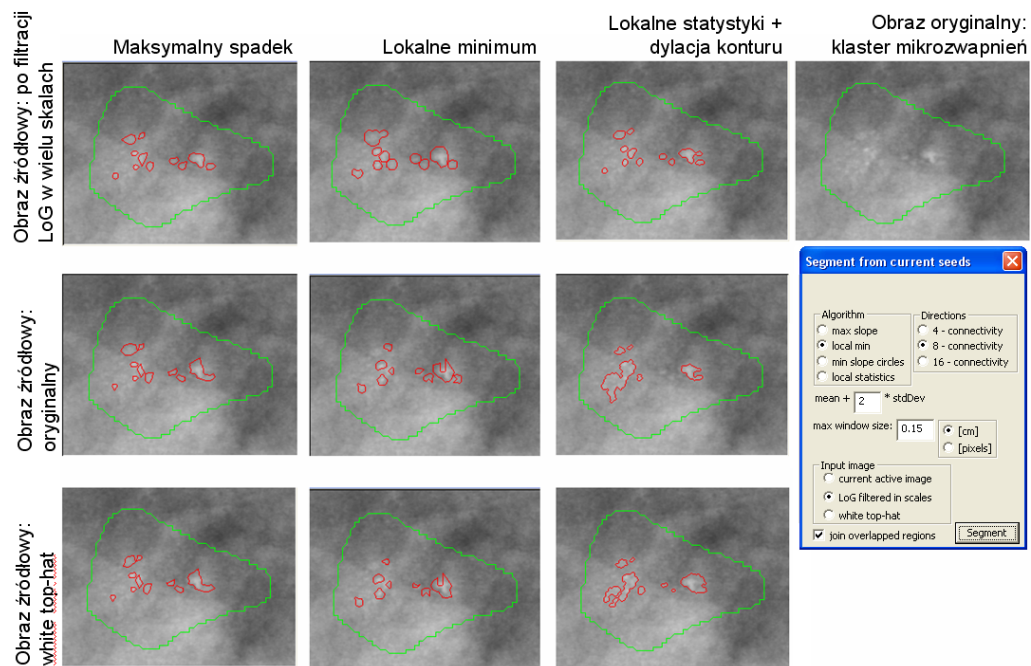
Dodatkowo po zastosowaniu każdej z wymienionych metod oceniono możliwość poprawy segmentacji obiektów poprzez zastosowanie wygładzania konturu metodami rozrostu regionów oraz dylacji wzdłuż brzegu konturu.

#### Wybór metody segmentacji

W fazie segmentacji nie były przeprowadzane regularne testy przedstawionych metod. Na początku powstała wstępna metoda PETH (wybrano parametry: dwukrotna filtracja 'white top-hat' z elementem strukturującym – kołem o średnicy 7-dmiu pikseli oraz parametrem w regule doboru progu  $n = 3, 3$ ). Zauważono, że często kształty wysegmentowanych obiektów są poszarpane. Dążąc do bardziej regularnych kształtów, zaimplementowano kolejne metody. Następnie wysegmentowane kształty oceniali specjaliści z przetwarzania obrazów (mający wiedzę na temat obrazu mikrozwapnień i ich cech). Kilkakrotnie przeprowadzono konsultacje z radiologami.

Radiolodzy ocenili metodę LS jako najlepiej oddającą percepcję kształtu (dobra aproksymacja, bez poszarpanych brzegów). Wybrane parametry metody to: rozmiar okna sąsiedztwa do obliczania statystyk wynosi 0,5 cm, obrazem wejściowym dla segmentacji jest obraz po filtracji *LoG* w wielu skalach, a statystyki do reguły wyznaczania progu także są obliczane na podstawie tego obrazu, parametr w regule doboru progu to  $n = 1, 5$ . W większości przypadków metoda MS także okazała się dobra, szczególnie dla większych obiektów, jednak czasem kształty mikrozwapnień były zbyt okrągłe, a zarysy brzegów – zbyt kanciaste.

Przykładowe wyniki algorytmów segmentacji są przedstawione na rys. 3.37.



Rysunek 3.37: Wyniki algorytmów segmentacji obiektów wokół punktów ziaren: Obraz oryginalny (po prawej) oraz obiekty wysegmentowane różnymi algorytmami. Dodatkowo pokazano okno interfejsu systemu *MammoViewer* z możliwością doboru metody segmentacji oraz jej parametrów. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*.)

## 3.6 Ekstrakcja cech pojedynczych mikrozwapnień i klastrów

System *MammoViewer* dostarcza narzędzi do ekstrakcji regionów z tła i obliczania: cech tekstury i kształtu [160, 19, 159], cech pojedynczych mikrozwapnień i cech klastrów mikrozwapnień. Zaimplementowano szereg (ponad 60) numerycznych metod opisu właściwości. Dokładne opisy tych metod i wzory są dostępne w dokumentacji systemu w załączniku E.

Wybrane do klasyfikacji właściwości powinny jak najlepiej odzwierciedlać specyfikę mikrozwapnień zawartych w mammogramach oraz uwypuklać różnicę pomiędzy łagodnymi i złośliwymi przypadkami, aby można było przeprowadzić skuteczną klasyfikację: wskazać potencjalne mikrozwapnienia oraz wyróżnić mikrozwapnienia złośliwe.

### 3.6.1 Opis potencjalnych mikrozwapnień

Grupy wykrytych obiektów (dla poszczególnych grup powinny być inne właściwości różnicujące):

- obiekty punktowe: Są to obiekty „poza percepcją radiologa” o powierzchni poniżej  $6,5 \text{ mikrometrów}$  ( $0,065 \text{ mm}^2$ ). Zwykle są to artefakty albo mikrozwapnienia punktowe poza percepcją radiologa, z których wyrastają mikrozwapnienia złośliwe. Bardzo często towarzyszą one złośliwym mikrozwapnieniom i wskazują miejsca rozrostu inwazji. Zgrubne rozróżnienie w tej grupie obiektów można osiągnąć poprzez eliminację przy pomocy klasteryzacji (są pozostawiane tylko obiekty w grupach) oraz pozostawianie do dalszej analizy tylko obiektów w grupach z co najmniej jednym większym obiektem.
- potencjalne mikrozwapnienia: złośliwe i łagodne, np. dysplastyczne i naczyniowe, mniejsze włókna i zmiany tekstury obrazu zdrowej tkanki. Jest to najtrudniejsza grupa – przydatne właściwości do rozróżnienia potencjalnych mikrozwapnień od normy (tkanki prawidłowej), to: momenty kształtu ( $SM^7$ ), miary tekstury wewnątrz obiektu, takie jak odchylenie standardowe (SD), energia (EE), średnia (MX) oraz miary lokalnego kontrastu: odpowiedź filtru *LoG* (*LoGR* – obliczona w metodzie lokalizacji), różnica średniego poziomu jasności obiektu od średniego poziomu jasności tła (FBD) oraz średnia siła krawędzi (ESM).
- duże obiekty o powierzchni powyżej  $1 \text{ mm}^2$ : włókna, makrozwapnienia łagodne, duże naczyniowe lub zwapnienia charakterystyczne dla zaawansowanego raka. W celu rozróżnienia istotnych obiektów (zaawansowanego raka) można zastosować właściwości wyrazistości krawędzi (średnia – ESM – i odchylenie standardowe – ESSD).

<sup>7</sup>W nawiasach podano symbole numerycznych metod opisu podanych właściwości zaimplementowane w systemie *MammoViewer*. Zostały one zdefiniowane w dokumentacji systemu – załącznik E.

We wstępnych testach weryfikowano możliwości klasyfikacji na zbiorze właściwości, wybranym w [167] dla grupy potencjalnych mikrozwapnień wysegmentowanych metodą PWITH (tab. 3.12). W kolejnych testach na zbiorze danych wysegmentowanych metodą LS dokonano automatycznej selekcji cech kilkoma metodami. Wyniki opisano w p. 4.3.

Nazwa	Opis
Powierzchnia (AR)	Rozmiar obiektu
Średnia (MX)	Średni poziom szarości, odchylenie standardowe poziomów szarości, poziom szarości tła obiektu
Odchylenie standardowe (SD)	
Tło (BAC)	
Skontrastowanie obiektu i tła (DR)	(średnia - tło)/(średnia + tło)
Współczynnik zwartości (CM)	obwód <sup>2</sup> /powierzchnia
Moment kształtu 1 (SM1)	$SM_i = \left[ \frac{1}{N} \sum_{j=1}^N [z(j) - m_1]^{i+1} \right]^{1/(i+1)} / m_1$ dla $i = 1$ , gdzie $m_1 = \frac{1}{N} \sum_{i=1}^N z(i)$ , $z(i)$ , dla $i = 1, 2, \dots, N$ są odległościami (w metryce Euklidesowej) między centroidem a uporządkowanym zbiorem kolejnych punktów konturu rozpatrywanego kształtu. [140]
Moment niezmienniczy 0 (IM0)	Niezależna od translacji, zmiany skali i obrotu kombinacja znormalizowanych momentów centralnych (wyprowadzonych z momentów geometrycznych względem centroidu obiektu)[121].
Kontrast (CM-CO)	Macierz powinowactwa $S$ (macierz zdarzeń, 'cooccurrence matrix') przechowuje informacje o teksturze obrazu. Elementami tej macierzy są estymowane prawdopodobieństwa $s(i, j)$ wystąpienia par punktów o jasnościach $i$ oraz $j$ , dla określonej odległości pomiędzy punktami i przyjętym kierunku analizy [168].
Entropia (CM-EN)	
Moment zwykły drugiego rzędu (CM-EE)	
Odwrotny moment różnicowy (CM-IDM)	
Korelacja (CM-COR)	
Kowariancja (CM-COV)	
Entropia rozkładu sumacyjnego (CM-SEN)	

Tabela 3.12: Zbiór cech kształtu i tekstury, zastosowanych do klasyfikacji pojedynczych obiektów mikrozwapnień.

### 3.6.2 Właściwości morfologiczne i numeryczne metody opisu właściwości klastrow mikrozwapnień dla ontologii i indeksowania obrazów

<sup>8</sup> Wybrane cechy złośliwych mikrozwapnień, należących do skupiska, charakteryzuje „duża zmienność”. Właściwości klastrow, świadczące o ich niejednorodności bądź jednorodności były „wzorowane” na właściwościach ocenianych wizualnie przez radiologa, zgodnie z percepcją radiologa, natomiast cechy macierzy zdarzeń należy wybrać algorytmem selekcji cech.

Niejednorodność klastra oznacza, że pojedyncze obiekty w obrębie klastra są różne od siebie. Podstawowe wizualne właściwości mikrozwapnień, brane pod uwagę przez radiologów przy ocenie niejednorodności/jednorodności skupiska:

- zmienność kształtu,
- zmienność wielkości,
- zmienność wysycenia.

Dodatkowe, nie zawsze brane pod uwagę i niefunkcjonujące powszechnie w świadomości większości początkujących radiologów objawy niejednorodności:

- niejednorodna tekstura wewnątrz klastra. Zwykle w takich klastrach na zdjęciu powiększonym widać więcej mikrozwapnień.
- „nierównomierne” rozłożenie mikrozwapnień wewnątrz klastra. Zazwyczaj w skupisku złośliwych mikrozwapnień z jednej strony jest więcej małych obiektów, stąd bierze się trójkątny kształt klastra.
- rozmycie krawędzi. Cecha świadcząca o podejrzanym charakterze, trudna do obserwacji wizualnej na standardowym zdjęciu, widoczna dopiero na zdjęciu powiększonym.

Proponowane właściwości,<sup>9</sup> opisujące niejednorodność/jednorodność klastra (zmienność cech obiektów w klastrze względem siebie):

- Zmienność wielkości: średnia i odchylenie standardowe –
  - długości osi obiektów należących do klastra (MDIAM),
  - powierzchni (AR).
- Zmienność kształtu – cechy dobrze różnicujące typy/kształty mikrozwapnień (okrągłe, ziarniste, linijne): średnie i odchylenia standardowe –
  - zwartości (CM),
  - momentów kształtu (MK1, MK3),

---

<sup>8</sup>Praca wspólna z Teresą Podsiadły-Marczykowską.

<sup>9</sup>Numeryczne metody opisu wyliczonych właściwości zostały zaimplementowane w systemie *MammoViewer* — opisy metod dla pojedynczych obiektów można znaleźć w dokumentacji systemu w załączniku E.

- najdłuższej osi (MDIAM),
  - stopień eliptyczności (ELD1, ELD2),
  - momenty niezmiennicze (IM0, IM2, IM3),
  - „chropowatości” konturu (RG1, RG2),
  - *box ratio* (BR) lub wydłużenia (EG),
  - trójkątności (TR).
- Zmienność wysycenia: średnie i odchylenia standardowe –
    - średniej jasności wewnątrz obiektów (MX),
    - lokalnego kontrastu obiektów: różnica średniego poziomu jasności obiektu i tła (FBD), stosunek tych poziomów jasności (FBR), skonstrastowanie obiektu i tła (DR),
    - energia obiektów (EE).
  - Zmienność tekstury wewnątrz klastra: odchylenie standardowe poziomów jasności obiektów (SD), cechy macierzy zdarzeń tekstury w obszarze klastra (CM-\*).
  - Zmienność rozmycia krawędzi: średnia (ESM) i odchylenie standardowe siły krawędzi (ESSD).

Właściwości rozłożenia obiektów w klastrze:

- ilość obiektów w skupisku lub ilość/powierzchnia klastra,
- średnia i odchylenie standardowe odległości środków mikrozwapnień od centrum klastra (dodatkowo odległości są pomnożone przez wagi, zależne od masy pojedynczych obiektów – obiekty z większą masą mają większą wagę),
- wydłużenie kształtu skupiska (EG) – bardziej podejrzany jest kształt klastra wydłużony lub przypominający drzewko.

Rozłożenie obiektów w klastrze można potraktować jako „zastępujące” kształt, który nie zawsze jest prawidłowy z powodu „niedoskonałych” (niezgodnych z percepcją radiologa) kryteriów zaliczania obiektów do klastra<sup>10</sup>.


### 3.7 Klasyfikacja

We wstępnych testach weryfikowano możliwości klasyfikacji na zdefiniowanym zbiorze cech (tab. 3.12) dla grupy potencjalnych mikrozwapnień, wysegmentowanych metodą PWITH. W kolejnych testach na trudniejszym zbiorze danych, wysegmentowanych metodą LS dokonano automatycznej selekcji cech kilkoma metodami. Klasyfikowano pojedyncze obiekty – potencjalne mikrozwapnienia (rys. 3.38).

<sup>10</sup>Opis problemów klasteryzacji zamieszczono w p. 3.5.2

### 3.8. ROZSZERZENIE OBSZARU ZASTOSOWAŃ

Zastosowanymi klasyfikatorami są sztuczna sieć neuronowa – trójwarstwowa sieć jednokierunkowa z algorytmem uczenia propagacji wstecznej oraz maszyna wektorów nośnych z jądrem wielomianowym oraz RBF. Wyniki opisano w p. 4.3.



Rysunek 3.38: Wyniki klasyfikacji pojedynczych potencjalnych mikrozwapnień: (a) obraz oryginalny; (b) zaznaczone odręcznie mikrozwapnienia; (c) wyniki automatycznej detekcji; (d) weryfikacja detekcji (klasyfikacja: mikrozwapnienia / norma-prawidłowa tkanka); (e) diagnoza (klasyfikacja: złośliwe / łagodne / norma).

### 3.8 Rozszerzenie obszaru zastosowań

Dodatkowo w systemie *MammoViewer* zostały zrealizowane przez innych członków zespołu (wykorzystując elementy systemu stworzone przez autorkę): metoda lokalizacji zaburzeń architektury [76] oraz metoda detekcji i segmentacji potencjalnych guzów [20].

System został również wykorzystany w badaniach nad stratną kompresją mammogramów [122] oraz progresją wiarygodności [128, 127], w badaniach nad poprawą percepcji wczesnego niedokrwionego zawału mózgu w tomografii komputerowej (CT) we wstępnej fazie w zakresie wizualizacji, optymalizacji algorytmów odszumiania i poprawy percepcji [163, 8].

### 3.8.1 Detekcja potencjalnych guzków

Celem było opracowanie metody detekcji guzków, spełniającej następujące założenia [20]<sup>11</sup>:

- w pełni automatyczne działanie (do zastosowania w systemie automatycznego indeksowania badań mammograficznych zawartością, umożliwia indeksowanie istniejących baz badań w trybie wsadowym),
- czas analizy obrazu dostosowany do aplikacji w interaktywnym systemie wspomagania diagnostyki,
- wysoka czułość detekcji kosztem wzrostu liczby wskazań nadmiarowych. W systemie w pełni automatycznego indeksowania i przeszukiwania pominięcie jakiegось przypadku zmiany oznacza brak możliwości utworzenia odpowiedniego opisu tego badania w indeksie, czyli zupełną utratę – niewidoczność tego przypadku przy przeglądaniu bazy referencyjnej.

Zasadniczą cechą opracowanej metody (algorytm 3.6) jest wstępne przetwarzanie – nieliniowa korekcja histogramu – transformacja Rayleigha. Główne kroki algorytmu przedstawiono na rysunku 3.39.


**Algorytm 3.6.** *Detekcja potencjalnych guzków*

1. Segmentacja gruczołu piersiowego.
2. Transformacja Rayleigha dla uwypuklenia potencjalnych centrów guza.
3. Progowanie w celu wyznaczenia punktów początkowych segmentacji. Poziom prog jest wyznaczany z histogramu obrazu po transformacji Rayleigha jako wartość 97 percentyla.
4. Dla każdego punktu początkowego segmentacja przybliżonego obszaru guza metodą rozrostu regionów/obszarów. Dolny próg, określający przynależność do regionu, to 93 percentyl histogramu obrazu po transformacji Rayleigha.
5. Odrzucenie regionów o powierzchni mniejszej niż  $5 \text{ mm}^2$ .
6. Wyznaczenie powierzchni i atrybutów kształtu (momenty kształtu) potencjalnego guza.

Do eksperymentów wykorzystano 156 obrazów, pochodzących z bazy DDSM. Zawierały one 72 obiekty, będące zdiagnozowanymi guzami złośliwymi. W tym zbiorze danych uzyskano: 58 przypadków TP, 376 przypadków FP oraz 14 przypadków FN. Tak więc czułość opracowanego algorytmu to około 80,2%, przy poziomie około 2,5 wskazań fałszywie pozytywnych.

---

<sup>11</sup>Metoda opracowana przez Piotra Bonińskiego przy wykorzystaniu istniejących elementów systemu.



Rysunek 3.39: Główne kroki algorytmu wykrywania potencjalnych guzów: (a) transformata Rayleigha dla uwypuklenia potencjalnych centrów guza, (b) progowanie dla wyznaczenia punktów początkowych segmentacji, (c) dla każdego punktu początkowego segmentacja przybliżonego obszaru guza.

### 3.8.2 Detekcja zaburzeń architektury

Metoda detekcji zaburzeń architektury (algorytm 3.7) bazuje na filtracji Gabora i analizie dwóch macierzy: maksymalnych amplitud i maksymalnych kątów kierunkowości tekstury [76]. Ma na celu przedstawienie rozkładu prawdopodobieństwa występowania zaburzeń architektury na mammogramie.

**Algorytm 3.7.** *Tworzenie mapy prawdopodobieństwa występowania zaburzeń architektury*

1. Segmentacja granicy gruczołu piersiowego.
2. Filtracja zespołem filtrów Gabora.
3. Analiza dwóch macierzy maksymalnych amplitud i kątów kierunkowości tekstury.
4. Tworzenie „mapy prawdopodobieństw”.

We wstępnym teście na zbiorze 9 obrazów przy takich parametrach metody, aby czułość wynosiła 100%, liczba fałszywych wskazań na obraz wynosiła średnio 8,55, a po odrzuceniu wskazań z linii brzegowej piersi oraz makrozwapnień liczba ta wynosiła 2,78.

### 3.8.3 Doskonalenie metod indeksowania po zawartości

Systemy indeksowania obrazów medycznych po zawartości (CBIR) są wykorzystywane do wspomaganie diagnostyki poprzez stosowanie referencyjnych baz danych

diagnostycznych. W systemach tych zbiory danych obrazowych są charakteryzowane na podstawie lokalnych i globalnych właściwości obrazów, które najlepiej korelują z semantyką zawartej w nich informacji, a podobieństwo obrazów określa numeryczna miara bliskości zawartej treści diagnostycznej. W takich referencyjnych bazach danych klinicznie zweryfikowana informacja obrazowa jest efektywnie przeglądana w celu doboru przypadków diagnostycznie bliskich zapytaniu (najczęściej są to trudne w interpretacji badania obrazowe).

Stworzono referencyjną bazę danych obrazowych *IShark* [17], gdzie *MammoViewer* służy jako narzędzie ekstrakcji cech semantycznych do indeksowania oraz jest klientem systemu indeksacji. *MammoViewer* generuje gotowe do użycia binarne pliki cech dla serwera indeksującego [16].

### 3.8.4 Wspieranie systemu ontologii mammografii

Ontologia mammografii jest to formalna reprezentacja wiedzy medycznej, używanej do semantycznego opisu i przede wszystkim do interpretacji zmian mammograficznych w kategoriach diagnozy obiektów w obrazie.

Opisy w ontologii i opis wynikający z przetwarzania obrazów są „nieprzystające” zarówno do siebie, jak i do sposobu patrzenia i rozumowania radiologa. Jednak, mimo subiektywnego opisu i niepewnych reguł diagnozy, radiolodzy, wykorzystując wiedzę o dziedzinie, są w stanie skutecznie stawiać diagnozę nawet w trudnych przypadkach. Subiektywność opisu semantycznego dotyczy zarówno samego opisu cech, jak i diagnozy.

Aby umożliwić bliższy związek pomiędzy semantycznym i numerycznym opisem mammograficznym (generowanym przez systemy przetwarzania obrazów), jest konieczna zintegrowana ontologia obrazu mammograficznego, zawierająca pojęcia odnoszące się do obrazu wraz z odpowiadającymi im deskryptorami matematycznymi i metodami przetwarzania.

Aby skutecznie współpracować z systemem ontologii, system CADD powinien dostarczać:

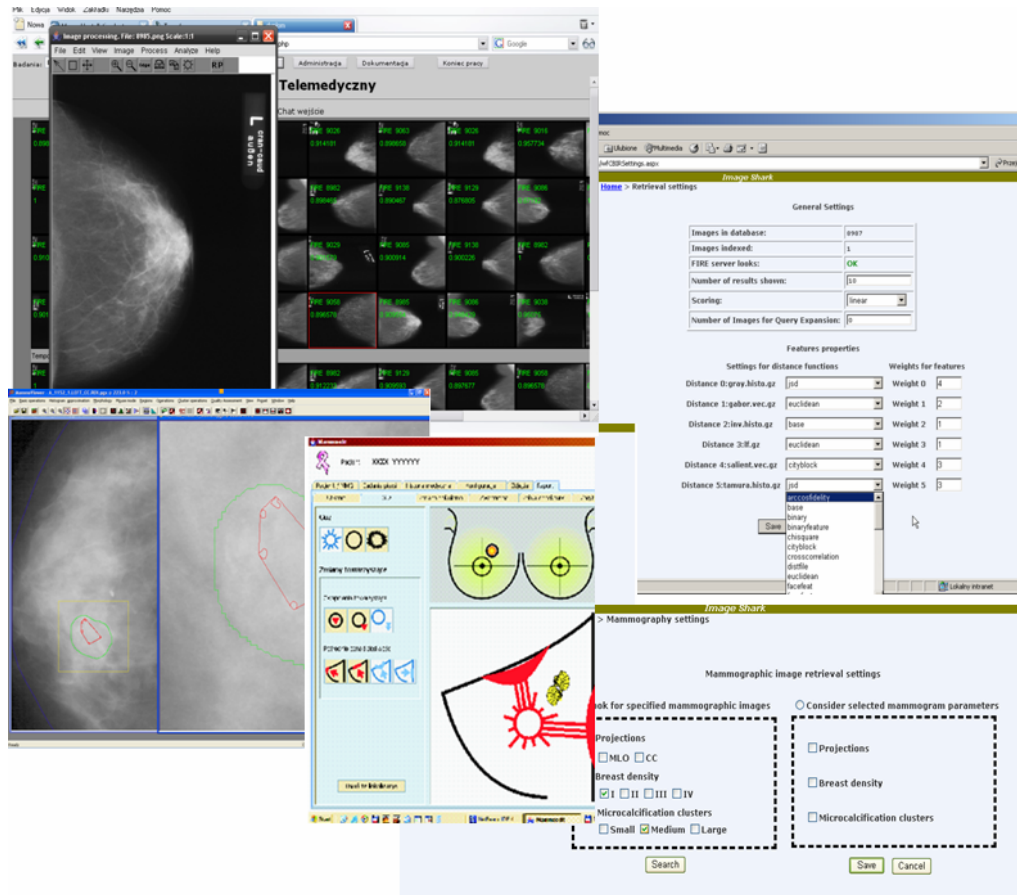
- Automatycznie ekstrahować cechy zmiany, zgodne z opisem semantycznym i regułami diagnozy.
- Na etapie klasyfikacji korzystać z „wiedzy” ontologicznej oraz z deskryptorów obrazu patologii [129].
- Dostarczać metody przetwarzania obrazu poprawiające percepcję zmian patologicznych (dostosowane do typów zmian oraz do ich właściwości).

### 3.8.5 Koncepcja zintegrowanego interfejsu wspomaganie do stacji diagnostycznej

Na bazie dotychczasowych badań naukowych powstała koncepcja współpracy systemu ontologii mammograficznej, referencyjnej bazy danych obrazów mammograficznych oraz systemu CADD – *MammoViewer*. Interfejs stacji diagnostycznej, wspieranej przez powyższe narzędzia, może wyglądać tak jak na rys. 3.40. Lekarz

### 3.8. ROZSZERZENIE OBSZARU ZASTOSOWAŃ

radiolog może korzystać z modułów do oglądania badań z zaawansowanymi metodami poprawy percepcji obrazów i z sugestiami potencjalnych patologii oraz modułu do opisu badań (wspieranego przez system ontologii mammografii) oraz wyszukiwać podobne badania według preferencji ustalonych w bazie obrazów mammograficznych *ImageShark* [129, 118].



Rysunek 3.40: Zintegrowany interfejs wspomagania do stacji diagnostycznej: system CADD – *MammoViewer*, system ontologii mammografii, baza danych obrazów referencyjnych– *ImageShark*.



## Rozdział 4

---

# Eksperymenty

---

W rozdziale została przedstawiona weryfikacja eksperymentalna algorytmów zaimplementowanych w systemie *MammoViewer*, głównie: poprawy percepcji, detekcji i klasyfikacji mikrozwapnień. Opisano: bazę testową obrazów mammograficznych, organizację i przebieg eksperymentów, wyniki i ich analizę.

Najważniejsze testy kliniczne przy współudziale lekarzy radiologów oraz ich opinie na temat systemu i przyjętych metod, wnioski z obserwacji ich pracy z systemem wspomagania przedstawiono w p. 4.4.

\* \* \*

### 4.1 Bazy testowych mammogramów

Do testów wykorzystano zdiagnozowane bazy danych obrazów mammograficznych DDSM (*'Digital Database for Screening Mammography'* dostępna w Internecie [64]) oraz własny zestaw obrazów mammograficznych.

#### 4.1.1 DDSM

Baza DDSM jest przeznaczona do: badań naukowych, testowania i porównywania skuteczności działania algorytmów wspomagania diagnostyki mammograficznej. Zawiera 2620 przypadków badań, które zostały wykonane w trzech ośrodkach w Stanach Zjednoczonych w latach 90. Pojedynczy przypadek w bazie zawiera 4 obrazy: zdjęcia obydwu piersi – każde w dwóch projekcjach (CC i MLO), a także niektóre informacje, dotyczące pacjentki (data badania, wiek, typ budowy piersi wg BI-RADS itp.) oraz informacje o digitalizacji obrazu (skaner, rozdzielczość przestrzenna). Obrazy zawierające regiony chorobowe mają dodatkowo informacje, określone przez radiologów, na temat: położenia, typu schorzenia (w przypadku zmian nowotworowych wyniku badania histopatologicznego), klasyfikacji BI-RADS oraz ich subtelności. Subtelność to stopień trudności detekcji (jakość

widoczności) zmian na obrazie w skali od 1 (bardzo słabo widoczne) do 5 (bardzo wyraźne). Jest to wypadkowa wielu czynników, takich jak: gęstość, typ utkania w otoczeniu zmiany i konfiguracja wartości jej cech, m.in. wielkość, wysycenie, lokalizacja, dystrybucja mikrozwapnień, licznosc w klastrze mikrozwapnień.

Jeśli w obrazie występuje kilka rodzajów zmian, zwykle zaznaczona i sklasyfikowana jest tylko najgroźniejsza z nich. Wszystkie te dodatkowe dane są zapisane w formie tekstowej w plikach o rozszerzeniu OVERLAY.

Do digitalizacji wybranych mammogramów z bazy DDSM użyto 3 skanerów. Parametry skanerów i digitalizacji są umieszczone w tabeli 4.1. Tak powstałe obrazy cyfrowe mają wymiary średnio 4 tys. x 5 tys. pikseli i zajmują około 30 Mb pamięci każde.

Nazwa skanera	Rozdz. przestrzenna w mikrometrach	Głęb. koloru liczba bitów/piksel
DBA M2100 ImageClear	42	16
HOWTEK MultiRAD 850	43,5	12
LUMISYS 200	50	12

Tabela 4.1: Typy i podstawowe parametry skanerów, zastosowanych do ucyfrowienia badań mammograficznych z DDSM.

#### 4.1.2 Własne obrazy

Własny zestaw zdjęć mammograficznych, zawierających interesujące przypadki zmian, został wybrany przez radiologów z Zakładu Diagnostyki Obrazowej Szpitala Wolskiego i Centrum Onkologii w Warszawie. Obrazy zostały ucyfrowione z rozdzielczością przestrzenną 45,5 mikrometrów oraz z 12-bitową głębią koloru. Obrazowane patologie zawierają przede wszystkim zmiany złośliwe, potwierdzone badaniem histopatologicznym.

#### 4.1.3 Ograniczenia testowych baz

W przypadku mikrozwapnień w zbiorach testowych nie były zaznaczone położenie i kształt pojedynczych obiektów, ale regiony, zawierające całe skupiska mikrozwapnień. Dla guzów był zaznaczony region guza wraz z jego sąsiedztwem (np. w przypadku guzów spikularnych z obszarem naciekania). Nie było dokładnie oznaczonych konturów zmian. Ponadto w zbiorze testowym było dużo ostrych i bardzo jasnych artefaktów oraz nieoznaczonych zmian łagodnych. Ograniczenia te stanowiły poważną trudność na etapie organizacji testów i analizy wyników.

## 4.2 Detekcja potencjalnych klastrów mikrozwapnień

### 4.2.1 Cel

Celem eksperymentów było badanie efektywności algorytmu detekcji klastrów potencjalnych mikrozwapnień, opisanego w p. 3.5.

Testy metody detekcji potencjalnych klastrów mikrozwapnień przebiegały dwu-etapowo: najpierw przeanalizowano możliwości metody ręcznie dobierając próg na etapie lokalizacji – wstępne testy, a następnie zaproponowano regułę automatycznego wyboru progu i zweryfikowano to rozwiązanie.

### 4.2.2 Testy wstępne detekcji półautomatycznej

Testy detekcji półautomatycznej przeprowadzona w dwóch turach: w pierwszej – podano ogólny wynik detekcji, w drugiej – dokładniej przeanalizowano metodę z zastosowaniem korekcji wskazań za pomocą prostych reguł.

#### Zestaw obrazów

Testy w pierwszej turze zostały przeprowadzone na 20 obrazach mammograficznych (ucyfrowionych z rozdzielczością 43,5 oraz 45,5 mikrometrów z 12-bitową głębią koloru) z DDSM oraz z własnej bazy. W drugiej turze eksperymentu użyto 58 obrazów mammograficznych (ucyfrowionych z rozdzielczością 43,5 oraz 50 mikrometrów z 12-bitową głębią koloru) z DDSM. Obrazy te to 29 przypadków (badań) z obrazami chorej piersi w dwóch projekcji.

Podczas testów wybrano regiony zainteresowania, zawierające rozległe obszary tkanki piersiowej, budzące szczególne podejrzenie raka (zawierające prawie cały obszar stożka gruczołowego, bez mięśnia oraz bez tkanki tłuszczowej, wiążącej gruczoł z klatką piersiową). Wymiary obrazów zawierających regiony zainteresowania to 1021-3275 na 1709-5381 pikseli, średnio – 2156 na 3308 pikseli. Powierzchnia analizowanych obszarów z wysegmentowaną tkanką (oddzieleniem tła obrazu) to: 4064,8-29651,4  $mm^2$ , średnio 14027,9  $mm^2$ .

W zbiorze testowym było dużo ostrych i bardzo jasnych artefaktów oraz nieoznaczonych zmian łagodnych. Te, które zostały wykryte podczas detekcji, zostały policzone jako fałszywie pozytywne klastry.

#### Realizacja eksperymentów

Próg metody detekcji na etapie lokalizacji pojedynczych obiektów był modyfikowany ręcznie (ustalenie największej wartości, która jest korzystna ze względu na relację wskazań prawdziwych do fałszywych).

Korekcję wskazań w drugiej turze eksperymentu uzyskano dzieląc pojedyncze wskazania na obiekty: punktowe, potencjalne mikrozwapnienia oraz większe obiekty (według opisu w p. 3.6.1), a następnie odrzucając większe obiekty oraz formując klastry zawierające co najmniej jeden obiekt potencjalnych mikrozwapnień (oraz ewentualnie uzupełniające wskazania punktowe).

Podczas przeprowadzania testów kontrolowano rozmiary klastrów, tak aby nie zajmowały zbyt dużego obszaru.

### Kryterium detekcji obiektów zainteresowania

**Prawdziwie pozytywne klastry mikrozwapnień** Klaster jest uznany za wskazanie prawdziwie pozytywne, jeśli spełnia wszystkie następujące warunki:

- jest klastrem, czyli zawiera co najmniej 3 pojedyncze obiekty skoncentrowane w obszarze co najwyżej  $1 \text{ cm}^2$ , według dostosowanego algorytmu DBSCAN,
- co najmniej 3 pojedyncze obiekty, należące do tego klastra, zawarte są w regionie chorobowym zaznaczonym przez lekarza (ROS),
- jego obszar (obszar otoczki wypukłej obiektów, należących do klastra) zajmuje co najmniej 0,2% powierzchni ROS,
- jego obszar jest nie większy niż powierzchnia ROS.

Jeśli wykryty klaster nie spełnia chociaż jednego z powyższych warunków, jest uznany za wskazanie fałszywie pozytywne.

**Fałszywie pozytywne klastry mikrozwapnień** Klaster fałszywie pozytywny (FP) to grupa co najmniej 3 obiektów, skoncentrowanych w obszarze co najwyżej  $1 \text{ cm}^2$  (wg dostosowanego algorytmu DBSCAN), położona poza obszarem chorobowym, zaznaczonym przez lekarza lub nie spełniających warunków klastra prawdziwie pozytywnego.

### Wyniki

W pierwszej turze bez korekcji wskazań czułość detekcji na obrazach wyniosła około 83% ze średnią liczbą 2 potencjalnych klastrów mikrozwapnień na obraz (FPI – liczba fałszywie pozytywnych wskazań na obraz). Wyniki eksperymentu w drugiej turze z zastosowaniem korekcji wskazań podano w tabelach: 4.2, 4.3 i 4.4. Powierzchnie wskazywanych klastrów wynosiły od  $1,5 \text{ mm}^2$  do  $45,1 \text{ mm}^2$ . Parametr w regule doboru progu w fazie lokalizacji (wzór 3.2) zmieniano w zakresie od 6,5 do 11, wartości progu zmieniały się wtedy od 83,2 do 177,2.

Przykład analizowanego regionu oraz wskazań klastrów prawdziwie pozytywnych i fałszywie pozytywnych są pokazane na rys. 4.1 i 4.2, przykłady fałszywie negatywnych wskazań – na rys. 4.3 i 4.4. Przykładowe wyniki detekcji klastrów i pojedynczych mikrozwapnień wewnątrz klastrów oraz efekty rekonstrukcji kształtów obiektów są na rysunkach: 4.5, 4.6 i 4.7.

#### 4.2. DETEKCJA POTENCJALNYCH KLASTRÓW MIKROZWAPNIENÍ

	Subtelność						
	1-5	1	2	3	4	5	2-5
	wszystkie	najsłabiej widoczne				najłatwiejsze	bez najtrudniejszych
Liczba obrazów	58	10	14	18	12	4	48
SE	87,9%	70,0%	85,7%	94,4%	91,7%	100%	91,7%
FPI	1,17	1,00	1,43	1,67	0,67	0,00	1,21
FPIwB	0,79	0,60	1,14	1,11	0,33	0,00	0,83
Liczba przypadków	29	5	7	9	6	2	24
SEC	96,6%	80,0%	100%	100%	100%	100%	100%


Tabela 4.2: Wyniki metody półautomatycznej detekcji potencjalnych klastrów mikrozwapnień na obrazach, zawierających mikrozwapnienia: rozkład dla zmian o różnej subtelności. Podano: czułość metody liczoną na obrazach (SE) i na badaniach (SEC – gdzie wskazanie oznaczone jest jako prawdziwie pozytywne, gdy metoda wskazuje klaster prawdziwie pozytywny w co najmniej jednej z dwóch projekcji) oraz średnią liczbę fałszywych wskazań klastrów na obraz (FPI) i średnią liczbę fałszywych wskazań klastrów na obraz (FPIwB) po odrzuceniu wskazań klastrów niepodejrzanych, oczywistych łagodnych, takich jak mikrozwapnienia naczyniowe itp.

Projekcja	CC	MLO
Liczba obrazów	29	29
SE	89,6%	86,2%
FPI	0,90	1,45
FPIwB	0,55	1,03

Tabela 4.3: Wyniki metody półautomatycznej detekcji potencjalnych klastrów mikrozwapnień na obrazach, zawierających mikrozwapnienia: rozkład dla różnych projekcji.


	Gęstość			
	1	2	3	4
	tłuszczowe			gęste
Liczba obrazów	6	14	12	26
SE	67%	100%	91,7%	84,6%
SEC	100%	100%	100%	92,3%
FPI	0,67	1,07	1,25	1,31
FPIwB	0,67	0,36	1,08	0,92

Tabela 4.4: Wyniki metody półautomatycznej detekcji potencjalnych klastrów mikrozwapnień na obrazach, zawierających mikrozwapnienia. Pokazano rozkład tej liczby w zależności od gęstości utkania gruczołu piersiowego: od 1 – mammogramy najłatwiejsze z utkaniem tłuszczowym poprzez 3 – mammogramy o zróżnicowanej gęstości, gruczołowo-tłuszczowe do 4 – bardzo gęste utkanie.




Rysunek 4.1: Przykładowy analizowany region tkanki piersiowej i wyniki detekcji (czerwone obrysy): patologia dobrze wykryta – klaster mikrozwapnień prawdziwie pozytywny (obrys lekarza zaznaczony zielonym kolorem) oraz klastry fałszywie pozytywne (fałszywe wskazania). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)


#### 4.2. DETEKCJA POTENCJALNYCH KLASTRÓW MIKROZWAPNIEŃ



Rysunek 4.2: Przykłady fałszywie pozytywne klastrow, wykrywanych metodą detekcji: po lewej – fragmenty obrazów mammograficznych (górny zawiera artefakty, dolny – zmiany w obrazowanej tkance), po prawej – na czerwono zostały zaznaczone kształty wykrytych klastrow. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)




Rysunek 4.3: Przykłady klastrow, których metoda detekcji nie wykrywa (wskazania fałszywie negatywne). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)




Rysunek 4.4: Przykład klastra mikrozwapnień (w dwóch projekcjach), którego metoda detekcji nie wykrywa. Na dole pokazano segmentację pojedynczych mikrozwapnień – wysegmentowano mniej niż 3 obiekty, co nie spełnia reguły tworzenia klastra. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)


#### 4.2. DETEKCYJA POTENCJALNYCH KLASTRÓW MIKROZWAPNIEŃ



Rysunek 4.5: Wykryty klaster złośliwych mikrozwapnień: (a) Oryginalny region, wskazany przez radiologa (zielony kontur). Czarna strzałka wskazuje mikrozwapnienie określone przez radiologa jako „o kształcie litery V”, sugerujące wysokie prawdopodobieństwo złośliwości całego klastra. (b) Wynik lokalizacji – białe kropki wskazujące pojedyncze obiekty. Średnica kropek w przybliżeniu odpowiada rozmiarom wykrywanych obiektów. (c) Kształty wykrytych mikrozwapnień (różowe kontury). Omawiane mikrozwapnienie „w kształcie litery V” zostało wysegmentowane jako 3 oddzielne obiekty z powodu nierównomiernej tekstury bardzo cienkich linii. (d) Kształt klastra. (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)



Rysunek 4.6: Detekcja klastrow mikrozwapnień: (a) Oryginalny region, wskazany przez radiologa (biały kontur). (b) Grupa równomiernie rozłożonych obiektów, zgrupowanych bez dołączania artefaktów. (c) Automatycznie wskazany kształt mikrozwapnień (czarne kontury). (d) Kształt całego klastra (czarny kontur). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)



Rysunek 4.7: Wskazanie fałszywie pozytywne: (a) Oryginalny region — artefakty, znajdujące się w pobliżu wyraźnego włókna. (b) Kształty wykrytych obiektów (czarne kontury). (c) Kształt fałszywie pozytywnego klastra (wzdłuż włókna). (Obraz źródłowy pochodzi z bazy DDSM [64]. Rysunek wykonany w systemie *MammoViewer*, opisanym w rozdziale 3.)

### 4.2.3 Testy detekcji automatycznej

W metodzie lokalizacji zaproponowano regułę doboru progu na podstawie odchylenia standardowego z obrazu (wysegmentowanego gruczołu piersiowego) po filtracji *LoG* w najniższej skali (wzór 3.2), przyjęto parametr  $n = 10$ .

#### Zestaw obrazów testowych

Testy zostały przeprowadzone na 36 trudnych badaniach mammograficznych (ucyfrowionych z rozdzielczością 43,5 oraz 50 mikrometrów z 12-bitową głębią koloru) z DDSM. Badania te zawierały 72 mammogramy z klastrami mikrozwapnień.

Dodatkowo liczbę fałszywych wskazań na obraz przetestowano na 20 prawidłowych badaniach (80 mammogramów) – normach bez żadnych podejrzanych zmian. Jednakże obrazy te zawierały czasem oczywiste mikrozwapnienia łagodne, takie jak np. naczyniowe.

Podobnie jak w testach półautomatycznych, w zbiorze testowym było dużo ostrych i bardzo jasnych artefaktów oraz nieoznaczonych zmian łagodnych. Te, które zostały wykryte podczas detekcji, zostały policzone jako fałszywie pozytywne klastry.

#### Wyniki

Wyniki testów przy tych samych parametrach algorytmu na całych obrazach mammograficznych, zawierających złośliwe mikrozwapnienia, przedstawiono w tabeli 4.5, rozkład dla różnych projekcji w tabeli 4.6. Liczbę wskazań potencjalnych klastrów mikrozwapnień na obraz na prawidłowych mammogramach pokazano w tabeli 4.7. Kryterium detekcji klastrów przyjęto takie samo, jak w fazie testów półautomatycznych. Około 1% wszystkich wykrytych klastrów miało powierzchnię powyżej  $2 \text{ cm}^2$ . W obrazach, zawierających mikrozwapnienia, takie klastry stanowiły 0,8% wszystkich wskazań, a w obrazach z badań prawidłowych stanowiły 2% wskazań. Klastry te zostały uznane za zbyt rozległe, zbyt rozlewające się. Założeniem detekcji była lokalność wskazań, dlatego też zostały one usunięte i nie podano ich w przedstawionych wynikach.

Wyniki detekcji bez oznaczania wskazań łagodnych mikrozwapnień jako fałszywie pozytywnych na zbiorze użytym w testach z radiologami pokazano w p. 4.4.5.

### 4.2.4 Analiza wyników

Metoda detekcji nie wykrywa szczególnie delikatnych mikrozwapnień, widocznych na mammogramach jako subtelne zmiany tekstury, w których często nie można wyodrębnić osobnych obiektów. Zwykle nie wykrywano także mikrozwapnienia, znajdujące się na tle mocno zarysowanych struktur, np. bardzo wyraźnych włókien o dużym lokalnym kontraście.

Zdarza się, że w badaniu mammograficznym mikrozwapnienia widać lepiej w jednej projekcji, a w drugiej są one prawie niewidoczne. Zwykle w takich przy-

	Subtelność					
	1-5	1	2	3	4-5	2-5
	wszystkie	najsłabiej widoczne			naj- łatwiejsze	bez najtrudniejszych
Liczba obrazów	72	12	28	26	6	60
SE	68,1%	33,3%	64,3%	80,8%	100%	75,0%
FPI	2,62	3,00	3,14	1,23	5,50	2,55
Liczba przypadków	36	6	14	13	3	30
SEC	80,6%	50,0%	78,6%	92,3%	100,0%	86,7%

Tabela 4.5: Wyniki metody automatycznej detekcji potencjalnych klastrów mikrozwapnień na obrazach, zawierających mikrozwapnienia: rozkład dla zmian o różnej subtelności.

Projekcja	CC	MLO
Liczba obrazów	36	36
SE	72,2%	63,9%
FPI	3,05	2,19

Tabela 4.6: Wyniki metody automatycznej detekcji potencjalnych klastrów mikrozwapnień na obrazach, zawierających mikrozwapnienia: rozkład dla różnych projekcji.

normy	Gęstość				
	1-4	1	2	3	4
	wszystkie	tłuszczowe			gęste
Liczba obrazów	80	4	12	32	32
FPI	1,66	0,00	0,83	2,28	1,56

Tabela 4.7: Liczba fałszywych wskazań – wskazania potencjalnych klastrów mikrozwapnień na prawidłowych badaniach (zdrowych). Pokazano rozkład tej liczby w zależności od gęstości utkania gruczołu piersiowego: od 1 – mammogramy najłatwiejsze z utkaniem tłuszczowym poprzez 3 – mammogramy o zróżnicowanej gęstości, gruczołowo-tłuszczowe do 4 – bardzo gęste utkanie.

## 4.2. DETEKcja POTENCJALNYCH KLASTRÓw MIKROZWAPNIEN

padkach lekarze radiolodzy zauważają mikrozwapnienia w jednej projekcji, natomiast w drugiej starają się ich doszukać, choć często nie są to już określone obiekty mikrozwapnień, ale zmiany tekstury. Dlatego też pokazano wyniki czułości algorytmu dla badań zawierających każdy klaster w dwóch projekcjach. Tutaj wyniki metody automatycznej wykazują ponad 85% czułość poza badaniami, zawierającymi najtrudniejsze zmiany – najbardziej subtelne m.in. zawierające bardzo mało obiektów (niektóre poniżej 3 mikrozwapnień). Radiolog Specjalista w czasie konsultacji zasugerował, że takie obrazy mogą pochodzić z bardzo wczesnych badań, na których nie zauważono zmian, a dopiero w późniejszych latach – na kolejnych badaniach zauważono bardziej zaawansowanego, widocznego raka i dołączono do bazy te poprzednie bardzo wczesne obrazy.

Niższe wartości czułości oraz liczby FPI na projekcjach MLO mogą wynikać z faktu, że obliczanie wartości progu w fazie lokalizacji odbywa się na obszarze gruczołu oraz mięśnia. Dla poprawy efektywności metody w projekcji MLO należałoby zastosować segmentację mięśnia albo niższe parametry ustawienia progu.

Liczba FPI na mammogramach, zawierających mikrozwapnienia, wynosi 2,62. Zakładając, że w tych obrazach znajduje się procentowo tyle samo oczywistych mikrozwapnień łagodnych, co w teście półautomatycznym, liczba FPIwB wynosiłaby 1,77. Najbardziej wiarygodne dane, dotyczące wskazań fałszywych, można uzyskać na obrazach, pochodzących ze zdrowych – prawidłowych badań. Najwięcej takich wskazań zostaje zaznaczonych na mammogramach o zróżnicowanej gęstości (utkanie gruczołowo-tłuszczowe), na mammogramach piersi o innej budowie liczba wskazań wynosi poniżej 1,6. W podanych wynikach liczby fałszywych wskazań dodano wskazania zmian łagodnych (niepodejrzanych) oraz wskazania znajdujące się w obszarze mięśnia na obrazach w projekcji MLO. Wskazania fałszywe znajdujące się w obszarze tkanki i niebędące zmianami łagodnymi – to przede wszystkim przejaśnienia we włóknach, niesprawiające lekarzowi radiologowi trudności przy weryfikacji. Ocena wykrytych fałszywych wskazań, ich licznosc z wyłączeniem wskazań poza obszarem gruczołu oraz bez wskazań łagodnych została podana na zbiorze obrazów testowanych w fazie testów klinicznych w p. 4.4.5.

Ważnym ulepszeniem algorytmu jest opracowanie automatycznej metody regulacji wartości progu w fazie lokalizacji. Testowano regułę zależności progu od odchylenia standardowego z obszaru tkanki (gruczołu piersiowego). Jednakże w mammogramach zawierających obszary o zróżnicowanym utkaniu (różnej jasności) metoda ta daje bardzo wiele fałszywych wskazań, np. jasnych włókien bardzo mocno zarysowanych w ciemniejszych obszarach. W przypadku tego typu obrazów o mocno zróżnicowanej gęstości zdarzały się także duże klastry (o powierzchni powyżej  $1,7 \text{ mm}^2$ ), które zostały usunięte z analizy. Na mammogramach o jednorodnym utkaniu metoda ta osiągnęła większą skuteczność. Dlatego też należałoby uzależnić próg w fazie lokalizacji od: lokalnych statystyk (gęstości tkanki), lokalnego kontrastu (np. statystyk w obrazie po filtracji *LoG*) i struktury tekstury (kompozycji tkanki) w sąsiedztwie lokalizowanych obiektów. Innym pomysłem jest wyznaczenie obszarów o jednorodnym utkaniu, a później wyznaczenie innego progu na każdym z obszarów.

Zasadność powyższych pomysłów potwierdzają wyniki testów półautomatycz-

nych z ręcznym doбором progu na obszarach o jednorodnym utkaniu. Wyniki te wykazują wysoką czułość metody – blisko 88%, a na przypadkach blisko 97% – oraz małą liczbę fałszywych wskazań na obraz – poniżej 1,2, a po usunięciu oczywistych zmian łagodnych poniżej 0,8. Czułość metody dla obrazów z wyłączeniem badań najtrudniejszych (o subtelności 1) wynosi blisko 92%, natomiast liczona na badaniach (SEC) – 100%.


Klasyfikacja (pojedynczych potencjalnych mikrozwapnień oraz klastrów) w celu redukcji wskazań włókien oraz oczywistych mikrozwapnień łagodnych (np. naczyń, bez podejrzenia) może zmniejszyć liczbę fałszywych wskazań, co potwierdzają wyniki testu półautomatycznego po usunięciu zmian łagodnych. Próby klasyfikacji, m.in. w celu redukcji nadmiarowych obiektów, opisano w p. 4.3.

#### **4.2.5 Test detekcji na obrazach po stratnej kompresji – wyniki**


Przeprowadzono testy na 24 obrazach. Do kompresji obrazów użyto stratnej falkowej kompresji z różną średnią liczbą bitów na piksel [122]. Przykładowy obraz oraz wyniki detekcji przedstawiono na rys. 4.8 i 4.9. Uzyskano mniej fałszywych wskazań na kompresowanych mammogramach (ze średnią bitową 0,3 i 0,4) przy takiej samej czułości.

Kompresję można traktować jako rodzaj filtracji, która przy odpowiednim nasileniu poprawiła stosunek wskazań prawdziwych do fałszywych. Wykorzystano ten fakt, proponując metody poprawy percepcji bazujące na falkach.

#### 4.2. DETEKCJA POTENCJALNYCH KLASTRÓW MIKROZWAPNIEŃ



Rysunek 4.8: Przykładowy wynik detekcji – wskazane prawdziwie pozytywne (czerwone) i fałszywie pozytywne (niebieskie) klastry mikrozwapnień: po lewej wynik na obrazie oryginalnym, po prawej – na obrazie kompresowanym.



Rysunek 4.9: Średnia wydajność (stosunek wskazań prawdziwie pozytywnych do wszystkich wskazań ogółem) detekcji dla zredukowanych średnich bitów na piksel.

## 4.3 Klasyfikacja mikrozwapnień

### 4.3.1 Testy wstępne

#### Cel

Celem eksperymentu jest badanie możliwości oceny pojedynczych obiektów zainteresowania – wysegmentowanych metodą PWTH, opisaną w p. 3.5.3 pod kątem opisu potencjalnych mikrozwapnień — klasyfikacja: potencjalne mikrozwapnienie-norma (prawidłowa tkanka) — oraz pod kątem diagnozy — klasyfikacja zmian na łagodne i złośliwe.

#### Realizacja eksperymentu

Do uczenia i testowania sieci neuronowej użyto zbioru 35 regionów zainteresowania, pochodzących z 35 cyfrowych obrazów mammograficznych z bazy DDSM, na których są uwidocznione mikrozwapnienia różniące się swoim typem i widocznością. Baza zawierała około 500 obiektów wysegmentowanych metodą PWTH. Zbiory uczący i testujący były rozłączne.

Przeprowadzono testy, dotyczące trzech rodzajów sieci:

- POTENCJALNE MIKROZWAPNIENIE / NORMA: Sieć określa, czy obiekty wejściowe są potencjalnymi mikrozwapnieniami, czy fragmentem struktury zdrowej tkanki (opis potencjalnych mikrozwapnień).
- ŁAGODNE / ZŁOŚLIWE: Sieć sugeruje diagnozę dla potencjalnych mikrozwapnień (diagnoza).
- ŁAGODNE / ZŁOŚLIWE / NORMA: Sieć ma za zadanie podział obiektów na trzy grupy: norma (zdrowa tkanka), łagodne, złośliwe (opis potencjalnych mikrozwapnień + diagnoza).

Użyto klasyfikatora sztucznej sieci neuronowej jednokierunkowej, z algorytmem ucącym propagacji wstecznej.

#### Wyniki

Uzyskane wyniki klasyfikacji na zbiorze testowym dla obiektów wykrytych automatycznie (z zastosowaniem właściwości opisanych w tab. 3.12) przedstawiono w tabeli 4.8, a rozkład niepoprawnych klasyfikacji — w tabeli 4.9.

#### Wnioski

Z powyższych rezultatów wynika, że opracowana metoda segmentacji PWTH i klasyfikacji mikrozwapnień na testowym zbiorze mammogramów pozwala uzyskać wysoką skuteczność opisu potencjalnych mikrozwapnień (93%). Niższą skuteczność zaobserwowano dla diagnozy obiektów. Wydaje się, że skuteczniejsze w ocenie charakteru mikrozwapnień będą metody segmentacji z bardziej wygładzonym kształtem, możliwie najwierniej oddające sposób postrzegania radiologa. Automatyczna diagnoza jest zadaniem trudnym, powinna zawierać bardziej

#### 4.3. KLASYFIKACJA MIKROZWAPNIENÍ

Rodzaj wyniku	Najwyższa skuteczność klasyfikacji na zbiorze testowym
POTENCJALNE MIKROZWAPNIENIE / NORMA	93%
ŁAGODNE / ZŁOŚLIWE	83%
ŁAGODNE / ZŁOŚLIWE / NORMA	70%

Tabela 4.8: Uzyskane wyniki klasyfikacji na zbiorze testowym przy zastosowaniu sieci neuronowej. Skuteczność oznacza tutaj: dokładność, % trafnych klasyfikacji.

Referencyjna diagnoza obiektu	Diagnoza sieci neuronowej	Złe odpowiedzi (procentowo)
POTENCJALNE MIKROZWAPNIENIA / NORMA		
Mikrozwapnienie	Norma	65%
Norma	Mikrozwapnienie	35%
sieć: ŁAGODNE / ZŁOŚLIWE		
Złośliwe	Łagodne	77%
Łagodne	Złośliwe	23%
sieć: ŁAGODNE / ZŁOŚLIWE / NORMA		
Złośliwe	Łagodne	35%
Złośliwe	Norma	22%
Łagodne	Złośliwe	15%
Łagodne	Norma	14%
Norma	Złośliwe	8%
Norma	Łagodne	6%

Tabela 4.9: Rozkład niepoprawnych klasyfikacji sieci neuronowej.

złożone reguły dotyczące oceny kształtów pojedynczych mikrozwapnień – charakterystycznych dla klastra – oraz ocenę stopnia niejednorodności klastra. Opis przykładowych reguł zamieszczono w p. 3.6.2. Poza wnikliwą analizą mammogramów, diagnoza powinna brać pod uwagę także dodatkowe dane, takie jak: dane wywiadu, wyniki dodatkowych badań (także innych modalności).

#### 4.3.2 Zasadnicze testy weryfikacyjne

##### Cel

Celem eksperymentu jest badanie możliwości oceny pojedynczych obiektów zainteresowania, wysegmentowanych metodą LS (opisaną w p. 3.5.3) pod kątem:

**test PMN:** opisu potencjalnych mikrozwapnień — klasyfikacji: potencjalne mikrozwapnienie-norma (prawidłowa tkanka),

**test K:** klasyfikacji kształtów pojedynczych mikrozwapnień — różnicowania klas

typowych mikrozwapnień: ziarnistych (pleomorficznych), liniowych, okrągłych.<sup>1</sup> Kształty są głównym kryterium oceny morfologii mikrozwapnień przez radiologów.<sup>2</sup> Z analizy wyłączono mikrozwapnienia o kształtach amorficznych, czyli bezkształtne. Praktycznie nie jest możliwa ich segmentacji i określenie kształtu, a jedynie określenie pewnych zmian tekstury (przykład na rys. 4.4), do czego potrzebna jest inna metoda detekcji mikrozwapnień.

## Materiał

Do uczenia i testowania klasyfikatorów użyto obiektów, wysegmentowanych metodą LS, ze zbioru około 80 cyfrowych obrazów mammograficznych z bazy DDSM, na których były uwidocznione mikrozwapnienia, różniące się swoim typem i widocznością. Materiał do klasyfikacji został przedstawiony w tabelach: test PMN — 4.10, test K — 4.11. Zbiory uczący i testowy były rozłączne.

Typ obiektów	Liczba obiektów	Opis
Mikrozwapnienia	371	obiekty pochodzące z klastrów złożonych i łagodnych mikrozwapnień
Fragmenty włókien (norma)	148	fragmenty włókien i ich skrzyżowań
Fragmenty tekstury (norma)	228	„granulacja” tekstury prawidłowej tkanki i oczywiste łagodne zwapnienia, takie jak: naczyniowe, dysplastyczne
Razem	747	

Tabela 4.10: Materiał do klasyfikacji — opisu potencjalnych mikrozwapnień (test PMN).

## Realizacja eksperymentu

Test PMN dotyczył opisu potencjalnych mikrozwapnień, czyli klasyfikator miał określić, czy obiekty wejściowe są potencjalnymi mikrozwapnieniami, czy fragmentem struktury prawidłowej tkanki. Natomiast test K dotyczył różnicowania klas typowych mikrozwapnień. Porównywano parami klasy mikrozwapnień: ziarniste-okrągłe, okrągłe-liniowe i okrągłe-ziarniste. Użyto klasyfikatorów sztucznej sieci neuronowej jednokierunkowej, z algorytmem uczącym propagacji wstecznej (SNN), klasyfikacji najbliższego sąsiada (1-NN) oraz maszyny wektorów nośnych (SVM) z jądrem liniowym, wielomianowym i RBF. W czasie testu dokonywano także selekcji właściwości na podstawie zbioru cech wyekstrahowanych numerycznymi metodami opisu właściwości zdefiniowanymi w dokumentacji systemu *MammoViewer* w załączniku E). W teście PMN wybierano ze zbioru 125 właściwości tekstury i kształtu, natomiast w teście K – ze zbioru 41 właściwości

<sup>1</sup>Praca wspólna z Teresą Podsiadły-Marczykowską.

<sup>2</sup>Bardziej rozbudowany opis kryteriów oceny klastrów mikrozwapnień zamieszczono w p. 3.6.2.

#### 4.3. KLASYFIKACJA MIKROZWAPNIENÍ

Typ obiektów mikrozwapnień	Liczba obiektów	Typowe — regularne	Nieco nieregularne
Ziarniste (pleomorficzne)	120	120 — typowe tzn. podobne do zaokrąglonych trójkątów, trapezów lub pięciokątów, wydłużone — „gruba elipsa”	0
Liniowe	119	90 — typowe tzn. trochę pofalowany pasek o zmiennej grubości, bez rozgałęzień	29 — jak typowe tylko lekko rozgałęzione
Okrągłe	120	120 — trochę zdeformowane okręgi lub owale	0
Razem	359		

Tabela 4.11: Materiał do klasyfikacji kształtów pojedynczych mikrozwapnień (test K). Wszystkie obiekty pochodziły z klastrow złośliwych mikrozwapnień.

kształtu. Zastosowano metody selekcji: *simba* (SIM), *infogain* (INFOG), *corrcoef* (CORR), *logratio* (LOGRAT) i *relief* (REL), opisane w [54]. Do sprawdzenia klasyfikatorów: SVM i 1-NN oraz selekcji właściwości użyto oprogramowania *Feature Selection Tool*, działającego w środowisku *Matlab* [54].

#### Wyniki

**Test PMN** Uzyskane wyniki dla różnych klasyfikatorów na zbiorze testowym dla obiektów wykrytych automatycznie przedstawiono w tabeli 4.12. Klasyfikatory osiągały najwyższą skuteczność na zbiorze 10 wybranych właściwości. Właściwości te oraz odpowiadające im numeryczne metody opisu wybrane za pomocą metod automatycznej selekcji przedstawiono w tabeli 4.13. Wykresy skuteczności maszyny wektorów nośnych z różnymi jądrami oraz 1-NN dla różnej liczby właściwości wyselekcjonowanych różnymi metodami przedstawiono w załączniku D.

Klasyfikator	Skuteczność
SVM jądro — liniowe	89%
SVM jądro — wielomianowe	89%
SVM jądro — RBF	85,5%
1-NN	86,5% (88% dla 20 cech)
SNN	87%

Tabela 4.12: Najwyższa skuteczność testowanych klasyfikatorów w zastosowaniu do zagadnienia opisu potencjalnych mikrozwapnień. Skuteczność oznacza tutaj: dokładność, procent trafnych klasyfikacji.

Lp.	CORR	INFOG	REL	SIM
1	FBD	FBD	EFR3	LoGR
2	LoGR	ESM	FBD	ESM
3	ESM	ELD1	LoGR	FBD
4	SM3	LoGR	ESM	TR
5	SM1	IM0	RG2	ELD1
6	DR	TR	FBR	DR
7	FBR	SM1	DR	FBR
8	MX	IM1	BIM1	EE
9	EE	SM3	IM0	MX
10	IM0	BIM0	M-DIAM	RC

Tabela 4.13: Zbiór właściwości kształtu i tekstury wybranych automatycznymi metodami selekcji. Wybrane metody numerycznego opisu właściwości zastosowano do klasyfikacji – opisu potencjalnych mikrozwapnień. Podano zestawy, za pomocą których klasyfikator osiągnął najwyższe skuteczności.

Skróty w tabeli oznaczają: FBD — różnica poziomów szarości obiektu i tła, EFR3 — efektywny promień, LoGR — odpowiedź filtru  $LoG$  z metody lokalizacji, ESM — średnia siła krawędzi, ELD1 — stopień eliptyczności, SM3 — moment kształtu 3, SM1 — moment kształtu 1, RG2 — „chropowatość” konturu, DR — skonstrastowanie obiektu i tła, TR — trójkątność, FBR — stosunek średniego poziomu szarości obiektu i tła, MX — średni poziom szarości, IM1 — moment niezmienniczy 1, EE — energia, IM0 — moment niezmienniczy 0, BIM0 — moment niezmienniczy 0 z obrazu binarnego, M-DIAM — maksymalna średnica, RC — względny kontrast – stosunek średniego poziomu szarości wzdłuż konturu do wartości najjaśniejszego piksela obiektu.

**Test K** Uzyskane wyniki dla najbardziej efektywnego klasyfikatora — SVM z jądrem RBF — na zbiorze testowym dla wykrytych automatycznie obiektów typowych mikrozwapnień przedstawiono w tabeli 4.14. Właściwości oraz odpowiadające im numeryczne metody opisu wybrane za pomocą metod automatycznej selekcji pokazano w tabeli 4.15. Wykresy skuteczności SVM dla różnej liczby właściwości wyselekcjonowanych różnymi metodami oraz przedstawiono w załączniku D. Rozrzut cech dla wybranych właściwości pokazano na rysunkach 4.10 i 4.11.

## Wnioski

Z powyższych rezultatów wynika, że opracowana metoda detekcji i klasyfikacji mikrozwapnień na testowym zbiorze mammogramów pozwala uzyskać znaczącą skuteczność rozróżnienia pojedynczych obiektów mikrozwapnień od prawidłowej tkanki (blisko 90%). Lepsze wyniki prawdopodobnie dawałoby rozróżnienie łagodnych oczywistych zwapnień od normy, czyli podział na grupy: mikrozwapnienia + zwapnienia oczywiste łagodne oraz prawidłowa tkanka, taka jak włókna i zmiany tekstury. Ponadto klasyfikacja na poziomie klastrów mikrozwapnień lub fałszywych wskazań klastrów także mogłaby zwiększyć efektywność weryfikacji wskazań potencjalnych klastrów mikrozwapnień, a więc zmniejszyć liczbę fałszywych wskazań.

#### 4.3. KLASYFIKACJA MIKROZWAPNIENÍ


Rodzaj wyniku klasyfikacji	Metoda selekcji właściwości	Najwyższa skuteczność
LINIOWE / ZIARNISTE	CORR	98%
	SIM	94%
	INFOG	94%
LINIOWE / OKRĄGLE	SIM	100%
	CORR	100%
ZIARNISTE / OKRĄGLE	LOGRAT	94%
	SIM	94%
	REL	94%

Tabela 4.14: Najwyższa skuteczność SVM (z jądrem RBF) użytej do klasyfikacji kształtów pojedynczych mikrozwapnień. Skuteczność oznacza tutaj: dokładność, procent trafnych klasyfikacji.

Rodzaj wyniku klasyfikacji	Lp.	CORR	INFOG	REL	SIM	LOGRAT
LINIOWE / ZIARNISTE	1	SM1	CM-IP	—	SM1	—
	2	SM3	(OP)	—	(M-DIAM)	—
	3	(CM-OP)	(CM-OP)	—	(SM3)	—
	4	(M-DIAM)	(M-DIAM)	—	(SM4)	—
LINIOWE / OKRĄGLE	1	SM1	—	—	SM3	—
	2	(SM3)	—	—	(SM1)	—
	3	(M-DIAM)	—	—	(BEFR2)	—
	4	(CM-IP)	—	—	(M-DIAM)	—
ZIARNISTE / OKRĄGLE	1	—	—	BELD1	BELD1	BELD1
	2	—	—	EFR3	BIM2	CM-IP
	3	—	—	IM0	IM0	IM2
	4	—	—	BIM2	AR	BIM3

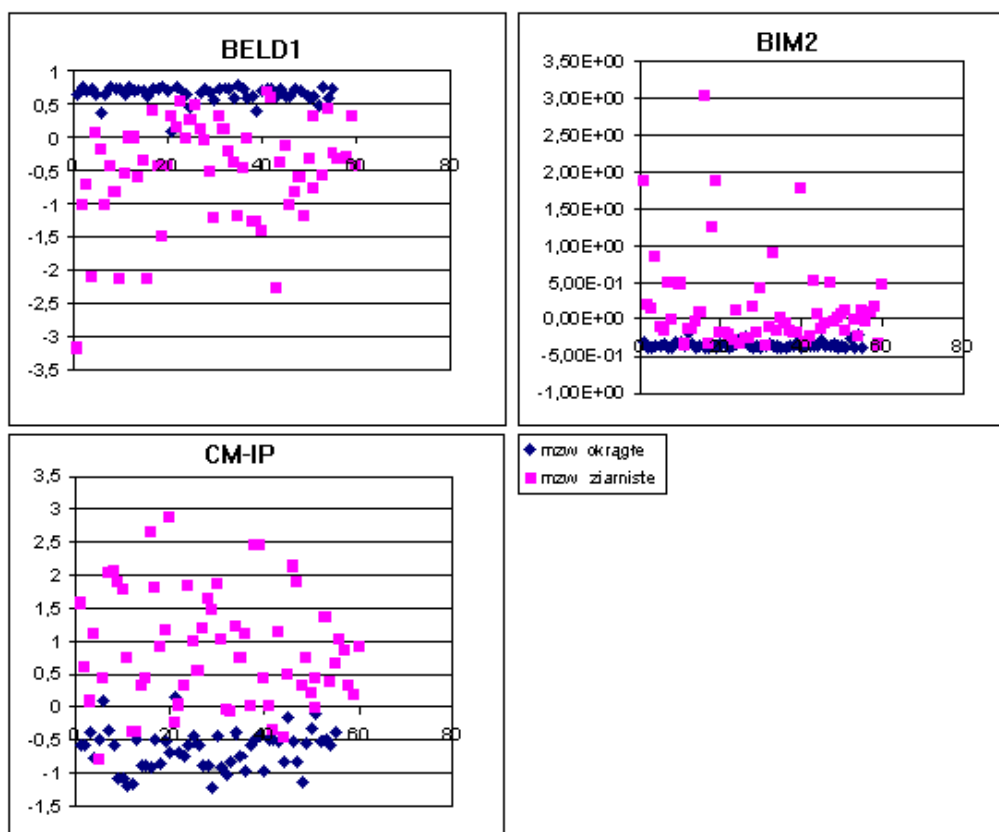
Tabela 4.15: Zbiór właściwości kształtu wybranych automatycznymi metodami selekcji. Wybrane metody numerycznego opisu właściwości zastosowano do klasyfikacji kształtów pojedynczych mikrozwapnień. Podano po 4 właściwości dla każdej metody selekcji. Bez nawiasów podano właściwości, za pomocą których klasyfikator osiągnął najwyższe skuteczności, natomiast w nawiasach podano uzupełnienie do zbioru czterech wartości.

Skróty w tabeli oznaczają: SM1, SM3, SM4 — momenty kształtu 1, 3 i 4, CM-IP — zawartość wewnętrzna, CM-OP — zawartość zewnętrzna, OP — obwód zewnętrzny, AR — powierzchnia, EFR3 — efektywny promień, BEFR2 — efektywny promień z obrazu binarnego, BELD1 — stopień eliptyczności liczony na obrazie binarnym, IM0, IM2 — momenty niezmiennicze 0 i 2, BIM2, BIM3 — momenty niezmiennicze 2 i 3 z obrazu binarnego, M-DIAM — maksymalna średnica.



Rysunek 4.10: Rozrzut cech na zbiorze testowym dla mikrozapnień liniowych (oznaczonych kolorem granatowym) i ziarnistych (kolor różowy). Oś X — numer obiektu w zbiorze testowym, oś Y — znormalizowana wartość cechy dla obiektu o danym numerze. Normalizacja wykonana na podstawie średnich i odchyłeń standardowych ze zbioru uczącego. Właściwości SM1, SM3, CM-IP oraz M-DIAM wykazały najlepsze różnicowanie w testach automatycznych.

#### 4.3. KLASYFIKACJA MIKROZWAPNIENÍ



Rysunek 4.11: Rozrzut cech na zbiorze testowym dla mikrozwapnień okrągłych (oznaczonych kolorem granatowym) i ziarnistych (kolor różowy). Oś X — numer obiektu w zbiorze testowym, oś Y — znormalizowana wartość cechy dla obiektu o danym numerze. Normalizacja wykonana na podstawie średnich i odchyłeń standardowych ze zbioru uczącego. Właściwości BELD1, CM-IP oraz BIM2 wykazały najlepsze różnicowanie w testach automatycznych.

W zakresie klasyfikacji kształtów mikrozwapnień słuszne wydaje się wykorzystywanie metody segmentacji, zgodnej z percepcją radiologa. Przykładem może być zastosowana metoda LS, mocno wygładzająca kształty mikrozwapnień. Typowe mikrozwapnienia należące do trzech klas — ziarnistych, liniowych i okrągłych — znacznie różnią się kształtem, stąd wysoka skuteczność klasyfikatora: od 94% do 100%. Na dalszym etapie badań należy uwzględnić grupę nieregularnych mikrozwapnień lub też metodę selekcji typowych kształtów dla klastrów.

## 4.4 Testy kliniczne wpływu wspomaganie komputerowego na detekcję i diagnozę radiologów

### 4.4.1 Cel

Celem eksperymentów jest badanie wpływu zaproponowanej metody poprawy jakości obrazów mammograficznych i percepcji zmian patologicznych (opisanej w p. 3.3) oraz automatycznej metody detekcji potencjalnych klastrów mikrozwapnień (opisanej w p. 3.5) na detekcję zmian patologicznych i diagnozę radiologów. Testy przeprowadzono na zbiorze trudnych badań mammograficznych.

### 4.4.2 Zestaw obrazów testowych

Procedura redukcji zbioru badań testowych składała się z trzech etapów. Do testów wstępnie zostało wybranych 150 badań mammograficznych (każde zawierało 4 obrazy: prawa i lewa pierś, projekcje CC i MLO) w przeważającej liczbie o dużej gęstości utkania oraz o niskiej subtelności zmian (najtrudniejszej diagnostycznie). Badania zostały wybrane z bazy DDSM (opisanej w 4.1), przy wyborze opierano się na opisach dostępnych w bazie. Były to badania o dużej gęstości i subtelności zmian poniżej 3. Obrazy zostały ucyfrowione z 12-bitową głębią koloru.

Następnie w tym zbiorze badań przeprowadzono wstępne testy z lekarzem radiologiem Specjalistą (opis obserwatorów w p. 4.4.3). Na podstawie weryfikacji diagnozy tego lekarza (odniesienia do informacji z bazy DDSM) oraz po odrzuceniu badań technicznie źle wykonanych (np. zawinięta skóra, źle wypozycjonowane), do dalszych testów wybrano 80 najtrudniejszych badań. Zestaw ten zawierał 20 badań prawidłowych (zdrowych) oraz 60 badań ze zmianami złośliwymi, które były trudne do wykrycia (trudność detekcji) lub o cechach podobnych do zmian łagodnych (trudność interpretacji – rozróżnienia pomiędzy zmianą złośliwą a łagodną). W pierwszej turze na obrazach oryginalnych lekarze obejrzeliby wszystkie te badania.

W drugiej turze testów wybrane badania zredukowano do 51 przypadków. (Główną przyczyną były ograniczenia finansowe.) Ze zbioru 80 badań odrzucono: 7 przypadków uznanych za zbyt łatwe, 4 przypadki uznane za zbyt trudne, resztę odrzuconych badań stanowiły przypadki pośrednie. Za zbyt łatwe zostały uznane przypadki wykryte w pierwszej turze testów przez wszystkich radiologów, biorących udział w teście. Za zbyt trudne uznano przypadki o gęstym utkaniu, których nie zauważyli wszyscy radiolodzy w pierwszej turze testów. Budziły one przypuszczenie, że są praktycznie niemożliwe do zauważenia, a do prawidłowego ich zdiagnozowania (wykrycia) w klinice wymagają dodatkowych badań. Dalsze opracowanie wyników dotyczy tych ostatecznie wybranych 51 badań.

Zestaw testowy był zbiorem trudnych badań, z przewagą zmian bardzo subtelnych oraz o dużej gęstości utkania. Rozkład gęstości utkania obrazowanych piersi oraz subtelności (widoczności) zmian są przedstawione w tabelach 4.16 i 4.17, histogramy pokazano na rys. 4.12 i 4.13.

#### 4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW

##### Opis rodzajów badań testowych

Badania prawidłowe (zdrowe) w bazie DDSM uznano za takie, w których nie stwierdzono żadnych podejrzanych zmian, wymagających dalszej diagnostyki (np. USG, biopsji itd.) i które były uznawane za normalne (prawidłowe) przez kolejne cztery lata. Stąd wynika, że badania prawidłowe mogły zawierać zmiany łagodne, uznane za niepodejrzane.

Badania ze zmianami złośliwymi (z katalogów „cancer” z bazy DDSM) pochodzą z badań skriningowych, w których został znaleziony przynajmniej jeden rak (udowodniony przez badanie histopatologiczne). W bazie DDSM jest informacja, że mała część badań z rakami może zawierać dodatkowo regiony podejrzane, ale niepotwierdzone badaniem histopatologicznym, które nie są oznaczone w bazie.

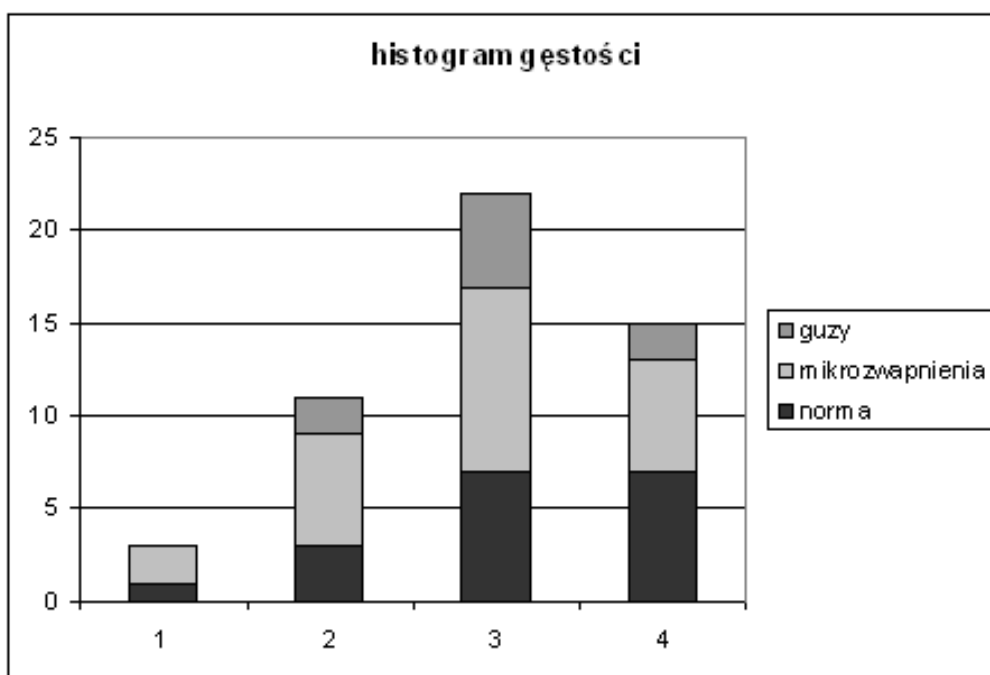
Ograniczenia bazy DDSM, wynikające z braku opisu zmian, które radiolodzy mogli uznać za podejrzane, stanowiły poważną trudność na etapie interpretacji wyników testów. Problemy związane z tymi ograniczeniami opisano w 4.4.5.

Gęstość utkania	Liczba badań			
	normy	guzy	mikrozwapnienia	sumarycznie wszystkie badania
tłuszczowe – 1	1	0	2	3
tłuszczowo-gruczołowe – 2	3	2	6	11
gruczołowo-tłuszczowe – 3	7	5	10	22
gęste utkanie gruczołowe – 4	7	2	6	15
Średnia gęstość	3,1	3	2,83	2,96


Tabela 4.16: Testowe badania: reprezentowane kategorie – zdrowe-norma, zawierające guzy i zawierające mikrozwapnienia – oraz rozkład gęstości utkania.

Subtelność	Liczba badań		
	guzy	mikrozwapnienia	sumarycznie zmiany
1	2	4	6
2	0	10	10
2.5	3	0	3
3	3	9	12
4	1	1	2
5	0	0	0
Średnia subtelność	2,5	2,29	2,35

Tabela 4.17: Zmiany patologiczne, znajdujące się w testowych badaniach – rozkład subtelności w skali 1 – najtrudniejsze do 5 – oczywiste zmiany. W trzech przypadkach subtelność zmian (guzów) różniła się w dwóch projekcjach – podano średnie z tych wartości.



Rysunek 4.12: Histogram gęstości utkania w testowych badaniach mammograficznych (1 – tłuszczowe do 4 – gęste utkanie gruczołowe).



Rysunek 4.13: Histogram subtelności zmian w zbiorze badań testowych (1 – najtrudniejsze, bardzo słabo widoczne do 5 – oczywiste zmiany). W trzech przypadkach zmiany (guzy) miały różne subtelności w dwóch projekcjach – podano wartości średnie.

#### 4.4.3 Obserwatorzy – lekarze radiolodzy

W teście wzięło udział trzech radiologów o różnym stopniu doświadczenia:

**Sta** radiolog stażysta, rozpoczynający naukę diagnozowania mammografii (2 miesiące praktyki w mammografii), w pracy na co dzień diagnozujący obrazy płuc,

**Spe** radiolog specjalista o pośrednim poziomie doświadczenia (10 lat w mammografii), ale praktyce w diagnozowaniu różnego typu badań cyfrowych, w skryningu różnych narządów (z przyswojoną umiejętnością obsługi programów do analizy obrazów),

**Eks** radiolog z 20-letnim doświadczeniem w mammografii analogowej, ekspert o uznanej renomie.

#### 4.4.4 Procedura testu

##### Test detekcji

W pierwszej turze lekarze diagnozowali badania oryginalne (bez przetwarzania) za pomocą systemu *Mammo Viewer*, używając go jako przeglądarki medycznej (monitora medycznego) z dostępnymi opcjami: ustawiania profilów (zakresu widzianych wartości), zmniejszania i powiększania zmian, wymiarowania struktur, itp.

W drugiej turze – główny test – (3 miesiące po pierwszej) lekarze diagnozowali kolejno:

- 1) obrazy oryginalne,
- 2) przetworzone (z możliwością weryfikacji zauważonych zmian na oryginałach),
- 3) oceniali (weryfikowali) automatyczne wskazania potencjalnych klastrów mikrozwapnień (AWPKM). Na obrazie były pokazywane tylko kwadratowe symbole, znajdujące się w centroidzie wykrytego klastra (jak na rysunku 4.14). Lekarze zostali poinformowani, że wskazania mają pokazywać potencjalne klastry mikrozwapnień, ale metoda wskazuje także nadmiarowe obiekty. Ich zadaniem było powiększenie każdego zaznaczonego obszaru i jego ocena pod kątem obecności mikrozwapnień. Na tym etapie radiolodzy nie wycofywali się z poprzednio zaznaczonych zmian, ale ewentualnie dodawali nowe wskazania – uznane za podejrzane klastry mikrozwapnień.

W drugiej turze za każdym razem lekarze mieli możliwość używania, podobnie jak w pierwszej turze, opcji przeglądarki medycznej.

Za każdym razem radiolodzy wyrażali swoją opinię, używając skali oceny detekcji (skala 1-5, wyrażająca pewność detekcji patologii – tab. 2.2), a jeśli zauważyli jakąś zmianę patologiczną (ocena detekcji większa od 1), określali jej położenie na mammogramach (strona prawa lub lewa i kwadrant), opisywali jej typ (guzy, mikrozwapnienia, zagęszczenia, zaburzenia architektury) i morfologię



Rysunek 4.14: Interfejs dla radiologa w czasie trwania testów weryfikacyjnych – widok projekcji MLO: obrazy przetworzone z oznaczonymi „miejscami” do powiększenia i weryfikacji – biało-czarnymi kwadratami, wskazującymi środki automatycznie wskazywanych, potencjalnych klastrow mikrozwapnień. Dodatkowo powiększony fragment obrazu złośliwych mikrozwapnień, wskazany przez AWPKM.

(dla guzów: zarysy i kształt, dla mikrozwapnień: kształt – tab. 4.18) i oceniali w skali BIRADS (tab. 1.1).

	Guzy		Mikrozwapnień
Ocena	Zarys	Kształt	Kształt
1	gładki	okrągły	punktowe
2	przesłonięty	owalny	pleomorficzne
3	spikularny	policykliczny	amorficzne
4	rozmyty	nieregularny	rozgałęziające (odlewowe)
5	mikropolicykliczny	—	—

Tabela 4.18: Skala opisu morfologii guzów i mikrozwapnień.

#### 4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW

##### Test z oceną porównawczą

Przy każdym badaniu lekarze dodatkowo porównywali obrazy z badania oryginalnego z przetworzonymi. Oceniali jakość obrazu i wizualizację struktur tkanki oraz poprawę widoczności zmian, które zauważyli. Do oszacowania poprawy jakości obrazów wykorzystano subiektywną porównawczą skalę ocen: od -3 – zdecydowanie gorsza jakość – do +3 – zdecydowanie lepsza jakość obrazu (tab 2.1).

##### Monitory

Wstępny wybór obrazów testowych był przeprowadzony na monitorach *Matrox MED 2 mp DVI* (96 dpi, 1024 poziomów szarości). Mała grupa badań w pierwszej turze była oglądana przez radiologów na sparowanych 3-megapikselowych monitorach firmy *NEC*<sup>3</sup>. Dalsze testy były przeprowadzane na sparowanych monitorach *EIZO RadiForce GS320 3 mp*<sup>4</sup>.

#### 4.4.5 Wyniki

##### Wyniki testu automatycznej detekcji na testowanych obrazach

Wyniki testu automatycznej detekcji na obrazach zawierających mikrozwapnienia są przedstawione w tabeli 4.19. Czulość na badaniach SEC wynosiła 95,8%. Liczba fałszywych wskazań na obraz FPI dla wszystkich obrazów z badań zawierających mikrozwapnienia wynosiła 2,48. Uwzględniając tylko wskazania w obszarze piersi (bez mięśnia w projekcjach MLO) liczba ta wynosiła 1,97. Natomiast z dodatkowym wyłączeniem łagodnych klastrów mikrozwapnień liczba FPI wynosiła 1,23. W tym przypadku jako fałszywe wskazania policzono tylko wskazania w obszarze piersi, niebędące klastrami mikrozwapnień złośliwych ani łagodnych.

Liczby AWPKM na obraz na badaniach prawidłowych-zdrowych (liczone automatycznie, a więc z dodanymi wskazaniami poza obszarem piersi i oczywistymi zmianami łagodnymi) przedstawiono w tabeli 4.20.

Obrazy z mikrozwapnieniami	Subtelność				
	1-5	1	2	3	4
	wszystkie	najsłabiej widoczne			
Liczba obrazów	48	8	20	18	2
SE	77,1%	62,5%	75,0%	83,3%	100%
FPI	2,48	3,00	3,60	1,06	2,00

Tabela 4.19: Wyniki metody automatycznej detekcji potencjalnych klastrów mikrozwapnień na obrazach, zawierających mikrozwapnienia: rozkład dla zmian o różnej subtelności.

<sup>3</sup>Monitory wykorzystano w testach dzięki uprzejmości firmy *Veracom* z Krakowa.

<sup>4</sup>Monitory wykorzystano w testach dzięki uprzejmości firmy *Alstor* z Warszawy.

Normy	Gęstość				
	1-4	1	2	3	4
	wszystkie	tłuszczowe			gęste
Liczba obrazów	72	1	12	28	28
FPI	0,89	0,00	0,67	1,21	0,79

Tabela 4.20: Liczba fałszywych wskazań – wskazania potencjalnych klastrow mikrozwapnień na zdrowych badaniach (normach). Pokazano rozkład tej liczby w zależności od gęstości utkania gruczołu piersiowego: od 1 – mammogramy najłatwiejsze z utkaniem tłuszczowym poprzez 3 – mammogramy o zróżnicowanej gęstości, gruczołowo-tłuszczowe do 4 – bardzo gęste utkanie.

### Trudności w analizie testu

Poważnym problemem na etapie przygotowania i analizy testów był brak bardzo dokładnych opisów w dostępnej bazie DDSM (opis badań testowych w 4.4.2):

- zasadniczo nieoznaczone zmiany łagodne,
- niemożność weryfikacji wskazanych przez radiologów biorących udział w teście dodatkowych zmian (w DDSM zaznaczona tylko jedna zmiana podejrzana na obrazie – oceniona jako najbardziej podejrzana – nawet gdy w rzeczywistości jest kilka zmian),
- czasami oczywiste z punktu widzenia radiologów biorących udział w teście nieoznaczone dodatkowe zmiany złośliwe (mikrozwapnienia, dodatkowe klastry).

### Charakterystyka sposobu pracy i stosowania przyjętych skal u radiologów

Każdy z lekarzy biorących udział w teście miał inny sposób oceniania i interpretacji obrazów, patrzenia na badania mammograficzne oryginalne i przetworzone oraz używania przyjętych skal.

Radiolog Stażysta był dopiero w fazie uczenia, cechowała go duża zmienność w wydawanych diagnozach. W pierwszej turze miał znacznie bardziej różniące się wyniki niż w drugiej już na samych obrazach oryginalnych. Dwa badania przypadkowo zostały pokazane dwa razy w ciągu jednej sesji i zdarzyło się, że wtedy to samo badanie zostało różnie zdiagnozowane.

Radiolog Specjalista oceniał obrazy dwóch stron, porównując je w dwóch projekcjach, jednak szczególnie skupiał się na dokładnej analizie każdej piersi w dwóch projekcjach (często rozkładał na ekranie obrazy jednej piersi). Lekarz ten był najbardziej zdecydowany co do swojej oceny (średnio wyższe oceny detekcji) i chętniej zmieniał swoje opinie, widząc obrazy po przetworzeniu. Zdarzało się też, że zauważał dodatkowe zmiany na obrazach przetworzonych i chętnie je opisywał. Jednak diagnozy jego najbardziej się różniły pomiędzy pierwszą i drugą turą na obrazach oryginalnych. Lekarz ten był świadom swojej nadwrażliwości na podejrzane objawy, widoczne na obrazach. Już przed rozpoczęciem testu zasygnalizował ją i uzasadnił wykrytym poprzedniego dnia rakiem u swojej pacjentki.

#### 4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKcję I DIAGNOzę RADIOLOGÓW

Po kilku latach od pierwszej mammografii rozwinął się duży rak, a na poprzednich obrazach jego objawy były niezauważalne.

Radiolog Ekspert bardzo systematycznie porównywał obrazy dwóch piersi w każdej projekcji, metodę jego pracy można określić jako „czytanie obrazów odcinek po odcinku”. Jego oceny były najbardziej stabilne pomiędzy turami na obrazach oryginalnych i raczej nie zmieniał swoich ocen, widząc obrazy przetworzone. Jednak w używaniu skali detekcji charakteryzował się mniejszą pewnością (mniej wysokich ocen).

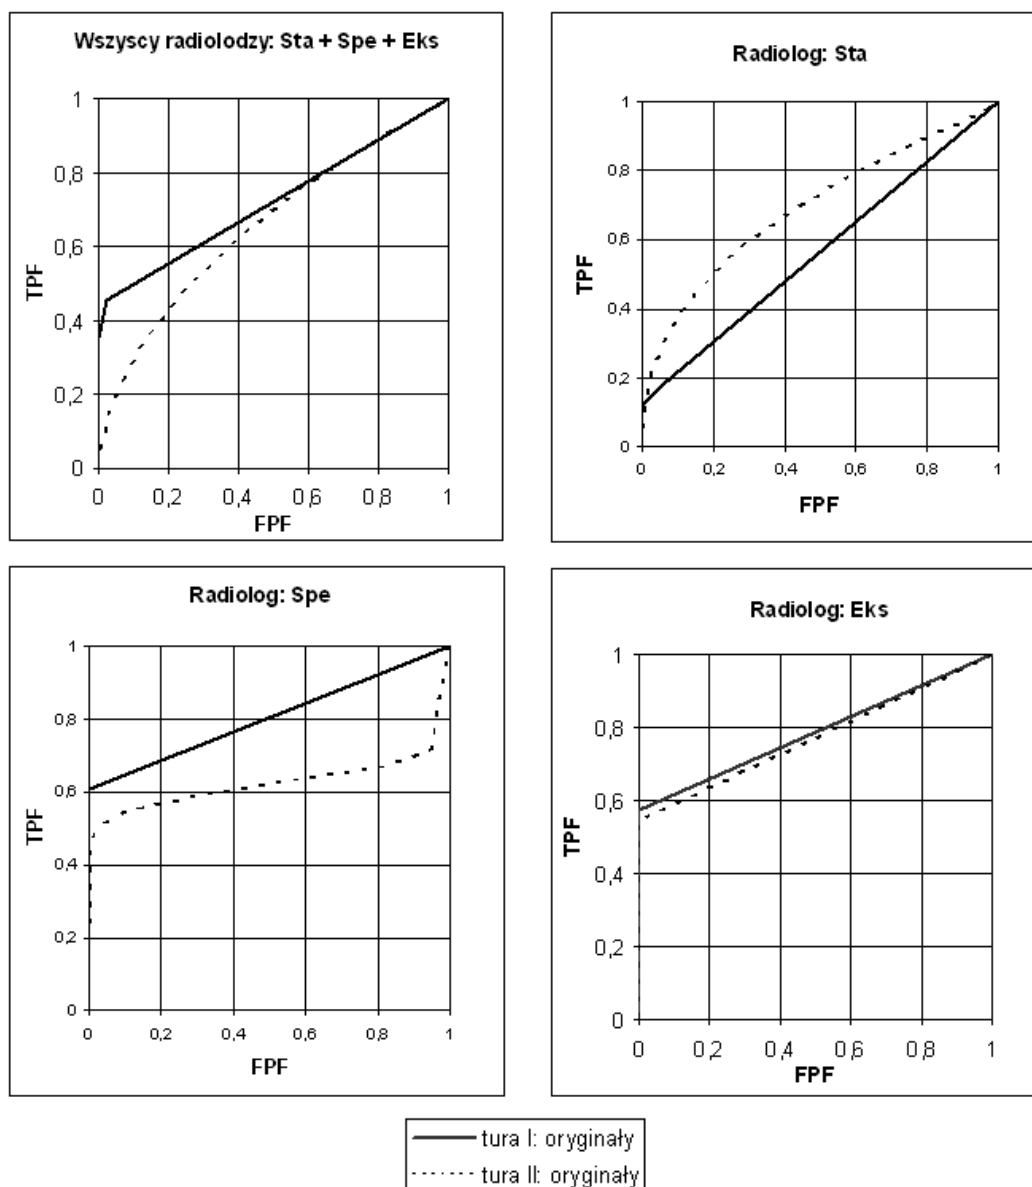
W teście porównawczym radiolog Stażysta ograniczał się do ocen 1 i 2 (nieznacznie lepiej i lepiej). Radiolog Specjalista bardziej różnicował swoje oceny stosując skalę od -1 (nieznacznie gorzej, w jednym badaniu zawierającym mikrozwapnienia w gęstym utkaniu drobnoguzkowym) do 3 (zdecydowanie lepiej). Radiolog Ekspert stosował skalę od -1 (jedno badanie zawierające guz) do 2. Radiolodzy Stażysta i Ekspert nigdy nie zdecydowali się na użycie oceny 3, nawet w przypadkach, kiedy na badaniach oryginalnych nie wiedzieli zmiany patologicznej, a zobaczyli ją na obrazach przetworzonych. Dlatego też wyniki testu porównawczego podano dodatkowo z zastosowaniem skal rozciągniętych do pełnego zakresu.

#### Test detekcji zmian

W podanych wynikach oceniano detekcję, a więc krzywe ROC i wyniki liczbowe są podane dla skali detekcji, z tym że jako wykryte zmiany uznano tylko zmiany zakwalifikowane przez lekarzy jako „potencjalnie podejrzane”, tzn. sklasyfikowane według BI-RADS jako 3, 4, 5 oraz 0 – uznane za wymagające dalszej diagnostyki. Ponadto patologia zostaje uznana za „rzeczywiście (realnie) wykrytą”, jeśli ocena detekcji jest większa lub równa 3. W podanych poniżej wynikach zmiany wykryte, ale sklasyfikowane przez lekarzy błędnie (tzn. niezgodnie z danymi w DDSM) jako zmiany łagodne uznano za fałszywie negatywne (Sta: 7 przypadków, Spe: 4 przypadki, Eks: 4 przypadki). Za pozytywne wskazania uznano badania opisane w DDSM jako prawidłowe, natomiast przez analizującego lekarza opisane jako zawierające zmianę potencjalnie podejrzaną (dane do specyficzności). Za wskazanie prawdziwie pozytywne uznano badania, na których opisano prawidłowo (także lokalizacja zgodna z DDSM) zmianę uznaną przez lekarzy jako potencjalnie złośliwą. Dodatkowe zmiany, opisane przez radiologów na badaniach zawierających wskazany w DDSM rak, nie zostały uwzględnione w wynikach z krzywymi ROC (nie ma możliwości weryfikacji zmian z powodu dostępnego materiału z bazy DDSM).

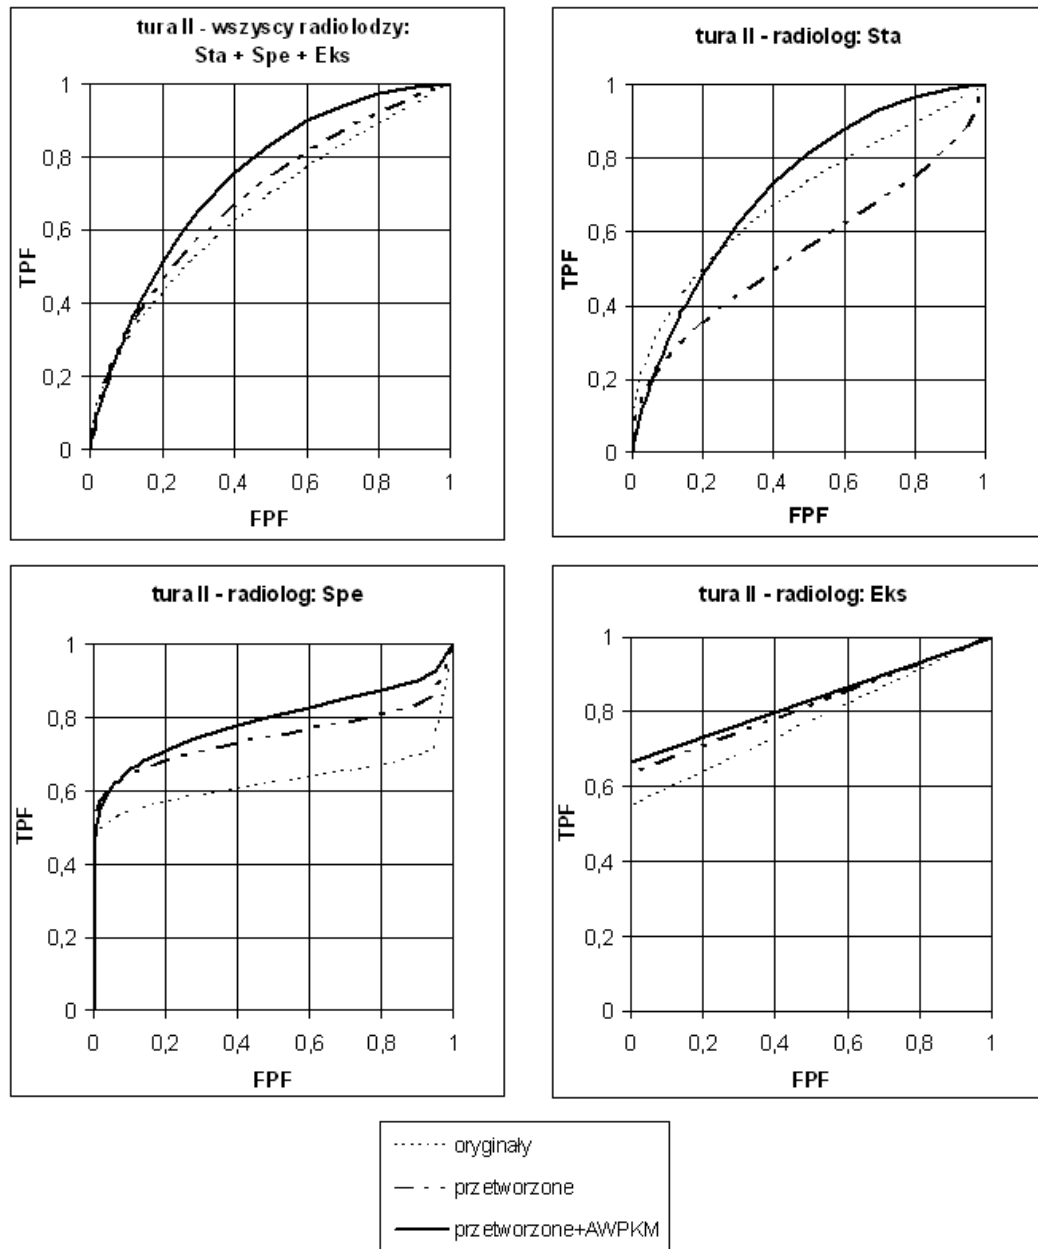
Rysunek 4.15 przedstawia krzywe ROC, wyznaczone dla wszystkich i dla poszczególnych radiologów dla obydwu tur eksperymentu dla diagnozy na badaniach oryginalnych. Jako odniesienie do detekcji i interpretacji przy wspomaganii komputerowym, wybrano diagnozę na badaniach oryginalnych z drugiego etapu, ponieważ została przeprowadzona w podobnych warunkach (te same warunki wstępne: obciążenie lekarzy, pora dnia, zaciemnienie). Rysunki 4.16 i 4.17 przedstawiają krzywe ROC wyznaczone dla wszystkich, dla poszczególnych radiologów oraz dla dwóch radiologów bardziej doświadczonych (Specjalista i Ekspert)

dla drugiej tury eksperymentu dla diagnozy na badaniach oryginalnych, przetworzonych i z pomocą automatycznych wskaźników potencjalnych klastrów mikrozwapnień (AWPKM). Wyniki testu za pomocą AWPKM zostały dodane do wyników testu na obrazach przetworzonych, jako że najpierw lekarze oglądali obrazy przetworzone, a dopiero później AWPKM – było to uzupełnienie diagnozy wydawanej na przetworzonych obrazach. Czułość, specyficzność, dokładność i pole pod krzywymi ROC dla każdej fazy testu zostały podane w tabeli 4.21.



Rysunek 4.15: Krzywe ROC wyznaczone dla wszystkich radiologów oraz dla poszczególnych radiologów w diagnozie na badaniach oryginalnych: pierwszy etap – linia ciągła, drugi etap – linia przerywana.

4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO  
NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW




Rysunek 4.16: Krzywe ROC wyznaczone dla wszystkich radiologów oraz dla poszczególnych radiologów w drugiej turze eksperymentu: diagnoza na oryginalnych badaniach – drobna linia przerywana, na badaniach przetworzonych – linia przerywana z różnej wielkości kreskami „-.-”, na badaniach przetworzonych z AWPKM – linia ciągła.

Radiolodzy	tura I: oryginały	tura II: oryginały	przetworzone	przetworzone + AWPKM
wszyscy: Sta+Spe+Eks	ACC=58,2% SE=35,4% SPE=100,0% EAUC=0,721 FAUC=-	ACC=54,9% SE=43,4% SPE=75,9% EAUC=0,636 FAUC=0,656	ACC=60,1% SE=55,6% SPE=68,5% EAUC=0,664 FAUC=0,687	ACC=65,4% SE=63,6% SPE=68,5% EAUC=0,707 FAUC=0,742
Sta	ACC=43,1% SE=12,1% SPE=100,0% EAUC=0,566 FAUC=-	ACC=51,0% SE=30,3% SPE=88,9% EAUC=0,645 FAUC=0,691	ACC=49,0% SE=33,3% SPE=77,8% EAUC=0,58 FAUC=0,549	ACC=58,8% SE=48,5% SPE=77,8% EAUC=0,684 FAUC=0,725
Spe	ACC=68,6% SE=51,5% SPE=100,0% EAUC=0,803 FAUC=-	ACC=52,9% SE=60,6% SPE=38,9% EAUC=0,616 FAUC=0,617	ACC=58,8% SE=75,8% SPE=27,8% EAUC=0,680 FAUC=0,743	ACC=64,7% SE=84,8% SPE=27,8% EAUC=0,726 FAUC=0,789
Eks	ACC=62,7% SE=42,4% SPE=100% EAUC=0,788 FAUC=-	ACC=60,8% SE=39,4% SPE=100% EAUC=0,773 FAUC=-	ACC=72,5% SE=57,6% SPE=100% EAUC=0,818 FAUC=-	ACC=74,5% SE=60,6% SPE=100% EAUC=0,833 FAUC=-
Spe+Eks	ACC=65,7% SE=47,0% SPE=100,0% EAUC=0,795 FAUC=-	ACC=56,9% SE=50,0% SPE=69,4% EAUC=0,642 FAUC=0,642	ACC=65,7% SE=66,7% SPE=63,9% EAUC=0,701 FAUC=0,729	ACC=69,6% SE=72,7% SPE=63,9% EAUC=0,726 FAUC=0,758

Tabela 4.21: Wartości dokładności (ACC), czułości (SE), specyficzności (SPE), pól pod krzywą ROC, wyznaczoną eksperymentalnie (EAUC) i dopasowaną (FAUC) dla radiologów. W niektórych kolumnach nie podano wartości FAUC, ponieważ w przypadku, gdy lekarz wykazał się 100-procentową specyficznością, dane do wykresu nie były funkcją (prosta równoległa do osi TPF, przecinająca oś FPF w punkcie zero), więc nie można było ich aproksymować funkcją.

#### 4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW



Rysunek 4.17: Krzywe ROC wyznaczone dla radiologów z większym doświadczeniem: Specjalisty i Eksperta w drugiej turze eksperymentu: diagnoza na oryginalnych badaniach – drobna linia przerywana, na badaniach przetworzonych – linia przerywana z różnej wielkości kreskami „-.-”, na badaniach przetworzonych z AWPKM – linia ciągła.

Do analizy statystycznej istotności różnicy pomiędzy wskaźnikami analizy ROC (pola pod krzywymi ROC) użyto algorytmu Dorman'a-Berbaum'a-Metz'a (oprogramowania DBM MRMC [110, 40, 39, 60, 61, 62, 63]). Pakiet ten wykorzystuje metodę analizy wariancji ANOVA do porównywania kilku populacji, umożliwiając obliczanie statystycznej istotności różnicy w sytuacji, kiedy wydajność narzędzia diagnostycznego zależy zarówno od populacji obserwatorów, jak i od populacji przypadków. DBM MRMC przeprowadza analizę statystyczną dla opcji: przypadkowi obserwatorzy i losowo dobrane przypadki, losowo dobrane przypadki, losowo dobrani obserwatorzy. Wybrano test z ustalonymi obserwatorami i losowo wybranymi przypadkami, ponieważ radiolodzy zostali celowo dobrani według doświadczenia zawodowego. Wyniki analizy statystycznej istotności dla różnych wariantów podano w tabeli 4.22.

**Szczegółowe uwagi na temat wyników** Najwięcej fałszywych wskazań zostało opisanych przez radiologa Specjalistę. Charakteryzował się najniższą specyficznością już na obrazach oryginalnych (tab. 4.23), jednocześnie uzyskując najwyższą czułość (tab. 4.21).

W kilku badaniach radiolodzy widzieli zmiany, ale błędnie (niezgodnie z DDSM) zinterpretowali je jako łagodne. Liczba błędnie łagodnych zmian, dostrzeżonych już na oryginałach, których ocena później się nie zmieniła wynosi 4 (Spe: 3 przypadki, Eks: 1 przypadek). Liczba zmian błędnie ocenionych jako łagodne, dodatkowo zauważonych na obrazach przetworzonych, wynosi 3 przypadki (Sta: 2 przypadki, Spe: 1 przypadek). Natomiast liczba takich zmian po weryfikacji AWPKM to dodatkowo sumarycznie 10 (Sta: 6 przypadków, Spe: 1 przypadek, Eks: 3 przy-

Radio- lodzy	Statystyczna istotność różnicy	
	oryginały – – przetworzone	oryginały – – przetworzone +AWPKM
Sta+Spe+Eks	0,5371	<b>0,0046</b>
Sta	0,1692	0,4101
Spe	0,1787	<b>0,0226</b>
Eks	0,1317	<b>0,0454</b>
Spe+Eks	<b>0,0455</b>	<b>0,0022</b>

Tabela 4.22: Wartości statystycznej istotności różnicy pola pod krzywymi ROC (wartość  $p$ ) dla różnych wariantów testu dla poszczególnych radiologów oraz dla wszystkich i bardziej doświadczonych. Wytłuszczono wartości  $p$ , świadczące o istotnej statystycznie różnicy pól pod krzywymi ROC ( $p < 0.05$ ), czyli o wyraźnej poprawie efektywności diagnozy przy zastosowaniu danej metody (przetwarzania lub przetwarzania z AWPKM).

padki). Stąd widać, że samo wskazanie patologii, nie gwarantuje jeszcze prawidłowej dalszej diagnostyki. Przykład zmiany błędnie ocenionej jako łagodna jest pokazany na rysunku 4.18.

Lekarz Ekspert uznał za artefakty dwa automatyczne wskazania pokazujące na klastry złośliwych mikrozwapnień (opisanych w DDSM). Stażysta i Specjalista zmienili diagnozę klastrow mikrozwapnień zauważonych na obrazach po przetwarzaniu na bardziej podejrzaną (z błędnej łagodnej) po weryfikacji AWPKM (Spe:1 przypadek, Sta: 1 przypadek). Automatyczne wskazania skłoniły ich do dokładniejszego przyjrzenia się fragmentowi obrazu, zawierającemu mikrozwapnienia. Jednak z drugiej strony – zbyt duża liczba automatycznych wskazań osłabia czujność radiologów, którzy w tym przypadku nie mają chęci weryfikowania wszystkich wskazań na badaniu. W teście były przypadki zawierające oczywiście mikrozwapnienia łagodne (naczyniowe, rozsiane dysplastyczne) zaznaczone przez AWPKM, w których jedno ze wskazań na badaniu dotyczyło zmiany złośliwej, która często była pomijana przez lekarzy (uznawana za fałszywe wskazanie).

### Ocena porównawcza

Wyniki subiektywnego testu porównawczego dla ocen podawanych przez lekarzy i dla skal rozciągniętych do pełnego zakresu dla każdego radiologa są przedstawione w tabelach: 4.24, 4.25 i 4.26, histogram ocen – na rysunku 4.19. Przykłady obrazów przetworzonych pokazano na rysunkach 4.20 i 4.21.


#### 4.4.6 Uwagi i opinie radiologów

Radiolog Stażysta generalnie uznał obrazy po przetworzeniu za lepsze. Natomiast automatyczne sugestie według niego wskazują dużo łagodnych zwapnień i artefaktów, jednak czasem pomagają i wskazują zmiany niezauważone wcześniej. Ocenił system *MammoViewer* jako wygodny w obsłudze, szczególnie docenił możliwość przełączania projekcji (pokazywania na przemiennie na ekranie) oraz możliwość ustawienia okna widoku (profilu), które bardzo ułatwiały mu pracę.

4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW

	FP na badaniach prawidłowych (zdrowych) liczba badań=18			FP na badaniach zawierających raka liczba badań=33		
	na oryginalach	dodatkowe FP po przetworzeniu	dodatkowe FP po AWPKM	na oryginalach	dodatkowe FP po przetworzeniu	dodatkowe FP po AWPKM
Sta	3	2	0	6	0	1
Spe	15	0	0	18	2	2
Eks	0	0	0	2	2	0

Tabela 4.23: Liczba fałszywych wskazań (z oceną detekcji większą od 2) dla poszczególnych radiologów. Fałszywe wskazania tutaj, to zmiany opisane przez radiologów jako potencjalnie podejrzane, które nie zostały opisane w bazie DDSM. Dla badań zawierających raki jednak nie można praktycznie zweryfikować, czy są to fałszywe wskazania z powodu ograniczeń bazy, w której opisano tylko zmiany najbardziej podejrzane w obrazie. Wskazań fałszywych na badaniach zawierających raki nie wzięto pod uwagę w analizie z krzywymi ROC.



Rysunek 4.18: Przykład zmiany złośliwej błędnie (niezgodnie z opisem w DDSM) zinterpretowanej przez wszystkich radiologów jako łagodna. Jest to skupisko punktowych mikrozwapnień, składające się z około pięciu obiektów. Cechy wskazujące na zmianę podejrzaną to: bardzo duża niejednorodność wysycenia pomiędzy mikrozwapnieniami i duża niejednorodność wielkości. Po prawej pokazano fragment obrazu oryginalnego, po lewej – obraz po przetworzeniu (nieznacznie lepiej widoczna duża niejednorodność wysycenia). Ekspert zauważył tę zmianę już na obrazach oryginalnych, natomiast Stażysta i Specjalista zwrócili na nią uwagę dopiero przy weryfikacji AWPKM.

Ocena w skali -3 do 3	Liczba ocen dla wszystkich badań	Liczba ocen dla badań z mikrozwapnieniami
-1	2	1
0	11	2
1	68	23
2	66	41
3	6	5

Tabela 4.24: Oceny testu porównawczego, wydawane przez trzech radiologów.

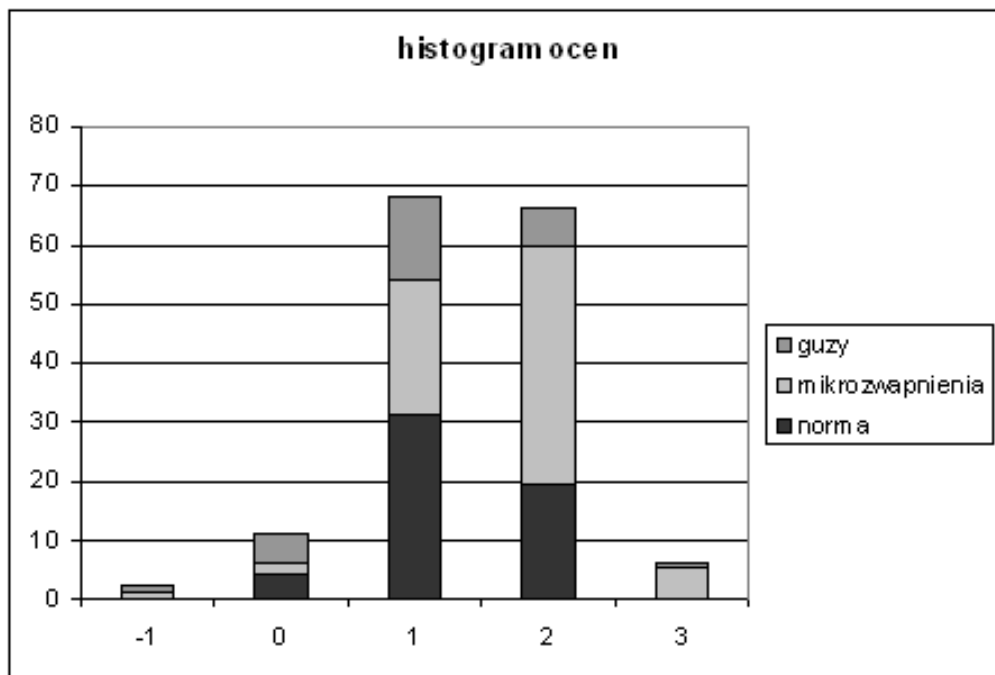
Średnia ocen	normy	guzy	mikrozwapnienia	wszystkie badania
Sta	1,33 (2,00)	1,22 (1,83)	1,5 (2,25)	1,39 (2,09)
Spe	1,39 (1,39)	1,67 (1,67)	1,96 (1,96)	1,71 (1,71)
Eks	1,11 (1,67)	0,22 (0,33)	1,5 (2,25)	1,12 (1,71)
wszyscy radiolodzy	1,28 (1,68)	1,04 (1,28)	1,65 (2,15)	1,41 (1,83)

Tabela 4.25: Średnie ocen testu porównawczego dla badań testowych. W nawiasie podano wartości po rozciągnięciu skal do pełnego zakresu: oceny radiologa 1 i 3 zostały pomnożone przez 1,5, oceny radiologa 2 nie były zmieniane.


Średnia ocen	Subtelności		Gęstości		
	1 – 2	2,5 – 4	1 – 2	3	4
Sta	1,38 (2,06)	1,47 (2,20)	1,28 (1,93)	1,41 (2,11)	1,47 (2,20)
Spe	1,88 (1,88)	1,88 (1,88)	1,78 (1,78)	1,64 (1,64)	1,73 (1,73)
Eks	1,19 (1,78)	1,12 (1,68)	1,14 (1,71)	1,00 (1,50)	1,33 (2,00)
wszyscy radiolodzy	1,48 (1,91)	1,49 (1,92)	1,40 (1,81)	1,35 (1,75)	1,51 (1,98)

Tabela 4.26: Średnie ocen testu porównawczego dla badań testowych o różnej subtelności i gęstości. W nawiasie podano wartości po rozciągnięciu skal do pełnego zakresu: oceny radiologa 1 i 3 zostały pomnożone przez 1,5, oceny radiologa 2 nie były zmieniane.


4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW



Rysunek 4.19: Histogram ocen porównawczych, wydawanych przez radiologów dla badań testowych.



Rysunek 4.20: Przykład poprawy percepcji: złożliwe mikrozwapnienia i obok guzek (po lewej – obraz oryginalny, po prawej – przetworzony).



Rysunek 4.21: Przykład przetwarzania: złośliwy guz (po lewej – obrazy oryginalny, po prawej – przetworzony). Po przetworzeniu guz został uznany przez Eksperta za nieznacznie gorzej widoczny, przez Specjalistę – za nieznacznie lepiej widoczny. Natomiast przez Stażystę został niedostrzeżony, choć struktura tkanki była przez niego oceniona jako nieznacznie lepsza.

Radiolog Specjalista uznał, że przetwarzanie generalnie poprawia obrazy, ocenił strukturę tkanki jako umiarkowanie lepszą. Automatyczne wskazania w większości potwierdzają wykryte mikrozwapnienia, a ponadto pokazują wszystkie mikrozwapnienia (w tym punktowe, łagodne, naczyniowe), zmuszając do bardzo dokładnego przejrzania mammogramu. *MammoViewer* ocenił jako wygodne narzędzie do diagnostyki (przełączanie projekcji, wygodne w obsłudze), zawierające wszystkie potrzebne elementy (miarka, powiększanie, zmiana zakresu widzianych wartości).

Radiolog Ekspert uznał, że po przetworzeniu lepiej widać mikrozwapnienia i łatwiej je policzyć. Przetwarzanie daje też wyraźniejsze różnice w gęstości. Jeśli chodzi o detekcję mikrozwapnień, przetworzony obraz jest lepszy. Jednak przy detekcji guzów lekarz wyraził pewne wątpliwości, czy przetwarzanie coś poprawia, a więc czy, są lepsze bardziej kontrastowe obrazy, ponieważ czasem guz może zniknąć (1 przypadek w teście). Stwierdził, że automatyczne wskazania mogą pomóc nie przeoczyć mikrozwapnień, które są często bardzo subtelnymi zmianami na mammogramach.

#### 4.4.7 Dyskusja

##### Test detekcji

Zdarzało się, że lekarze na obrazach przetworzonych zauważali klastry złośliwych mikrozwapnień (pomimo, że nie widzieli ich na oryginałach) – w sumie dla wszystkich radiologów to 10 przypadków. Czasem widzieli dodatkowe mikrozwapnienia, towarzyszące guzom lub zagęszczeniom, które także nie były widoczne na oryginalnie – 3 przypadki. Po przetworzeniu lekarze widzieli też dodatkowe zagęszczenia. Z powodu ograniczeń bazy DDSM, weryfikacja negatywna jest możliwa tylko na obrazach zdrowych, natomiast praktycznie niemożliwa – na obrazach, zawierających zmiany złośliwe. Jeden raz ekspert zrezygnował z oryginalnie opisanego zagęszczenia i z oryginalnie opisanego guza po obejrzeniu obrazów przetworzonych.

Radiolog Stażysta rzadko dawał się przekonać obrazom przetworzonym: nowe w stosunku do oryginału – 2 zmiany PP (jednak niezgodnie z DDSM uznane za łagodne) i 2 zmiany FP realnie (detekcja powyżej 2) uznane za patologie. Częściej przekonywujące były dla niego AWPKM: 10 zmian (plus jedna z oceną detekcji równą 2), w tym 6 zdiagnozowanych jako łagodne (niezgodnie z DDSM). Na wykresach z krzywymi ROC pokazano spadek efektywności (wzrost czułości, ale spadek specyficzności) tego lekarza na obrazach przetworzonych, natomiast znaczny wzrost po uwzględnieniu AWPKM. Tutaj efektywność tego radiologa wzrasta nawet powyżej efektywności na badaniach oryginalnych, mimo że wyniki z AWPKM zostały dodane do wyników uzyskanych na badaniach przetworzonych. Na podstawie wyników nasuwa się wniosek, że radiolog o bardzo małym doświadczeniu ma trudności z poprawną interpretacją przetworzonych (zmienionych) obrazów. Bardziej przydatne okazują się dla niego automatyczne sugestie zmian patologicznych. Na krzywych ROC z dwóch tur na oryginałach widać proces uczenia się radiologa Stażysty – początkowo bardzo niska czułość wzrosła, ale kosztem specyficzności w drugiej fazie. Widać tutaj duże wahania w interpretacji mammogramów – w rozumieniu objawów patologicznych.

Radiolog Specjalista zaznaczał bardzo dużo fałszywych wskazań już na obrazach oryginalnych – prawdopodobnie jest to wpływ psychologii na lekarza, który miał poprzedniego dnia w pracy trudne doświadczenie ze stałą pacjentką, u której nagle pojawił się rak. Szczególnie jest to widoczne na tle diagnozy w pierwszej turze testu już na obrazach oryginalnych, gdzie jego dokładność była bliska Ekspertowi (a nawet nieco wyższa). Efektywność Specjalisty wzrosła już na obrazach przetworzonych, a także po weryfikacji AWPKM (wzrost istotny statystycznie), jego czułość wzrasta na każdym etapie testu, a specyficzność maleje przy diagnozie na obrazach przetworzonych.

Ekspert wykazał się największą stabilnością w dwóch turach testów na obrazach oryginalnych: w drugiej turze jego efektywność nieznacznie zmalała w stosunku do pierwszej tury. Jego efektywność wzrasta już po zastosowaniu obrazów przetworzonych i jeszcze bardziej wzrasta po weryfikacji AWPKM (wzrost istotny statystycznie).

Analiza wszystkich radiologów wykazuje, że wzrost efektywności radiologów

diagnozujących na obrazach przetworzonych nie jest istotny statystycznie, natomiast wzrost po dodaniu weryfikacji AWPKM jest już na poziomie istotnym statystycznie. Analiza efektywności lekarzy bardziej doświadczonych (Spe+Eks) wykazuje, że wzrost efektywności na poziomie istotnym statystycznie dotyczy diagnozy na obrazach przetworzonych oraz po weryfikacji AWPKM. Mimo wszystko jednak ogólna efektywność radiologów, mierzona krzywymi ROC, jest dość niska, można uzasadnić to bardzo trudnym zbiorem obrazów testowych, zawierającym większość mikrozwapnień, które radiolodzy oceniają gorzej niż guzy [99].

Podsumowując: radiolodzy powinni nabrać doświadczenia w czytaniu zmienionych obrazów (przetworzonych) i pracy z automatycznymi wskazaniami potencjalnych patologii. W trakcie przeprowadzonych testów nie było to możliwe z uwagi na dostępne środki, przed testem przeprowadzono wstępne konsultacje, mające na celu zaznajomienie się ze zmienionym obrazem, ale najwłaściwsza byłaby tu praca równoległa na obrazach przetworzonych i oryginałach przez dłuższy okres czasu (np. 2 miesiące).

W czasie eksperymentu stwierdzono istotną statystycznie poprawę efektywności diagnostycznej u bardziej doświadczonych radiologów, używających systemu *MammoViewer* (z obrazami przetworzonymi i AWPKM). A więc możliwe jest zwiększenie czułości i trafności decyzji radiologów poprzez poprawę diagnostycznie istotnych cech obrazów (uwydatnienie oznak patologii) oraz zasugerowanie lokalizacji zmian.

Analiza testów została przeprowadzona bez uwzględnienia zmian, które radiolodzy błędnie interpretowali jako łagodne – problemem była niewłaściwa interpretacja zmian. Stąd odpowiednio ukierunkowane narzędzia wspomagające interpretację zmian patologicznych (w szczególności mikrozwapnień) przez lekarzy, takie jak *MammoEdit* [118], czy automatyczne szacowanie złośliwości mogą być przydatne także w zmniejszeniu błędów detekcji.

### Ocena porównawcza

Najlepsze wyniki testu porównawczego zostały uzyskane dla mammografii piersi bardzo gęstych, które jednocześnie są bardzo trudne w diagnozie. Ponadto, wnioskując z otrzymanych wyników, wybrana metoda poprawia jakość obrazów mammograficznych, szczególnie poprawia widoczność małych szczegółów obrazu, jakimi są m.in. mikrozwapnienia (czasem też spikule w guzach czy małe zagęszczenia). Może to jednak prowadzić czasami do pogorszenia widoczności litych guzów, gdzie obserwacja drobnych zmian w teksturze nie jest potrzebna, a nawet wskazana, ponieważ lekarz powinien widzieć je jako całość. W tym przypadku przetworzenie może sugerować brak spistości guza, czyli w sumie jego brak w obrazie (jeden przypadek w teście z oceną -1 daną przez Eksperta, pokazany na rysunku 4.21). Wydaje się jednak, że większość takich guzów jest zmianami dobrze widocznymi już na obrazach oryginalnych. W porównaniu obrazów przetworzonych (bardziej skontrastowanych) i oryginalnych zachodzą analogiczne zależności jak przy porównaniu mammografii analogowej z cyfrową, gdzie pewne guzy lepiej są widoczne (wręcz zauważalne) tylko na obrazach analogowych, a inne na obrazach cyfrowych [4]. Poza tym otrzymany efekt pogorszenia widoczności guza

#### 4.4. TESTY KLINICZNE WPŁYWU WSPOMAGANIA KOMPUTEROWEGO NA DETEKCJĘ I DIAGNOZĘ RADIOLOGÓW

sugeruje potrzebę innych metod przetwarzania, dedykowanych do mikrozwapnień (lub innych bardzo subtelnych zmian, jak np. spikule czy drobne zagęszczenia) i do guzów, podobnie jak to zostało opisane w [102].

Podsumowując opinie radiologów: uznali oni, że przetwarzanie generalnie poprawia obrazy, ocenili strukturę tkanki jako umiarkowanie lepszą lub lepszą, ponadto stwierdzili, że po przetworzeniu lepiej widać mikrozwapnienia i łatwiej je policzyć oraz ocenić ich morfologię, przetwarzanie daje też wyraźniejsze różnice w gęstości. Jednak przy detekcji guzów lekarz Ekspert wyraził pewne wątpliwości, czy przetwarzanie coś poprawia, stwierdzając, że w tym przypadku czasami zdjęcia wysoko skonstrastowane są gorsze, ponieważ „guzy znikają”.

#### **Podsumowanie opinii o systemie MammoViewer**

W opinii autorki, jako głównego architekta systemu *MammoViewer*, po obserwacji pracy radiologów w systemie *MammoViewer* i innych komercyjnych systemach do diagnostyki mammograficznej, w systemie *MammoViewer* brakuje kilku drobnych narzędzi, ułatwiających pracę lekarzy, takich jak „lupa”, możliwość profilowania interfejsu indywidualnie dla każdego lekarza itp. „Lupa” czasem przydałaby się, żeby szybko przejrzeć obraz w poszukiwaniu mikrozwapnień. Za każdym razem powiększanie podejrzanego regionu wydłuża pracę. Jednak w innych dziedzinach *MammoViewer* mógłby z powodzeniem konkurować z komercyjnymi systemami, dotyczy to szczególnie możliwości różnego typu przetwarzania obrazów, która nie jest dostępna w znanych systemach komercyjnych. Ponadto system *MammoViewer* jest otwartym pakietem, stwarzającym możliwości porównywania różnych metod, m.in. detekcji i przetwarzania obrazów.



## Rozdział 5

---

# Podsumowanie

---

W pracy opisano: cele, zastosowania oraz kierunki rozwoju współczesnych systemów wspomagania diagnostyki obrazowej, ze szczególnym uwzględnieniem mammografii. Dokonano charakterystyki właściwości obrazowych najważniejszych patologii w mammografii.

Zaprojektowano i zrealizowano system *MammoViewer* do wspomagania diagnostyki obrazowej, mający zastosowanie przede wszystkim do badań mammograficznych. Jest to także narzędzie do optymalizacji metod, zapewniające środowisko (*'framework'*), przygotowane do tworzenia i testowania algorytmów, m.in. przetwarzania obrazów oraz detekcji, segmentacji i ekstrakcji cech. System spełnia założenia otwartej architektury, umożliwiającą integrację z innymi rozwiązaniami i pracami badawczymi. Zawiera szereg zaawansowanych narzędzi, m.in. do analizy wielorozdzielczej, wizualizacji obrazów oraz niezbędny zestaw podstawowych operacji obrazowych.

W systemie *MammoViewer* zostało zaimplementowanych kilka metod poprawy percepcji objawów patologicznych w mammogramach poprzez nieliniowe przetwarzanie obrazów w dziedzinie falkowej.

Ponadto została zrealizowana metoda detekcji potencjalnych skupisk mikrozwapnień, składająca się z etapów: zoptymalizowanej lokalizacji pojedynczych obiektów potencjalnych mikrozwapnień, bazującej na filtracji *Laplacian-of-Gaussian*, segmentacji zlokalizowanych obiektów, dostosowanej metody klasteryzacji DBSCAN, opartej na gęstości obiektów z uwzględnieniem szumu. Zaproponowana metoda łączy kilka technik przetwarzania obrazów w celu uzyskania maksymalnej efektywności — wysokiej czułości detekcji oraz wstępnej minimalizacji najbardziej oczywistych wskazań fałszywych. Opisany algorytm przesuwając akcent z etapu dokładnej detekcji pojedynczych mikrozwapnień (jest to powszechnie stosowane rozwiązanie), ku analizie całych skupisk. Naszym założeniem była wstępna detekcja nadmiarowego zbioru kandydatów, zredukowanego w znacznym stopniu w procesie klasteryzacji. W kolejnym kroku niektóre obiekty ze zdegradowanym kształtem zostają odrzucone przez segmentację. Ponadto segmentacja oraz wygładzanie kształtu służą do jak najwierniejszego opisu obiektów w celu poprawy

skuteczności kolejnych etapów algorytmu – redukcji fałszywych wskazań poprzez analizę statystyczną tekstury i cech kształtu pojedynczych obiektów i całych klastrów. Rezultaty uzyskane dla badań mammograficznych z różnych baz i ośrodków są zbliżone, co sugeruje uniwersalność opracowanej metody.

Ponadto w systemie *Mammo Viewer* zaimplementowano szereg numerycznych metod opisu właściwości pojedynczych obiektów i ich skupisk. Wybrano właściwości do redukcji wskazań fałszywych mikrozwapnień i klasyfikacji skupisk w zależności od jednorodności. Metody opisu właściwości pojedynczych obiektów zweryfikowano we wstępnej klasyfikacji pojedynczych mikrozwapnień.

Przedstawiono: rezultaty szeregu konsultacji z radiologami, wyniki testów klinicznych metod poprawy percepcji zmian patologicznych i wpływu automatycznych wskazań na diagnozę lekarską oraz rezultaty eksperymentów poprawy efektywności i weryfikacji opracowanych narzędzi. Wykazały one użyteczność kliniczną opracowanego systemu *Mammo Viewer*.

System *Mammo Viewer* znalazł zastosowanie także w innych badaniach naukowych, które nie były prowadzone bezpośrednio przez autorkę, ale wykorzystywały elementy systemu i prac autorki: lokalizacja zaburzeń architektury, metoda detekcji i segmentacji potencjalnych guzów. System został również wykorzystany w badaniach nad stratną kompresją mammogramów oraz progresją wiarygodności, w badaniach nad poprawą percepcji wczesnego niedokrwienego zawału mózgu w tomografii komputerowej.

Ponadto wybrane algorytmy *Mammo Viewera* służą jako moduł indeksowania po zawartości w bazie referencyjnych badań mammograficznych *IShark*. Metodę segmentacji i ekstrakcji cech wykorzystano także do wspierania ontologii mammografii. Na bazie przeprowadzonych badań zespołowych powstała koncepcja integracji systemu *Mammo Viewer* z ontologią mammografii oraz referencyjną bazą obrazów, mająca na celu realizację nowatorskiej koncepcji zintegrowanej stacji diagnostycznej.

---

## Lista publikacji, związanych z rozprawą

---

1. Anna Wróblewska. Wspomaganie diagnostyki mammograficznej: poprawa percepcji zmian patologicznych. *Materiały VIII Seminarium Radiokomunikacji i Techniki Multimedialnych*, str. 87-94, grudzień 2007.
2. Teresa Podsiadły-Marczykowska, Anna Wróblewska, Artur Przelaskowski. Enhancement of accuracy in mammogram interpretation using ontology-driven editor for lesions description and CAD tool – preliminary results. *Journal of Medical Informatics and Technologies*, XII międzynarodowa konferencja *Medical Informatics and Technologies*, 11:235-243, Published by Computer Systems Dept., University of Silesia, listopad 2007.
3. Piotr Boniński, Anna Wróblewska, Artur Przelaskowski. Metoda detekcji guzków w obrazach mammograficznych, oparta o zmodyfikowaną transformę Rayleigha. *Prace Naukowe Politechniki Warszawskiej – Elektronika, materiały II Symposium Inżynieria Biomedyczna i Telemedycyna IBiTel* w Warszawie, Oficyna Wydawnicza PW, 6 stron, w druku, 2007.
4. Artur Przelaskowski, Rafał Józwiak, Tomasz Krzyżewski, Anna Wróblewska. The ordering of diagnostic information in encoded medical image: accuracy progression. *Optoelectronics Review*, 16(1):49-59, 2008.
5. Teresa Podsiadły-Marczykowska, Artur Przelaskowski, Anna Wróblewska, Piotr Boniński. A framework for integrated, diagnosis supporting interface for mammograms description – advantages and pitfalls. *Proceedings of the Second IASTED International Conference on Human-Computer Interaction*, str. 80-86, Chamonix, France, 14–16 March 2007.

6. Artur Przelaskowski, Teresa Podsiadły-Marczykowska, Anna Wróblewska, Piotr Boniński, Paweł Bargieł. Computer-aided interpretation of medical images: mammography case study. *Machine Graphics and Vision*, 2/3, 27 stron, w druku, 2007.
7. Anna Wróblewska, Artur Przelaskowski. Poprawa percepcji guzków i mikrozwapnień poprzez nieliniowe przetwarzanie wstępne mammogramów w dziedzinie falkowej. *Prace Naukowe Politechniki Warszawskiej – Elektronika, Sympozjum Inżynieria Biomedyczna i Telemedycyna IBiTel w Warszawie*, 157:93-100, Oficyna Wydawnicza PW, 2006.
8. Artur Przelaskowski, Rafał Józwiak, Tomasz Krzyżewski, Anna Wróblewska. Porządkowanie informacji diagnostycznej w kompresowanych obrazach medycznych: progresja wiarygodności. *Materiały V Sympozjum „Techniki Przetwarzania Obrazu”*, strony: 435–448, 2006.
9. Anna Wróblewska, Artur Przelaskowski, Paweł Bargieł, Piotr Boniński. MammoViewer – CAD application based on effective multiscale image analysis. *Polish Journal of Medical Physics & Engineering*, 11(1):17–28, 2005.
10. Anna Wróblewska, Artur Przelaskowski, Paweł Bargieł, Piotr Boniński. MammoViewer – narzędzie do wielorozdzielczej analizy obrazów medycznych. *Materiały ogólnopolskiej konferencji „Fizyka i inżynieria we współczesnej medycynie i ochronie zdrowia – szanse i wyzwania członkostwa w Unii Europejskiej”*, str. 140-141, Warszawa, 2005.
11. Anna Wróblewska, Artur Przelaskowski, Paweł Bargieł, Piotr Boniński. Metoda klasteryzacji i segmentacji mikrozwapnień w celu redukcji wskazań fałszywych przy komputerowym wspomaganium mammografii. *Materiały XIV Krajowej Konferencji Naukowej: Biocybernetyka i Inżynieria Biomedyczna*, tom 1:396–401, Częstochowa, 2005.
12. Anna Wróblewska, Artur Przelaskowski, Paweł Bargieł, Piotr Boniński. Two stage detection and clustering of microcalcifications in mammograms. *Biomedizinische Technik, Medical Physics, Proceeding of 14th International Conference of Medical Physics ICMP 2005*, 50 (supp 1):56–57, Nuremberg, Germany, wrzesień 2005.
13. Piotr Boniński, Artur Przelaskowski, Konrad Durasiewicz, Anna Wróblewska, Paweł Bargieł. Automatyczne indeksowanie obrazów w zastosowaniach

medycznych. *Materiały XIV Krajowej Konferencji Naukowej: Biocybernetyka i Inżynieria Biomedyczna*, tom 1:411–416, Częstochowa, 2005.

14. Paweł Bargieł, Piotr Boniński, Anna Wróblewska, Artur Przelaskowski. Perception improvement of chosen pathological changes in mammograms and us images. *Biomedizinische Technik, Medical Physics, Proceeding of 14th International Conference of Medical Physics ICMP 2005*, 50 (supp 1):64–65, Nuremberg, Germany, wrzesień 2005.
15. Paweł Bargieł, Artur Przelaskowski, Anna Wróblewska, Piotr Boniński. Poprawa percepcji guzków spikularnych w obrazach mammograficznych. *Materiały XIV Krajowej Konferencji Naukowej: Biocybernetyka i Inżynieria Biomedyczna*, tom 1:227–332, Częstochowa, 2005.
16. Artur Przelaskowski, Przemysław Wojtaszczyk, Anna Wróblewska. Modelowanie zmian patologicznych sutka z wykorzystaniem analizy wielorozdzielczej. *Structures, Waves, Human Health*, 14(2):135–142, 2005.
17. Artur Przelaskowski, Anna Wróblewska. Współczesne systemy wspomaganie detekcji patologii w mammografii. *Materiały XIV Krajowej Konferencji Naukowej: Biocybernetyka i Inżynieria Biomedyczna*, tom 1:348–353, Częstochowa, 2005.
18. Artur Przelaskowski, Anna Wróblewska, Paweł Bargieł. Wspomaganie decyzji diagnostycznych w mammografii. *Structures, Waves, Human Health*, 14(2):127–134, 2005.
19. Anna Wróblewska, Artur Przelaskowski. Detection of microcalcifications with shape marking in digital mammograms. *The Society for Computer Applications in Radiology (SCAR) Scientific Abstract Book*, str. 18-20, Vancouver, Canada, 2004.
20. Paweł Bargieł, Artur Przelaskowski, Anna Wróblewska. Wavelet methods in improving the detection of lesions in mammograms. *Computational Imaging and Vision, Proceeding of International Conference on Computer Vision and Graphics ICCVG 2004*, 32:869–874, Warsaw, Springer, 2006.
21. Paweł Bargieł, Anna Wróblewska, Artur Przelaskowski. Falkowe metody poprawy percepcji zmian patologicznych w mammogramach. *Prace Naukowe Instytutu Telekomunikacji i Akustyki Politechniki Wrocławskiej*, nr 85,

seria: *Konferencje, nr 29, X Sympozjum Nowości w Technice Audio i Wi-  
deo 2004*, str. 221-229, Wrocław, 2004.

22. Anna Wróblewska, Piotr Boniński, Artur Przelaskowski, Marian Kazubek. Segmentation and feature extraction for reliable classification of microcalcifications in digital mammograms. *Optoelectronics Review*, 11(3):227–235, 2003.
23. Anna Wróblewska, Artur Przelaskowski. System automatycznej detekcji i klasyfikacji mikrozwapnień w cyfrowej mammografii. *Elektronizacja*, 3:8–11, 2003.
24. Anna Wróblewska, Artur Przelaskowski. System automatycznej detekcji i klasyfikacji mikrozwapnień w cyfrowej mammografii. *Materiały IV Sympozjum „Techniki Przetwarzania Obrazu”*, str. 299-305, 2002.
25. Piotr Boniński, Artur Przelaskowski, Marian Kazubek, Anna Wróblewska. Zastosowanie kwantyzacji wektorowej LVQ w procesie klasyfikacji mikrozwapnień w cyfrowej mammografii. *Materiały IV Sympozjum „Techniki Przetwarzania Obrazu”*, str. 359-368, listopad 2002.

Powyższe publikacje są także ujęte w bibliografii, gdzie można znaleźć odniesienia do cytujących je fragmentów rozprawy.

### **Udział autorki w projektach badawczych**

Wykonawca w projekcie badawczym MNiI nr 3 T11E 014 28 pt. „Modelowanie informacji istotnej diagnostycznie w dziedzinie przekształceń falkowych do zastosowań radiologii cyfrowej”, realizowanym w okresie 03.2005–12.2006.

### **Stypendia, otrzymane przez autorkę**

2005/2006 – stypendium Fundacji na Rzecz Nauki Polskiej

2006/2007 (10 miesięcy) i 2007/2008 (5 miesięcy) – stypendium naukowe dla doktorantów Politechniki Warszawskiej

2007 (9 miesięcy) – Stypendium Fundacji Wspierania Rozwoju Radiokomunikacji i Techniki Multimedialnych

---

# Bibliografia

---

- [1] B. Acha, R. M. Rangayyan, J. E. L. Desaultes. Detection of microcalcifications in mammograms. *Recent Advances in Breast Imaging*, SPIE Press, 2006. [cytowanie na str. 61, 79]
- [2] American College of Radiology (ACR). *Breast imaging reporting and data system (BI-RADS)*. Reston, 3 edition, 1998. [cytowanie na str. 23, 24, 73]
- [3] T. C. Andre, R. M. Rangayyan. Classification of tumors and masses in mammograms using neural networks with shape and texture features. *Proceedings of the 25th Annual International Conference of the IEEE EMBS*, 2261–2264, Mexico, September 17-21, 2003. [cytowanie na str. 75, 76]
- [4] Assessment Program. Full-field digital mammography. Technical Report 20 (16), Technology Evaluation Center, Blue Cross and Blue Shield Association, 2006. [cytowanie na str. 186]
- [5] J. A. Baker, P. J. Kornguth, J. Y. Lo, C. E. J. Floyd. Artificial neural network: improving the quality of breast biopsy recommendations. *Radiology*, 198:131–135, 1996. [cytowanie na str. 73, 74, 79]
- [6] J. A. Baker, E. L. Rosen, J. Y. Lo, E. I. Gimenez, R. Walsh, M. S. Soo. Computer-aided detection in screening mammography: Sensitivity of commercial cad systems for detecting architectural distortion. *American Journal of Roentgenology*, 181:1083–1088, 2003. [cytowanie na str. 33, 34]
- [7] I. N. Bankman, T. Nizialek, I. Simon, O. B. Gatewood, I. N. Weinberg, W. R. Brody. Segmentation algorithms for detecting microcalcifications in mammograms. *IEEE Transactions on Information Technology in Biomedicine*, 1(2):141–149, 1997. [cytowanie na str. 62, 69, 76, 131]
- [8] P. Bargieł. *Komputerowe metody poprawy jakości medycznych danych obrazowych*. Rozprawa doktorska, Politechnika Warszawska, Wydział Elektroniki i Technik Informacyjnych, 2007. [cytowanie na str. 7, 41, 42, 48, 49, 50, 51, 53, 84, 106, 139]
- [9] P. Bargieł, P. Boniński, A. Wróblewska, A. Przelaskowski. Perception improvement of chosen pathological changes in mammograms and us images. *Biomedizinische Technik, Medical Physics, Proceeding of 14th International Conference of Medical Physics ICMP 2005*, 50 (supp 1):64–65, Nuremberg, Germany, September 2005. [cytowanie na str. 84]

- [10] P. Bargieł, A. Przelaskowski, A. Wróblewska. Wavelet methods in improving the detection of lesions in mammograms. *Computational Imaging and Vision, Proceeding of International Conference on Computer Vision and Graphics ICCVG 2004*, 32:869–874, Warsaw, Springer, 2006. [cytowanie na str. 84]
- [11] P. Bargieł, A. Wróblewska, A. Przelaskowski. Falkowe metody poprawy percepcji zmian patologicznych w mammogramach. *Prace Naukowe Instytutu Telekomunikacji i Akustyki Politechniki Wrocławskiej, nr 85, seria: Konferencje, nr 29, X Sympozjum Nowości w Technice Audio i Wideo 2004*, str. 221–229, Wrocław, 2006. [cytowanie na str. 84]
- [12] A. Bazzani, A. Bevilacqua, D. Bolloni, R. Brancaccio, D. Romani. An SVM classifier to separate false signals from microcalcifications in digital mammograms. *International Journal of Modern Physics*, 11:901–912, 2000. [cytowanie na str. 79]
- [13] C. A. Beam, P. M. Layde, D. D. Sullivan. Variability in the interpretation of screening mammograms by us radiologists. *Archives of Internal Medicine*, 156:209–213, 1996. [cytowanie na str. 23]
- [14] B. Betal, N. Roberts, G. H. Whitehouse. Segmentation and numerical analysis of microcalcifications on mammograms using mathematical morphology. *British Journal of Radiology*, 70:903–917, 1997. [cytowanie na str. 57, 76]
- [15] R. Birdwell, P. Bhandarkar, D. Ikeda. Computer aided detection with screening mammography in a university hospital setting. *Radiology*, 236:451–457, 2005. [cytowanie na str. 34]
- [16] P. Boniński. *Metody indeksowania obrazów medycznych na potrzeby radiologii cyfrowej*. rozprawa doktorska, Politechnika Warszawska, Wydział Elektroniki i Technik Informacyjnych, 2007. [cytowanie na str. 7, 112, 142]
- [17] P. Boniński, A. Przelaskowski. Interfejs referencyjnej bazy danych obrazowych. *Prace naukowe, Elektronika, z.157, Materiały Sympozjum „Inżynieria Biomedyczna i Telemedycyna IBiTel 2006”*, red. Antoni Grzanka, str. 101–107. Politechnika Warszawska, Akademia Medyczna – Warszawa, wrzesień 2006. [cytowanie na str. 13, 84, 142]
- [18] P. Boniński, A. Przelaskowski, K. Durasiewicz, A. Wróblewska, P. Bargieł. Automatyczne indeksowanie obrazów w zastosowaniach medycznych. *Materiały XIV Krajowej Konferencji Naukowej: Biocybernetyka i Inżynieria Biomedyczna*, tom 1:411–416, Częstochowa, 2005. [cytowanie na str. 7, 13]
- [19] P. Boniński, A. Przelaskowski, M. Kazubek, A. Wróblewska. Zastosowanie kwantyzacji wektorowej LVQ w procesie klasyfikacji mikrozwapnień w cyfrowej mamografii. *Materiały IV Sympozjum „Techniki Przetwarzania Obrazu”*, str. 359–368, listopad 2002. [cytowanie na str. 84, 135]
- [20] P. Boniński, A. Wróblewska, A. Przelaskowski. Metoda detekcji guzków w obrazach mammograficznych oparta o zmodyfikowaną transformatę Rayleigha. *Materiały Sympozjum „Inżynieria Biomedyczna i Telemedycyna IBiTel 2007”*, red. Antoni Grzanka, Politechnika Warszawska, Akademia Medyczna – Warszawa, Warszawa, wrzesień 2007. [cytowanie na str. 7, 84, 139, 140]
- [21] R. F. Brem. Blinded comparison of computer-aided detection with human second reader in screening mammography: the importance of the question and the critical numbers game. *American Journal of Roentgenology*, 189(5):1142–1144, 2007. [cytowanie na str. 33]

## BIBLIOGRAFIA

- [22] R. F. Brem, J. Baum, M. Lechner, S. Kaplan, S. Sounders, L. G. Naul, J. Hofmeister. Improvement in sensitivity of screening mammography with computer-aided detection: a multiinstitutional trial. *American Journal of Roentgenology*, 181(3):687–693, 2003. [cytowanie na str. 33]
- [23] D. Brzakovic, X. M. Luo, P. Brzakovic. An approach to automated detection of tumors in mammograms. *IEEE Transactions on Medical Imaging*, 9:233–241, 1990. [cytowanie na str. 60, 75]
- [24] L. J. W. Burhenne, S. A. Wood, C. J. D’Orsi, S. A. Feig, D. B. Kopans, K. F. O’Shaughnessy, E. A. Sickles, L. Tabar, C. J. Vyborny, R. A. Castellino. Potential contribution of computer-aided detection to the sensitivity of screening mammography. *Radiology*, 215:554–562, 2000. [cytowanie na str. 33]
- [25] S. A. Butler, R. J. Gabbay, D. A. Kass, D. E. Siedler, K. F. O’Shaughnessy, R. A. Castellino. Computer-aided detection in diagnostic mammography. *American Journal of Roentgenology*, 183(5):1511–1515, 2004. [cytowanie na str. 14]
- [26] S. Ciatto, M. .R. Del Turco, G. Risso, S. Catarzi, R. Bonardi, V. Viterbo, P. Gnutti i in. Comparison of standard reading and computer aided detection (CAD) on a national proficiency test of screening mammography. *European Journal of Radiology*, 45(2):135—138, 2003. [cytowanie na str. 33]
- [27] H. D. Cheng, X. Cai, X. Chen, L. Hu, X. Lou. Computer-aided detection and classification of microcalcifications in mammograms: a survey. *Pattern Recognition*, 36:2967–2991, 2003. [cytowanie na str. 26, 56, 57, 61, 69, 76, 79]
- [28] H. D. Cheng, H. Xu. A novel fuzzy logic approach to mammogram contrast enhancement. *Information Science*, 148:167–184, 2002. [cytowanie na str. 57]
- [29] I. Christoyanni, E. Dermatas, G. Kokkinakis. Fast detection of masses in computer-aided mammography. *IEEE Signal Processing Magazine*, 17(1):54–64, 2000. [cytowanie na str. 60, 79, 81]
- [30] L. Costaridou, P. Sakellaropoulos, S. Skiadopoulos, G. Panayiotakis. *Locally adaptive wavelet contrast enhancement*. Taylor and Francis Group, LLC, 2005. [cytowanie na str. 52, 54]
- [31] T. E. Cupples, J. E. Cunningham, J. C. Reynolds. Impact of CAD in a regional screening mammography program. *American Journal of Roentgenology*, 185:944–950, 2005. [cytowanie na str. 34]
- [32] G. Davis. Wavelet image compression construction kit. <http://www.geoffdavis.net/dartmouth/wavelet/wavelet.html>, 1997. [cytowanie na str. 87, 231]
- [33] J. C. Dean, C. C. Ilvento. Improved cancer detection using computer-aided detection with diagnostic and screening mammography: prospective study of 104 cancers. *American Journal of Roentgenology*, 187:20–28, 2006. [cytowanie na str. 34]
- [34] J. Dengler, S. Behrens, J. F. Desaga. Segmentation of microcalcifications in mammograms. *IEEE Transactions on Medical Imaging*, 12(4):774–786, 1993. [cytowanie na str. 56, 57, 76]
- [35] S. Destounis. Computer-aided detection and second reading utility and implementation in a high-volume breast clinic. *Applied Radiology*, 9(33):8–15, 2004. [cytowanie na str. 14]

- [36] J. Didkowska, U. Wojciechowska, W. Tarkowski, W. Zatoński. *Nowotwory Złośliwe w Polsce w 2000 roku*. Centrum Onkologii — Instytut Marii Skłodowskiej-Curie, Zakład Epidemiologii i Prewencji Nowotworów, Krajowy Rejestr Nowotworów, Warszawa, ISSN 0867-8251, 2003. [cytowanie na str. 1]
- [37] W. M. Diyana, J. Larcher, R. Besar. A comparison of clustered microcalcifications automated detection methods in digital mammogram. *Proceedings of IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '03)*, 2:385–388, 6-10 April 2003. [cytowanie na str. 61, 76]
- [38] K. Doi. Computer-aided diagnosis in medical imaging: historical review, current status and future potential. *Computerized Medical Imaging and Graphics*, 31:198–211, 2007. [cytowanie na str. 2, 13, 16, 17, 33, 34, 35]
- [39] D. D. Dorfman, K. S. Berbaum, R. V. Lenth, Y. F. Chen, B. A. Donaghy. Monte Carlo validation of a multireader method for receiver operating characteristic discrete rating data: factorial experimental design. *Academic Radiology*, 5:591–602, 1998. [cytowanie na str. 179]
- [40] D. D. Dorfman, K. S. Berbaum, C. E. Metz. Receiver Operating Characteristic rating analysis: generalization to the population of readers and patients with the jackknife method. *Investigative Radiology*, 27:723–731, 1992. [cytowanie na str. 179]
- [41] B. Dudziński, R. Pająk. *Laboratorium podstaw fotoniki – cyfrowe przetwarzanie obrazu*. Zakład Przetwarzania Obrazu. Instytut Mikroelektroniki i Optoelektroniki Politechniki Warszawskiej, Warszawa, 2003. [cytowanie na str. 41, 43]
- [42] J. Dziukowa. *Mammografia w diagnostyce raka sutka*. Bel Corp Scientific Publ. Co., Warszawa, 1998. [cytowanie na str. 1, 19, 22, 23, 24, 26, 28]
- [43] I. El-Naqa, Y. Yang, M. N. Wernick, N. P. Galatsanos, R. M. Nishikawa. A support vector machine approach for detection of microcalcifications. *IEEE Transactions on Medical Imaging*, 21(12):1552–1563, 2002. [cytowanie na str. 79]
- [44] R. L. Ellis, A. A. Meade, M. A. Mathiason, K. M. Willison, W. Logan-Young. Evaluation of computer-aided detection systems in the detection of small invasive breast carcinoma1. *Radiology*, 245:88–94, 4th October, 2007. [cytowanie na str. 33, 34]
- [45] J. G. Elmore, R. J. Brenner. The more eyes, the better to see? From double to quadruple reading of screening mammograms. *JNCI J Natl Cancer Inst*, 99:1141–1143, 2007. [cytowanie na str. 33]
- [46] B. J. Erickson, B. Bartholmai. Computer-aided detection and diagnosis at the start of the third millennium. *Journal of Digital Imaging*, 15(2):59–68, 2002. [cytowanie na str. 10, 14]
- [47] M. Ester, H. P. Kriegel, J. Sander, X. Xu. A density-based algorithm for discovering clusters in large spatial databases with noise. *Proc. 2nd Int. Conf. on Knowledge Discovery and Data Mining*, 1996. [cytowanie na str. 123, 128, 129]
- [48] S. A. Feig, E. A. Sickles, W. P. Evans, M. N. Linver. Letter to the editor: Re: Changes in breast cancer detection and mammography recall rates after the introduction of a computer-aided detection system. *J Natl Cancer Inst*, 96:1260–1261, 2004. [cytowanie na str. 34]

## BIBLIOGRAFIA

- [49] J. J. Fenton, S. H. Taplin, P. A. Carney, L. Abraham, E. A. Sickles, C. D’Orsi, E. A. Berns, G. Cutter, R. E. Hendrick, W. E. Barlow, J. G. Elmore. Influence of computer-aided detection on performance of screening mammography. *The New England Journal of Medicine*, 356(14):1399–1409, 5th April 2007. [cytowanie na str. 33]
- [50] T. W. Freer, M. J. Ulissey. Screening mammography with computer-aided detection: prospective study of 12,860 patients in a community breast center. *Radiology*, 220:781–786, 2001. [cytowanie na str. 33, 34]
- [51] D. Georgian-Smith, R. H. Moore, E. Halpern, E. D. Yeh, E. A. Rafferty, H. A. D’Alessandro, M. Staffa, D. A. Hall, K. A. McCarthy, D. B. Kopans. Blinded comparison of computer-aided detection with human second reading in screening mammography. *American Journal of Roentgenology*, 189:1135–1141, 2007. [cytowanie na str. 33]
- [52] D. J. Getty, R. M. Pickett, C. J. D’Orsi, J. A. Swets. Enhanced interpretation of diagnostic images. *Investigative Radiology*, 23:240–252, 1988. [cytowanie na str. 72]
- [53] M. L. Giger. CAD in breast imaging. *SCAR (The Society for Computer Applications in Radiology) TRIP Session*, Vancouver, Canada, 2004. [cytowanie na str. 13, 14, 15, 16, 35, 36, 37]
- [54] R. Gilad-Bachrach, A. Navot, N. Tishby. Margin based feature selection – theory and algorithms. *Proceedings of the 21st International Conference on Machine Learning*, Banff, Canada, 2004. [cytowanie na str. 72, 163, 234, 235, 236, 237, 238, 239, 240]
- [55] M. Gromet. Original research. Comparison of computer-aided detection to double reading of screening mammograms: review of 231,221 mammograms. *American Journal of Roentgenology*, 10.2214/AJR.07.2812, in print, April 2008 [cytowanie na str. 13, 35]
- [56] B. R. Groshong, W. P. Kegelmeyer. Evaluation of a Hough transform method for circumscribed lesion detection. *Proc. 3rd Int. Workshop Digital Mammography*, editors: K. Doi, M.L. Giger, R.M. Nishikawa, R.A. Schmidt, pages 361–366, 9-12 June 1996. [cytowanie na str. 60]
- [57] D. Gur, J. H. Dumkin, H. E. Rockette et al. Changes in breast cancer detection and mammography recall rates after the introduction of a computer-aided detection system. *J Natl Cancer Inst*, 96:185–190, 2004. [cytowanie na str. 34]
- [58] C. H. Harris. Why mammography CAD matters? Health Imaging and IT <http://www.healthimaging.com>, 1st July 2007. [cytowanie na str. 35]
- [59] P. Heinlein, J. Drexler, W. Schneider. Integrated wavelet for enhancement of microcalcifications in digital mammography. *IEEE Transactions on Medical Imaging*, 22(3):402–413, 2003. [cytowanie na str. 56]
- [60] S. L. Hillis. Monte Carlo validation of the Dorfman-Berbaum-Metz method using normalized pseudovalues and less data-based model simplification. *Academic Radiology*, 12:1534–1541, DOI:10.1016/j.acra.2005.07.012, 2005. [cytowanie na str. 179]
- [61] S. L. Hillis. A comparison of denominator degrees of freedom for multiple observer ROC analysis. *Statistics in Medicine*, in press, 2006. [cytowanie na str. 179]
- [62] S. L. Hillis, K. S. Berbaum. Power estimation for the Dorfman-Berbaum-Metz method. *Academic Radiology*, 11:1260–1273, 2004. [cytowanie na str. 179]

- [63] S. L. Hillis, N. A. Obuchowski, K. M. Schartz, K. S. Berbaum. A comparison of the Dorfman-Berbaum-Metz and Obuchowski-Rockette methods for receiver operating characteristic (ROC) data. *Statistics in Medicine*, 24:1579–1607, DOI:10.1002/sim.2024, 2005. [cytowanie na str. 179]
- [64] <http://marathon.csee.usf.edu/Mammography/Database.html>. Digital Database for Screening Mammography. [cytowanie na str. xiii, 43, 45, 47, 49, 57, 63, 70, 87, 90, 91, 92, 93, 96, 97, 114, 119, 124, 125, 126, 127, 128, 132, 134, 145, 150, 151, 152, 153, 154]
- [65] <http://sprojects.mmi.mcgill.ca/mammography/>. [cytowanie na str. 32]
- [66] <http://www.breastcancer.org>. [cytowanie na str. 22]
- [67] <http://www.healthimaging.com>. CAD: Expanding applications and accuracy, RSNA 2005 in review. 2005. [cytowanie na str. 31, 36]
- [68] <http://www.healthimaging.com>. CAD streamlines to speed workflow, RSNA Technology Reviews. January 2006. [cytowanie na str. 10]
- [69] <http://www.healthimaging.com>. A new era for CAD, RSNA Technology Reviews. January 2007. [cytowanie na str. 10, 17, 31]
- [70] <http://www.icadmed.com>. [cytowanie na str. 31, 33]
- [71] <http://www.kodak.com/global/en/health/productsByType/medFilmSys/eqp/system/mamCad.jhtml>. Kodak carestream health. [cytowanie na str. 31]
- [72] <http://www.mrml.org>. [cytowanie na str. 23]
- [73] <http://www.r2tech.com>. R2 Technology Inc. [cytowanie na str. 2, 31, 33]
- [74] <http://www.scanis.com>. [cytowanie na str. 31]
- [75] D. M. Ikeda, R. L. Birdwell, K. F. O’Shaughnessy, E. A. Sickles, R. J. Brenner. Computer-aided detection output on 172 subtle findings on normal mammograms previously obtained in women with breast cancer detected at follow-up screening mammography. *Radiology*, 230:811–819, 2004. [cytowanie na str. 13]
- [76] M. Jasionowska. Metody detekcji zaburzeń architektury w mammografii. praca dyplomowa inżynierska, Politechnika Warszawska, Wydział Elektroniki i Technik Informacyjnych, wrzesień 2007. [cytowanie na str. 7, 84, 139, 141]
- [77] J. Jiang, B. Yao, A. M. Wason. Integration of fuzzy logic and structure tensor towards mammogram contrast enhancement. *Computerized Medical Imaging and Graphics*, 29:83–90, 2005. [cytowanie na str. 57]
- [78] Y. Jiang. Classification of breast lesions from mammograms. *Handbook of Medical Imaging*. pages 341–357, Academic Press, 2000. . [cytowanie na str. 2, 23, 72, 77]
- [79] Y. Jiang, R. M. Nishikawa, D. E. Wolverton. Malignant and benign clustered microcalcifications: automated feature analysis and classification. *Radiology*, 198:671–678, 1996. [cytowanie na str. 78, 79]
- [80] R. Józwiak. Metody wstępnego przetwarzania obrazów ultrasonograficznych prostaty z wykorzystaniem przekształceń falkowych. praca magisterska, Instytut Radioelektroniki, Politechnika Warszawska, 2006. [cytowanie na str. 50]

## BIBLIOGRAFIA

- [81] M. Kallergi, G. M. Carney, J. Gaviria. Evaluating the performance of detection algorithms in digital mammography. *Medical Physics*, 26(2):267–276, 1999. [cytowanie na str. 69, 71, 131]
- [82] A. Karahaliou, I. Boniatis, P. Sakellaropoulos, S. Skiadopoulos, G. Panayiotakis, L. Costaridou. Can texture of tissue surrounding microcalcifications in mammography be used for breast cancer diagnosis? *Nuclear Instruments and Methods in Physics Research, Section A*, 580:1071–1074, 2007. [cytowanie na str. 76]
- [83] N. Karssemeijer, G. M. Brake. Detection of stellate distortions in mammograms. *IEEE Transactions on Medical Imaging*, 15, 1996. [cytowanie na str. 58]
- [84] N. Karssemeijer, J. D. M. Otten, A. L. M. Verbeek, J. H. Groenewoud, H. J. de Koning, J. H. C. L. Hendriks, R. Holland. Computer-aided detection versus independent double reading of masses on mammograms. *Radiology*, 227:192–200, 2003. [cytowanie na str. 13, 14]
- [85] W. P. Kegelmeyer, J. M. Pruneda, P. D. Bourland, A. Hillis, M. W. Riggs, M. L. Nipper. Computer-aided mammographic screening for spiculated lesions. *Radiology*, 191:331–337, 1994. [cytowanie na str. 58]
- [86] J. K. Kim, H. W. Park. Statistical textural features for detection of microcalcifications in digitized mammograms. *IEEE Transactions on Medical Imaging*, 18(3):231–238, 1999. [cytowanie na str. 61, 79]
- [87] H. Kobatake, M. Murakami, H. Takeo, S. Nawano. Computerized detection of malignant tumors on digital mammograms. *IEEE Transactions on Medical Imaging*, 18:369–378, 1999. [cytowanie na str. 60]
- [88] D. Kufe, R. Pollock. *Cancer Medicine*. BC Decker Inc., 6th edition, 2003. <http://www.ncbi.nlm.nih.gov/books/bv.fcgi?rid=cmed>. [cytowanie na str. 21, 23, 25, 29, 31]
- [89] M. J. Lado, P. G. Tahoces, A. J. Mendez, M. Souto, J. J. Vidal. A wavelet-based algorithm for detecting clustered microcalcifications in digital mammograms. *Medical Physics*, 26:1294–1305, 1999. [cytowanie na str. 69, 70]
- [90] S. M. Lai, X. Li, W. F. Bischof. On techniques for detecting circumscribed masses in mammograms. *IEEE Transactions on Medical Imaging*, 8(4):377–386, 1989. [cytowanie na str. 44]
- [91] A. F. Laine. Wavelets in temporal and spatial processing of biomedical images. *Biomedical Engineering, Annual Reviews*, 02:511–550, 2000. [cytowanie na str. 48]
- [92] A. F. Laine, X. Zong. A multiscale sub-octave wavelet transform for de-noising and enhancement. *Wavelet Applications in Signal and Image Processing IV. Proceeding of SPIE.*, 2825:238–249, 1996. [cytowanie na str. 48, 56]
- [93] H. Li, K. J. R. Liu, S. C. B. Lo. Fractal modeling and segmentation for the enhancement of microcalcifications in digital mammograms. *IEEE Transactions on Medical Imaging*, 16(6):785–798, 1997. [cytowanie na str. 52, 56]
- [94] H. D. Li, Y. Wang, K. J. R. Liu, S. C. B. Lo, M. T. Freedman. Computerized radiographic mass detection – part I: lesion site selection by morphological enhancement and contextual segmentation. *IEEE Transactions on Medical Imaging*, 20(4):289–301, 2001. [cytowanie na str. 59]

- [95] H. D. Li, M. Kallergi, L. P. Clarke, V. K. Jain, R. A. Clark. Markov random field for tumor detection in digital mammography. *IEEE Transactions on Medical Imaging*, 14:565–576, 1995. [cytowanie na str. 58, 59, 60, 74, 75, 79]
- [96] H. D. Li, Y. Wang, K. J. R. Liu, S. B. Lo, M. T. Freedman. Computerized radiographic mass detection—part II: decision support by featured database visualization and modular neural networks. *IEEE Transactions on Medical Imaging*, 20(4):302–313, 2001. [cytowanie na str. 74]
- [97] S. L. Liu. *The analysis of digital mammograms: spiculated tumor detection and normal mammogram characterization*. PhD thesis, Purdue University, 1999. [cytowanie na str. 2, 26, 27, 29, 30, 77]
- [98] S. L. Liu, C. F. Babbs, E. J. Delp. Multiresolution detection of spiculated lesions in digital mammograms. *IEEE Transactions on Image Processing*, 10(6):874–884, 2001. [cytowanie na str. 58]
- [99] J. Y. Lo, M. Gavrielides, M. K. Markey, J. L. Jesneck. Computer-aided classification of breast microcalcification clusters: merging of features from image processing and radiologists. *Medical Imaging 2003: Image Processing*, editors: M. Sonka, J. M. Fitzpatrick, pages 882–889. Proceedings of SPIE Vol. 5032, 2003. [cytowanie na str. 1, 186]
- [100] A. Malich. Tumor detection rate of a new commercially available computer-aided detection system. *European Radiology*, 11:2454–2459, 2001. [cytowanie na str. 33]
- [101] A. Malich, D. Saunder, Ch. Marx, M. Facius, T. Boehm, S. O. Pfeiderer, M. Fleck, W. A. Kaiser. Influence of breast lesion size and histologic findings on tumor detection rate of a computer-aided detection system. *Radiology*, 228(3):851–856, 2003. [cytowanie na str. 33]
- [102] M. K. Markey, J. Y. Lo, C. E. Floyd. Differences between computer-aided diagnosis of breast masses and that of calcifications. *Radiology*, 223:489, 2002. [cytowanie na str. 187]
- [103] T. Matsubara, H. Fujita, T. Endo, K. Horita, M. Ikeda, C. Kido, T. Ishigaki. Development of mass detection algorithm based on adaptive thresholding technique in digital mammograms. *Proc. of 3rd International Workshop on Digital Mammography. Digital Mammography*, 391–396, Elsevier Science, 1996. [cytowanie na str. 59, 75]
- [104] R. Mekle, A. F. Laine, S. Smith, C. Singer, T. Koenigsberg, M. Brown. Evaluation of a multiscale enhancement protocol for digital mammography. *Wavelet Applications in Signal and Image Processing VIII. Proceeding of SPIE.*, 4119:1038–1049, 2000. [cytowanie na str. 48, 54, 56]
- [105] W. M. Morrow, R. B. Paranjape, R. M. Rangayyan, J. E. L. Desaultes. Region-based contrast enhancement of mammograms. *IEEE Transactions on Medical Imaging*, 11(3):392–406, 1992. [cytowanie na str. 56]
- [106] M. J. Morton, D. H. Whaley, K. R. Brandt i in. Screening mammograms: interpretation with computer-aided detection — prospective evaluation. *Radiology*, 239:375–383, 2006. [cytowanie na str. 34]
- [107] N. R. Mudigonda, R. M. Rangayyan, J. E. L. Desaultes. Gradient and texture analysis for the classification of mammographic masses. *IEEE Transactions on Medical Imaging*, 19(10):1032–1043, 2000. [cytowanie na str. 76]

## BIBLIOGRAFIA

- [108] T. Netsch, H. O. Peitgen. Scale-space signatures for the detection of clustered microcalcifications in digital mammograms. *IEEE Transactions on Medical Imaging*, 18(9):774–786, 1999. [cytowanie na str. 62, 64, 65, 66, 68]
- [109] M. Nieniewski. Morphological method for extraction of microcalcifications in mammograms for breast cancer diagnosis. *Machine Graphics and Vision*, 8(3):427–448, 1999. [cytowanie na str. 57]
- [110] Oprogramowanie ROCKIT i DBM MRMC. [http://www-radiology.uchicago.edu/krl/KRL\\_ROC/software\\_index6.htm](http://www-radiology.uchicago.edu/krl/KRL_ROC/software_index6.htm). [cytowanie na str. 179]
- [111] C. J. Orsi, D. B. Kopans. Mammographic feature analysis. *Seminars in Roentgenology*, 28:204–229, 1998. [cytowanie na str. 22]
- [112] S. Osowski. *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa, 1996. [cytowanie na str. 81]
- [113] N. Petrick, H. P. Chan, B. Sahier, D. Wei. An adaptive density-weighted contrast enhancement filter for mammographic breast mass detection. *IEEE Transactions on Medical Imaging*, 15:59–67, 1996. [cytowanie na str. 60]
- [114] E. D. Pisano, S. Zong, B. M. Hemminger, M. C. DeLuca, R. E. Johnstone, K. E. Muller, M. P. Braeuning, S. M. Pizer. Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. *Journal of Digital Imaging*, 11(4):193–200, 1998. [cytowanie na str. 56]
- [115] E. D. Pisano, C. Gatsonis, E. Hendrick, M. Yaffe, J. K. Baum, S. Acharyya, E. F. Conant, L. L. Fajardo, L. Bassett, C. D’Orsi, R. Jong, M. Rebner. Diagnostic performance of digital versus film mammography for breast-cancer screening. *The New England Journal of Medicine*, 353(17):1773–1783, 2005. [cytowanie na str. 36]
- [116] T. Podsiadły-Marczykowska, A. Guzik. Mammographic ontology, model structure, definitions and concept instances. *Bio-Algorithms and Medical Systems*, 1(1):247–252, 2005. [cytowanie na str. 12]
- [117] T. Podsiadły-Marczykowska, A. Przelaskowski. Poprawa efektywności interpretacji diagnostycznej i komunikacji: obiektywizacja oceny zmian w mammografii. *Materiały Sympozjum Inżynieria Biomedyczna i Telemedycyna 2006. Prace naukowe Politechniki Warszawskiej, Elektronika, zeszyt 157*, red. Antoni Grzanka, str. 43–49, 2006. [cytowanie na str. 12]
- [118] T. Podsiadły-Marczykowska, A. Przelaskowski, A. Wróblewska, P. Boniński. A framework for integrated, diagnosis supporting interface for mammograms description – advantages and pitfalls. *Proceedings of the Second IASTED International Conference on Human-Computer Interaction*, pages 80–86, Chamonix, France, 14–16 March 2007. [cytowanie na str. 10, 12, 84, 143, 186]
- [119] T. Podsiadły-Marczykowska, A. Wróblewska, A. Przelaskowski. Enhancement of accuracy in mammogram interpretation using ontology-driven editor for lesions description and CAD tool – preliminary results. *Journal of Medical Informatics and Technologies, XII międzynarodowa konferencja Medical Informatics and Technologies*, 11:235–243, Published by Computer Systems Dept., University of Silesia, November 2007. [cytowanie na str. 10, 84, 94]
- [120] W. E. Polakowski, D. A. Cournoyer, S. K. Rogers, M. P. DeSimio, D. W. Ruck, J. W. Hoffmeister, R. A. Reiners. Computer-aided breast cancer detection and diagnosis of masses using difference of Gaussians and derivative-based feature saliency. *IEEE Transactions on Medical Imaging*, 16:811–819, 1997. [cytowanie na str. 60, 75]

- [121] W. K. Pratt. *Digital Image Processing*. A Wiley – Interscience publication, John Wiley & Sons, New York, 1991. [cytowanie na str. 41, 136]
- [122] A. Przelaskowski, P. Hałasa, D. Rieves. Progressive and interactive modes of image transmission: optimized wavelet-based image representation. *Report of 3rd International Conference on Telemedicine and Multimedia Communication in J. International Telemedicine Academy*, 1(1):53, 2005. [cytowanie na str. 7, 139, 158]
- [123] A. Przelaskowski, P. Surowski. Metody optymalizacji reprezentacji medycznych danych obrazowych do archiwizacji i transmisji telemedycznej. Projekt badawczy KBN 7T11E03920, 2002. [cytowanie na str. 1, 19, 22, 26]
- [124] A. Przelaskowski. *Falkowe metody kompresji danych obrazowych*, rozprawa habilitacyjna, Prace naukowe – Elektronika, zeszyt 138. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2002. [cytowanie na str. 45, 48, 51, 52, 53, 54, 55, 56, 87, 231]
- [125] A. Przelaskowski. Vector quality measure of lossy compressed medical images. *Computers in Biology and Medicine*, 34(3):193–207, 2004. [cytowanie na str. 87]
- [126] A. Przelaskowski. *Komputerowe wspomaganie diagnostyki obrazowej*. przygotowywana monografia, dostępna pod adresem: [www.ire.pw.edu.pl/arturp](http://www.ire.pw.edu.pl/arturp). Politechnika Warszawska, 2006. [cytowanie na str. 10, 11, 13, 53]
- [127] A. Przelaskowski, R. Józwiak, T. Krzyżewski, A. Wróblewska. Porządkowanie informacji diagnostycznej w kompresowanych obrazach medycznych: progresja wiarygodności. *Materiały V Sympozjum „Techniki Przetwarzania Obrazu”*, str. 435–448, 2006. [cytowanie na str. 139]
- [128] A. Przelaskowski, R. Józwiak, T. Krzyżewski, A. Wróblewska. The ordering of diagnostic information in encoded medical image: accuracy progression. *Optoelectronics Review*, 16(1):49–59, 2008. [cytowanie na str. 7, 139]
- [129] A. Przelaskowski, T. Podsiadły-Marczykowska, A. Wróblewska, P. Boniński, P. Bargieł. Computer-aided interpretation of medical images: mammography case study. *Machine Graphics and Vision*, in print, 2007. [cytowanie na str. 12, 84, 142, 143]
- [130] A. Przelaskowski, P. Wojtaszczyk, A. Wróblewska. Modelowanie zmian patologicznych sutka z wykorzystaniem analizy wielorozdzielczej. *Structures, Waves, Human Health*, 14(2):135–142, 2005. [cytowanie na str. 84, 87]
- [131] A. Przelaskowski, A. Wróblewska, P. Bargieł. Wspomaganie decyzji diagnostycznych w mammografii. *Structures, Waves, Human Health*, 14(2):127–134, 2005. [cytowanie na str. 84]
- [132] H. Qi, W. E. Snyder. Lesion detection and characterization in digital mammography by Bezier histograms. *Proc. 20th Annual Inter. Conf. IEEE Engineering in Medicine and Biology Society*, 20(2), 1998. [cytowanie na str. 59]
- [133] W. Qian, L. Li, L. Clarke, R. A. Clark, J. Thomas. Comparison of adaptive and non adaptive CAD methods for mass detection. *Academic Radiology*, 6:471–480, 1999. [cytowanie na str. 60]
- [134] S. Quadrades, A. Sacristan. Automated extraction of microcalcifications BI-RADS numbers in mammograms. In *Proc. IEEE ICIP*, pages 289–292, 2001. [cytowanie na str. 57]

## BIBLIOGRAFIA

- [135] R. M. Rangayyan, N. R. Mudigonda, J. E. L. Desautels. Boundary modelling and shape analysis methods for classification of mammographic masses. *Medical and Biological Engineering and Computing*, 38:487–495, 2000. [cytowanie na str. 75]
- [136] J. Rogowska. Overview and fundamentals of medical image segmentation. *Handbook of Medical Imaging*. Academic Press, 2000. [cytowanie na str. 44]
- [137] M. F. Salfity, G. H. Kaufmann, P. Granitto, H. A. Ceccatto. Automated detection and classification of clustered microcalcifications using morphological filtering and statistical techniques, <http://citeseer.ist.psu.edu/489768.html>, Instituto de Fisica Rosario, Argentina. 2000. [cytowanie na str. 57, 76]
- [138] M. P. Sampat, M. K. Markey, A. C. Bovik. Computer-aided detection and diagnosis in mammography. *Handbook of Image and Video Processing*. Elsevier Academic Press, 2nd edition, 1195–1217, 2005. [cytowanie na str. 16, 23, 24, 52, 58, 59, 60]
- [139] M. De Santo, M. Molinara, F. Tortorella, M. Vento. Automatic classification of clustered microcalcifications by a multiple expert system. *Pattern Recognition*, 36:1467–1477, 2003. [cytowanie na str. 76, 77]
- [140] L. Shen, R.M. Rangayyan, J.E.L. Desautels. Shape analysis of mammographic calcifications. *Proceedings of Fifth Annual IEEE Symposium on Computer-Based Medical Systems*, pages 123–128, 1992. [cytowanie na str. 76, 79, 136]
- [141] P. E. Shile, J. A. Guingrich. Detecting "missed" breast cancers: a comparison of CAD systems. *Applied Radiology, Supplement*, pages 1–3, 2003. [cytowanie na str. 33]
- [142] M. A. Sid-Ahmed. *Image Processing. Theory, algorithms and architecture*. McGraw-Hill, Inc., New York, 1995. [cytowanie na str. 41]
- [143] S. Singh, K. Bovis. An evolution of contrast enhancement techniques for mammographic breast masses. *IEEE Transactions on Information Technology in Biomedicine*, 9(1):109–119, 2005. [cytowanie na str. 52, 56]
- [144] W. Skarbek. *Multimedia. Algorytmy i standardy kompresji*. Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1998. [cytowanie na str. 54]
- [145] M. Sonka, V. Hlavac, R. Boyle. *Image Processing, Analysis and Machine Vision*. PWS Publishing, 2. edition, 1998. [cytowanie na str. 115, 116, 117, 118]
- [146] M. S. Soo, J. A. Baker, L. E. Rosen. Sonographic detection and sonographically guided biopsy of breast microcalcifications. *American Journal of Roentgenology*, 180(4):941–948, 2003. [cytowanie na str. 35]
- [147] Special issue. Special issue on wavelets in medical imaging. *IEEE Transactions on Medical Imaging*, 22(3), 2003. [cytowanie na str. 87]
- [148] R. N. Strickland, H. I. Hahn. Wavelet transforms for detecting microcalcifications in mammograms. *IEEE Transactions on Medical Imaging*, 15(2):218–229, 1996. [cytowanie na str. 56, 65]
- [149] Y. Sun, Ch. Babbs, E. J. Delp. A normal mammogram classifier using binary decision trees with multiresolution features. In *Proceedings of the 6th International Workshop on Digital Mammography*, pages 363–367, Springer, Bremen, June 2002. [cytowanie na str. 79]

- [150] J. S. Suri, R. M. Rangayyan. *Recent Advances in Breast Imaging, Mammography and Computer-Aided Diagnosis of Breast Cancer*, volume PM155. SPIE International Society for Optical E, SPIE Press Monograph, 2006. [cytowanie na str. 15, 36, 39]
- [151] T. Ślubowski, M. Ślubowska, A. Wojciechowski. Techniki diagnostyczne w raku piersi. część I: metody obrazowe i ich modyfikacje. *Ginekologia Polska*, 78:388–392, 2007. [cytowanie na str. 35, 36]
- [152] T. Ślubowski, M. Ślubowska, A. Wojciechowski. Techniki diagnostyczne w raku piersi. część II: metody fizyczne i biopsyjne. *Ginekologia Polska*, 78:479–483, 2007. [cytowanie na str. 19]
- [153] M. Ustymowicz, M. Nieniewski. Morphological method of microcalcifications detection in mammograms. *Proceedings of the International Conference on Computer Vision and Graphics*, pages 29–32, Kluwer, September 2004. [cytowanie na str. 57]
- [154] M. Ustymowicz. *Automatyczna detekcja i klasyfikacja skupisk mikrozwapnień w cyfrowych obrazach mammograficznych*. rozprawa doktorska, Instytut Podstawowych Problemów Techniki Polskiej Akademii Nauk, 2005. [cytowanie na str. 69, 71]
- [155] T. C. Wang, N. B. Karayiannis. Detection of microcalcifications in digital mammograms using wavelets. *IEEE Transactions on Medical Imaging*, 17(4):498–509, 1998. [cytowanie na str. 56]
- [156] M. A. Wirth. Performance evaluation of CADe algorithms in mammography. *Recent Advances in Breast Imaging, Mammography and Computer-Aided Diagnosis of Breast Cancer*. volume PM155 SPIE International Society for Optical E, SPIE Press Monograph, 2006. [cytowanie na str. 51]
- [157] K. S. Woods. *Automated image analysis techniques for digital mammography*. PhD thesis, University of South Florida, 1994. [cytowanie na str. 76]
- [158] A. Wróblewska. Wspomaganie diagnostyki mammograficznej: poprawa percepcji zmian patologicznych. *Materiały VIII Seminarium Radiokomunikacji i Techniki Multimedialnych*, str. 87–94, Warszawa, grudzień 2007. [cytowanie na str. 84, 94]
- [159] A. Wróblewska, P. Boniński, A. Przelaskowski, Marian Kazubek. Segmentation and feature extraction for reliable classification of microcalcifications in digital mammograms. *Optoelectronics Review*, 11(3):227–235, 2003. [cytowanie na str. 84, 131, 135]
- [160] A. Wróblewska, A. Przelaskowski. System automatycznej detekcji i klasyfikacji mikrozwapnień w cyfrowej mammografii. *Elektronizacja*, 3:8–11, 2003. *Materiały IV Sympozjum „Techniki Przetwarzania Obrazu”*, 299–305, 2002. [cytowanie na str. 62, 84, 120, 131, 135]
- [161] A. Wróblewska, A. Przelaskowski. Detection of microcalcifications with shape marking in digital mammograms. *SCAR (The Society for Computer Applications in Radiology) Scientific Abstract Book*, pages 18–20, Vancouver, Canada, 2004. [cytowanie na str. 84, 120]
- [162] A. Wróblewska, A. Przelaskowski. Poprawa percepcji guzków i mikrozwapnień poprzez nieliniowe przetwarzanie wstępne mammogramów w dziedzinie falkowej. *Prace naukowe, Elektronika, z.157, Materiały Sympozjum „Inżynieria Biomedyczna i Telemedycyna IBiTel 2006”*, red. Antoni Grzanka, Politechnika Warszawska, Akademia Medyczna – Warszawa, str. 93–100, Warszawa, wrzesień 2006. [cytowanie na str. 84, 94]

## BIBLIOGRAFIA

- [163] A. Wróblewska, A. Przelaskowski, P. Bargieł, P. Boniński. MammoViewer – CAD application based on effective multiscale image analysis. *Polish Journal of Medical Physics & Engineering*, 11(1):17–28, 2005. [cytowanie na str. 84, 139]
- [164] A. Wróblewska, A. Przelaskowski, P. Bargieł, P. Boniński. MammoViewer – narzędzie do wielorozdzielczej analizy obrazów medycznych. *Materiały ogólnopolskiej konferencji „Fizyka i inżynieria we współczesnej medycynie i ochronie zdrowia – szanse i wyzwania członkostwa w Unii Europejskiej”*, str. 140–141, Warszawa, 2005. [cytowanie na str. 84]
- [165] A. Wróblewska, A. Przelaskowski, P. Bargieł, P. Boniński. Metoda klasteryzacji i segmentacji mikrozwapnień w celu redukcji wskazań fałszywych przy komputerowym wspomaganium mammografii. *Materiały XIV Krajowej Konferencji Naukowej: Biocybernetyka i Inżynieria Biomedyczna*, tom 1:396–401, Częstochowa, 2005. [cytowanie na str. 84, 120]
- [166] A. Wróblewska, A. Przelaskowski, P. Bargieł, P. Boniński. Two stage detection and clustering of microcalcifications in mammograms. *Biomedizinische Technik, Medical Physics, Proceeding of 14th International Conference of Medical Physics ICMP 2005*, 50 (supp 1):56–57, Nuremberg, Germany, September 2005. [cytowanie na str. 84, 120]
- [167] S. Yu, L. Guan. A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films. *IEEE Transactions on Medical Imaging*, 19(2):115–125, 2000. [cytowanie na str. 62, 68, 72, 76, 77, 79, 136]
- [168] K. W. Zieliński, M. Strzelecki. *Komputerowa analiza obrazu biomedycznego. Wstęp do morfometrii i patologii ilościowej*. WN PWN, Warszawa, 2001. [cytowanie na str. 41, 43, 44, 113, 136]
- [169] A. R. Zolghadrasli, Z. Maghsoodzadeh. Modification of mammograms for early diagnosis of breast cancer using wavelet and neural networks. *Proceedings of IEEE International Conference on Computer Systems and Applications*, pages 288–295, March 8, 2006. [cytowanie na str. 40, 50]



# Załączniki



## Dodatek A

---

# Obliczenia z programu DBM MRMC, pracującego na wynikach testów klinicznych – porównanie krzywych ROC

---

### A.1 Analiza dla trzech radiologów: Reader 1 – Ekspert, Reader 2 – Stażysta, Reader 3 – Specjalista

DBMTRMC 2.1 BETA 2

MULTIREADER-MULTICASE ROC ANALYSIS OF VARIANCE  
TRAPEZOIDAL AREA ANALYSIS

Analysis 2 -- Fixed Readers and Random Cases -- treats only cases as a random sample -- results apply to the population of cases but only for the readers used in this study

For the analysis the null hypothesis of equal treatments is tested in part (a), treatment difference 95% confidence intervals are given in part (b), and treatment 95% confidence intervals are given in part (c). Parts (a) and (b) are based on the treatment x reader x case ANOVA while part (c) is based on the reader x case ANOVA for the specified treatment; these ANOVA tables are displayed before the analyses. Different error terms are used as indicated for parts (a), (b), and (c) according to whether readers and cases are treated as fixed or random factors. Note that the treatment confidence intervals in part (c) are based only on the data for the specified treatment, rather than the pooled data. Treatment difference 95% confidence intervals for each reader are presented in part (d) of Analysis 2; each interval is based on the treatment x case ANOVA table (not included) for the specified reader.

DODATEK A. OBLICZENIA Z PROGRAMU DBM MRMC, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH  
- PORÓWNANIE KRZYWYCH ROC

3 treatments, 3 readers, 51 cases (18 normal, 33 abnormal)

Curve fitting methodology is TRAPEZOIDAL/WILCOXON

Dependent variable is AREA

Normalized pseudovalues used in analyses.

=====  
\*\*\*\*\* Estimates \*\*\*\*\*  
=====

TREATMENT			
READER	1	2	3
1	0.77272727	0.81818182	0.83333333
2	0.64478114	0.57996633	0.68350168
3	0.61616162	0.68013468	0.72558923

TREATMENT MEANS (averaged across readers)

1	0.67789001
2	0.69276094
3	0.74747475

TREATMENT MEAN DIFFERENCES

1 - 2	-0.01487093
1 - 3	-0.06958474
2 - 3	-0.05471380

=====  
\*\*\*\*\* ANOVA Tables \*\*\*\*\*  
=====

TREATMENT X READER X CASE ANOVA			
Source	SS	DF	MS
T	0.41089581	2	0.20544790
R	2.49930232	2	1.24965116
C	37.96305184	50	0.75926104
TR	0.27797239	4	0.06949310
TC	4.40998471	100	0.04409985
RC	41.52988766	100	0.41529888
TRC	9.14892327	200	0.04574462
TOTAL	96.24001801	458	

READER X CASE ANOVAs for each treatment

Mean Squares				
Source	df	Treatment 1	Treatment 2	Treatment 3
R	2	0.35446780	0.72961730	0.30455226
C	50	0.28669918	0.29156407	0.26919748
RC	100	0.14986196	0.17857045	0.17835569

=====  
\*\*\*\*\* Variance components estimates \*\*\*\*\*  
=====

(for sample size estimation for future studies)

Component	Estimate
-----------	----------

A.1. ANALIZA DLA TRZECH RADIOLOGÓW: READER 1 – EKSPERT, READER 2 – STAŻYSTA, READER 3 – SPECJALISTA

```

-----
Var(R)                0.00530
Var(C)                0.03840
Var(T*R)              0.00047
Var(T*C)              0.00000
Var(R*C)              0.12318
Var(T*R*C) + Var(Error) 0.04574

```

```

=====
*****      Analysis 2: Fixed Readers and Random Cases      *****
=====

```

(Results apply to the population of cases but only for the readers used in this study)

a) Test for H0: Treatments have the same AUC

Source	DF	Mean Square	F value	Pr > F
Treatment	2	0.20544790	4.66	0.0116
Error	100	0.04409985		

Error term: MS(TC)

Conclusion: The treatment AUCs are not equal,  $F(2,100) = 4.66$ ,  $p = .0116$ .

b) 95% confidence intervals for treatment differences

Treatment	Estimate	StdErr	DF	t	Pr > t	95% CI
1 - 2	-0.01487	0.02401	100	-0.62	0.5371	-0.06251 , 0.03276
1 - 3	-0.06958	0.02401	100	-2.90	0.0046	-0.11722 , -0.02195
2 - 3	-0.05471	0.02401	100	-2.28	0.0248	-0.10235 , -0.00708

\* H0: the 3 treatments are equal. To control the overall type I error rate at .05, we conclude that treatment differences with  $p < .05$  are significant only if the global test in (a) is also significant (i.e,  $p < .05$ ).  
Error term: MS(TC)

c) 95% treatment confidence intervals based on reader x case ANOVAs for each treatment (each analysis is based only on data for the specified treatment)

Treatment	Area	Std Error	DF	95% Confidence Interval
1	0.67789001	0.04328800	50	(0.59094351 , 0.76483652)
2	0.69276094	0.04365372	50	(0.60507986 , 0.78044202)
3	0.74747475	0.04194593	50	(0.66322388 , 0.83172562)

Error term: MS(C)

d) Treatment-by-case ANOVA CIs for each reader (each analysis is based only on data for the specified reader)

Reader	Treatment	Estimate	StdErr	DF	t	Pr > t	95% CI
1	1 - 2	-0.04545	0.02991	50	-1.52	0.1317	-0.10479, 0.01388
1	1 - 3	-0.06061	0.02991	50	-2.03	0.0454	-0.11994, -0.00127

DODATEK A. OBLICZENIA Z PROGRAMU DBM MRMC, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH  
- PORÓWNANIE KRZYWYCH ROC

1	2 - 3	-0.01515	0.02991	50	-0.51	0.6136	-0.07449,	0.04419
2	1 - 2	0.06481	0.04681	50	1.38	0.1692	-0.02805,	0.15768
2	1 - 3	-0.03872	0.04681	50	-0.83	0.4101	-0.13158,	0.05414
2	2 - 3	-0.10354	0.04681	50	-2.21	0.0292	-0.19640,	-0.01067
3	1 - 2	-0.06397	0.04724	50	-1.35	0.1787	-0.15770,	0.02975
3	1 - 3	-0.10943	0.04724	50	-2.32	0.0226	-0.20315,	-0.01570
3	2 - 3	-0.04545	0.04724	50	-0.96	0.3383	-0.13918,	0.04827

## A.2 Analiza dla dwóch doświadczonych radiologów: Reader 1 – Ekspert, Reader 2 – Specjalista

DBMRMC 2.1 BETA 2

MULTIREADER-MULTICASE ROC ANALYSIS OF VARIANCE  
TRAPEZOIDAL AREA ANALYSIS

3 treatments, 2 readers, 51 cases (18 normal, 33 abnormal)

Curve fitting methodology is TRAPEZOIDAL/WILCOXON

Dependent variable is AREA

Normalized pseudovalues used in analyses.

```

*****                               Estimates                               *****
=====
TREATMENT
-----
READER      1          2          3
-----
1          0.77272727  0.81818182  0.83333333
2          0.61616162  0.68013468  0.72558923
  
```

TREATMENT MEANS (averaged across readers)

```

-----
1          0.69444444
2          0.74915825
3          0.77946128
  
```

TREATMENT MEAN DIFFERENCES

```

-----
1 - 2      -0.05471380
1 - 3      -0.08501684
2 - 3      -0.03030303
  
```

```

*****                               ANOVA Tables                               *****
=====
TREATMENT X READER X CASE ANOVA
Source      SS          DF          MS
-----
T          0.37875103         2          0.18937552
R          1.37607415         1          1.37607415
C          34.17101255        50          0.68342025
  
```

A.2. ANALIZA DLA DWÓCH DOŚWIADCZONYCH RADIOLOGÓW: READER 1  
 – EKSPERT, READER 2 – SPECJALISTA

TR	0.03098040	2	0.01549020
TC	3.72275078	100	0.03722751
RC	15.20627292	50	0.30412546
TRC	4.24953008	100	0.04249530
TOTAL	59.13537192	305	

READER X CASE ANOVAs for each treatment

Source	df	Mean Squares		
		Treatment 1	Treatment 2	Treatment 3
R	1	0.62507652	0.48595381	0.29602422
C	50	0.26709529	0.25824352	0.23253645
RC	50	0.15082023	0.12014378	0.11815205

\*\*\*\*\* Variance components estimates \*\*\*\*\*

(for sample size estimation for future studies)

Component	Estimate
Var(R)	0.00718
Var(C)	0.06409
Var(T*R)	0.00000
Var(T*C)	0.00000
Var(R*C)	0.08721
Var(T*R*C) + Var(Error)	0.04250

\*\*\*\*\* Analysis 2: Fixed Readers and Random Cases \*\*\*\*\*

(Results apply to the population of cases but only for the readers used in this study)

a) Test for H0: Treatments have the same AUC

Source	DF	Mean Square	F value	Pr > F
Treatment	2	0.18937552	5.09	0.0079
Error	100	0.03722751		

Error term: MS(TC)

Conclusion: The treatment AUCs are not equal,  $F(2,100) = 5.09$ ,  $p = .0079$ .

b) 95% confidence intervals for treatment differences

Treatment	Estimate	StdErr	DF	t	Pr > t	95% CI
1 - 2	-0.05471	0.02702	100	-2.03	0.0455	-0.10832 , -0.00111
1 - 3	-0.08502	0.02702	100	-3.15	0.0022	-0.13862 , -0.03141
2 - 3	-0.03030	0.02702	100	-1.12	0.2647	-0.08391 , 0.02330

\* H0: the 3 treatments are equal. To control the overall type I error rate at .05, we conclude that treatment differences with  $p < .05$  are significant only if the global test in (a) is also significant (i.e,  $p < .05$ ).

DODATEK A. OBLICZENIA Z PROGRAMU DBM MRMC, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH  
- PORÓWNANIE KRZYWYCH ROC

Error term: MS(TC)

c) 95% treatment confidence intervals based on reader x case ANOVAs  
for each treatment (each analysis is based only on data for the  
specified treatment)

Treatment	Area	Std Error	DF	95% Confidence Interval
1	0.69444444	0.05117208	50	(0.59166231 , 0.79722658)
2	0.74915825	0.05031699	50	(0.64809361 , 0.85022289)
3	0.77946128	0.04774693	50	(0.68355875 , 0.87536381)

Error term: MS(C)

d) Treatment-by-case ANOVA CIs for each reader  
(each analysis is based only on data for the specified reader)

Reader	Treatment	Estimate	StdErr	DF	t	Pr > t	95% CI
1	1 - 2	-0.04545	0.02991	50	-1.52	0.1317	-0.10479, 0.01388
1	1 - 3	-0.06061	0.02991	50	-2.03	0.0454	-0.11994, 0.00127
1	2 - 3	-0.01515	0.02991	50	-0.51	0.6136	-0.07449, 0.04419
2	1 - 2	-0.06397	0.04724	50	-1.35	0.1787	-0.15770, 0.02975
2	1 - 3	-0.10943	0.04724	50	-2.32	0.0226	-0.20315, 0.01570
2	2 - 3	-0.04545	0.04724	50	-0.96	0.3383	-0.13918, 0.04827

## Dodatek B

---

# Obliczenia z programu ROCKIT, pracującego na wynikach testów klinicznych

---

Używane oprogramowanie:

JROCFIT:

Maximum likelihood estimation of a binormal ROC curve from categorical rating data.

Java translation by John Eng, M.D.

The Russell H. Morgan Department of Radiology and Radiological Science  
Johns Hopkins University, Baltimore, Maryland, USA

Version 1.0.2, March 2004

Original Fortran program ROCFIT by Charles Metz and colleagues  
Department of Radiology, University of Chicago January 1994

### B.1 I tura – oryginał, trzech radiologów: Ekspert, Stażysta, Specjalista

DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing strongest evidence of positivity (e.g., that abnormality is present).

Number of actually negative cases = 54

Number of actually positive cases = 99

RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	53	1	0	0	0
Actually positive cases	54	10	22	10	3

OBSERVED OPERATING POINTS:

DODATEK B. OBLICZENIA Z PROGRAMU ROCKIT, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH

FPF: 0.0000 0.0000 0.0000 0.0000 0.0185 1.0000  
TPF: 0.0000 0.0303 0.1313 0.3535 0.4545 1.0000

WARNINGS AND ERROR MESSAGES:

Data are degenerate. Implied exact-fit  
binormal ROC curve is horizontal at constant  
TPF=0.4545.

## B.2 II tura – oryginał, trzech radiologów: Ekspert, Stażysta, Specjalista

DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing  
strongest evidence of positivity (e.g., that abnormality is  
present).

Number of actually negative cases = 54

Number of actually positive cases = 99

RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	38	3	6	5	2
Actually positive cases	46	10	11	14	18

OBSERVED OPERATING POINTS:

FPF: 0.0000 0.0370 0.1296 0.2407 0.2963 1.0000  
TPF: 0.0000 0.1818 0.3232 0.4343 0.5354 1.0000

INITIAL VALUES OF PARAMETERS:

A = 0.4292  
B = 0.7608  
Z(K): 0.5347 0.7036 1.1282 1.7866  
LOGL = -196.2178

FINAL VALUES OF PARAMETERS:

Procedure converges after 5 iterations.  
A = 0.5242  
B = 0.8442  
Z(K): 0.5243 0.7791 1.1505 1.7108  
LOGL = -194.7193

VARIANCE-COVARIANCE MATRIX:

A	0.0707	0.0450	0.0328	0.0246	0.0117	-0.0103
B	0.0450	0.0544	0.0111	0.0005	-0.0163	-0.0448
Z(1)	0.0328	0.0111	0.0320	0.0283	0.0234	0.0165
Z(2)	0.0246	0.0005	0.0283	0.0312	0.0291	0.0273
Z(3)	0.0117	-0.0163	0.0234	0.0291	0.0394	0.0453
Z(4)	-0.0103	-0.0448	0.0165	0.0273	0.0453	0.0804

CORRELATION MATRIX:

A	1.0000	0.7250	0.6888	0.5228	0.2209	-0.1360
B	0.7250	1.0000	0.2664	0.0117	-0.3512	-0.6765
Z(1)	0.6888	0.2664	1.0000	0.8941	0.6574	0.3251
Z(2)	0.5228	0.0117	0.8941	1.0000	0.8292	0.5452
Z(3)	0.2209	-0.3512	0.6574	0.8292	1.0000	0.8054

B.2. II TURA – ORYGINAL, TRZECH RADIOLOGÓW: EKSPERT, STAŻYSTA,  
SPECJALISTA

Z(4) -0.1360 -0.6765 0.3251 0.5452 0.8054 1.0000

SUMMARY OF ROC CURVE:

Area = 0.6556  
Std. Dev. (Area) = 0.0636

ESTIMATED BINORMAL ROC CURVE WITH ASYMMETRIC 95% CONFIDENCE  
INTERVAL:

FPF	TPF	95% Conf. Interv.
0.005	0.0494	(0.0057, 0.2196)
0.010	0.0749	(0.0134, 0.2528)
0.020	0.1132	(0.0303, 0.2934)
0.030	0.1437	(0.0479, 0.3218)
0.040	0.1700	(0.0657, 0.3448)
0.050	0.1936	(0.0833, 0.3647)
0.060	0.2152	(0.1005, 0.3826)
0.070	0.2352	(0.1174, 0.3990)
0.080	0.2539	(0.1339, 0.4145)
0.090	0.2716	(0.1498, 0.4292)
0.100	0.2885	(0.1653, 0.4432)
0.110	0.3046	(0.1803, 0.4569)
0.120	0.3200	(0.1947, 0.4701)
0.130	0.3348	(0.2086, 0.4831)
0.140	0.3491	(0.2221, 0.4958)
0.150	0.3629	(0.2350, 0.5084)
0.200	0.4262	(0.2928, 0.5687)
0.250	0.4821	(0.3406, 0.6258)
0.300	0.5326	(0.3810, 0.6796)
0.400	0.6220	(0.4467, 0.7750)
0.500	0.6999	(0.5012, 0.8521)
0.600	0.7697	(0.5507, 0.9112)
0.700	0.8331	(0.5996, 0.9536)
0.800	0.8915	(0.6523, 0.9811)
0.900	0.9459	(0.7182, 0.9958)
0.950	0.9721	(0.7664, 0.9990)

ESTIMATES OF EXPECTED OPERATING POINTS ON FITTED ROC CURVE:

Expected Operating Point ( FPF , TPF )	95% C.I. of Lower Bound ( FPF , TPF )	95% C.I. of Upper Bound ( FPF , TPF )
(0.0436, 0.1788)	(0.0117, 0.0824)	(0.1240, 0.3260)
(0.1250, 0.3274)	(0.0618, 0.2190)	(0.2232, 0.4528)
(0.2179, 0.4469)	(0.1302, 0.3352)	(0.3325, 0.5630)
(0.3000, 0.5325)	(0.1908, 0.4151)	(0.4311, 0.6472)

WARNINGS AND ERROR MESSAGES:

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.  
Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.

### B.3 II tura – przetworzone, trzech radiologów: Ekspert, Stażysta, Specjalista

DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing strongest evidence of positivity (e.g., that abnormality is present).

Number of actually negative cases = 54

Number of actually positive cases = 99

RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	34	3	8	5	4
Actually positive cases	35	9	15	13	27

OBSERVED OPERATING POINTS:

FPF: 0.0000 0.0741 0.1667 0.3148 0.3704 1.0000

TPF: 0.0000 0.2727 0.4040 0.5556 0.6465 1.0000

INITIAL VALUES OF PARAMETERS:

A = 0.5997

B = 0.8465

Z(K): 0.3304 0.4818 0.9674 1.4464

LOGL = -211.3073

FINAL VALUES OF PARAMETERS:

Procedure converges after 4 iterations.

A = 0.6573

B = 0.9054

Z(K): 0.3204 0.5413 0.9839 1.4026

LOGL = -210.2221

VARIANCE-COVARIANCE MATRIX:

A	0.0591	0.0371	0.0309	0.0258	0.0145	0.0025
B	0.0371	0.0552	0.0120	0.0035	-0.0150	-0.0347
Z(1)	0.0309	0.0120	0.0301	0.0267	0.0208	0.0157
Z(2)	0.0258	0.0035	0.0267	0.0284	0.0249	0.0226
Z(3)	0.0145	-0.0150	0.0208	0.0249	0.0351	0.0385
Z(4)	0.0025	-0.0347	0.0157	0.0226	0.0385	0.0573

CORRELATION MATRIX:

A	1.0000	0.6490	0.7341	0.6297	0.3193	0.0438
B	0.6490	1.0000	0.2943	0.0891	-0.3416	-0.6160
Z(1)	0.7341	0.2943	1.0000	0.9136	0.6413	0.3791
Z(2)	0.6297	0.0891	0.9136	1.0000	0.7892	0.5589
Z(3)	0.3193	-0.3416	0.6413	0.7892	1.0000	0.8575
Z(4)	0.0438	-0.6160	0.3791	0.5589	0.8575	1.0000

SUMMARY OF ROC CURVE:

Area = 0.6870

Std. Dev. (Area) = 0.0530

ESTIMATED BINORMAL ROC CURVE WITH ASYMMETRIC 95% CONFIDENCE  
INTERVAL:

FPF	TPF	95% Conf. Interv.
0.005	0.0470	(0.0043, 0.2339)

*B.4. II TURA – PRZETWORZONE+AWPKM, TRZECH RADIOLOGÓW:  
EKSPERT, STAŻYSTA, SPECJALISTA*

0.010	0.0736	(0.0109, 0.2725)
0.020	0.1146	(0.0265, 0.3193)
0.030	0.1478	(0.0436, 0.3515)
0.040	0.1767	(0.0614, 0.3772)
0.050	0.2026	(0.0794, 0.3991)
0.060	0.2264	(0.0976, 0.4185)
0.070	0.2485	(0.1156, 0.4361)
0.080	0.2693	(0.1334, 0.4525)
0.090	0.2888	(0.1509, 0.4678)
0.100	0.3074	(0.1681, 0.4823)
0.110	0.3252	(0.1849, 0.4961)
0.120	0.3421	(0.2013, 0.5095)
0.130	0.3585	(0.2173, 0.5224)
0.140	0.3742	(0.2329, 0.5349)
0.150	0.3893	(0.2481, 0.5471)
0.200	0.4584	(0.3173, 0.6050)
0.250	0.5187	(0.3762, 0.6588)
0.300	0.5725	(0.4263, 0.7094)
0.400	0.6658	(0.5071, 0.7992)
0.500	0.7445	(0.5718, 0.8715)
0.600	0.8123	(0.6283, 0.9258)
0.700	0.8711	(0.6818, 0.9633)
0.800	0.9221	(0.7369, 0.9862)
0.900	0.9654	(0.8018, 0.9973)
0.950	0.9841	(0.8462, 0.9995)

ESTIMATES OF EXPECTED OPERATING POINTS ON FITTED ROC CURVE:

Expected Operating Point ( FPF , TPF )	95% C.I. of Lower Bound ( FPF , TPF )	95% C.I. of Upper Bound ( FPF , TPF )
(0.0804, 0.2701)	(0.0306, 0.1497)	(0.1753, 0.4256)
(0.1626, 0.4077)	(0.0883, 0.2856)	(0.2688, 0.5395)
(0.2942, 0.5664)	(0.1917, 0.4475)	(0.4165, 0.6795)
(0.3743, 0.6433)	(0.2546, 0.5238)	(0.5077, 0.7501)

WARNINGS AND ERROR MESSAGES:

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.

**B.4 II tura – przetworzone+AWPKM, trzech radiologów:  
Ekspert, Stażysta, Specjalista**

DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing  
strongest evidence of positivity (e.g., that abnormality is  
present).

Number of actually negative cases = 54

Number of actually positive cases = 99

RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	34	3	8	5	4

DODATEK B. OBLICZENIA Z PROGRAMU ROCKIT, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH

Actually positive cases      26      10      21      14      28

OBSERVED OPERATING POINTS:

FPF: 0.0000 0.0741 0.1667 0.3148 0.3704 1.0000  
TPF: 0.0000 0.2828 0.4242 0.6364 0.7374 1.0000

INITIAL VALUES OF PARAMETERS:

A = 0.9095  
B = 1.0600  
Z(K): 0.3304 0.4818 0.9674 1.4464  
LOGL = -217.1482

FINAL VALUES OF PARAMETERS:

Procedure converges after 4 iterations.  
A = 0.9817  
B = 1.1361  
Z(K): 0.3179 0.5369 1.0152 1.3805  
LOGL = -215.5517

VARIANCE-COVARIANCE MATRIX:

A	0.0829	0.0547	0.0388	0.0326	0.0170	0.0036
B	0.0547	0.0820	0.0151	0.0046	-0.0213	-0.0429
Z(1)	0.0388	0.0151	0.0300	0.0267	0.0204	0.0159
Z(2)	0.0326	0.0046	0.0267	0.0282	0.0247	0.0227
Z(3)	0.0170	-0.0213	0.0204	0.0247	0.0360	0.0401
Z(4)	0.0036	-0.0429	0.0159	0.0227	0.0401	0.0560

CORRELATION MATRIX:

A	1.0000	0.6629	0.7765	0.6740	0.3115	0.0530
B	0.6629	1.0000	0.3045	0.0953	-0.3911	-0.6328
Z(1)	0.7765	0.3045	1.0000	0.9191	0.6207	0.3873
Z(2)	0.6740	0.0953	0.9191	1.0000	0.7753	0.5723
Z(3)	0.3115	-0.3911	0.6207	0.7753	1.0000	0.8929
Z(4)	0.0530	-0.6328	0.3873	0.5723	0.8929	1.0000

SUMMARY OF ROC CURVE:

Area = 0.7417  
Std. Dev. (Area) = 0.0473

ESTIMATED BINORMAL ROC CURVE WITH ASYMMETRIC 95% CONFIDENCE  
INTERVAL:

FPF	TPF	95% Conf. Interv.
0.005	0.0259	(0.0010, 0.2139)
0.010	0.0483	(0.0036, 0.2616)
0.020	0.0882	(0.0126, 0.3206)
0.030	0.1239	(0.0251, 0.3619)
0.040	0.1568	(0.0402, 0.3949)
0.050	0.1874	(0.0570, 0.4229)
0.060	0.2162	(0.0751, 0.4477)
0.070	0.2434	(0.0941, 0.4702)
0.080	0.2693	(0.1137, 0.4909)
0.090	0.2940	(0.1337, 0.5102)
0.100	0.3176	(0.1538, 0.5284)
0.110	0.3402	(0.1740, 0.5457)
0.120	0.3619	(0.1940, 0.5622)
0.130	0.3828	(0.2138, 0.5781)

## B.5. I TURA – ORYGINAŁ, DWÓCH BARDZIEJ DOŚWIADCZONYCH RADIOLOGÓW: EKSPERT, SPECJALISTA

0.140	0.4030	(0.2333, 0.5935)
0.150	0.4224	(0.2525, 0.6084)
0.200	0.5103	(0.3416, 0.6771)
0.250	0.5854	(0.4180, 0.7384)
0.300	0.6504	(0.4825, 0.7929)
0.400	0.7563	(0.5840, 0.8803)
0.500	0.8369	(0.6618, 0.9390)
0.600	0.8978	(0.7264, 0.9736)
0.700	0.9426	(0.7842, 0.9911)
0.800	0.9737	(0.8393, 0.9980)
0.900	0.9926	(0.8971, 0.9998)
0.950	0.9978	(0.9314, 1.0000)

### ESTIMATES OF EXPECTED OPERATING POINTS ON FITTED ROC CURVE:

Expected Operating Point ( FPF , TPF )	95% C.I. of Lower Bound ( FPF , TPF )	95% C.I. of Upper Bound ( FPF , TPF )
(0.0837, 0.2787)	(0.0326, 0.1328)	(0.1796, 0.4761)
(0.1550, 0.4318)	(0.0827, 0.2762)	(0.2600, 0.5990)
(0.2957, 0.6450)	(0.1933, 0.4992)	(0.4177, 0.7721)
(0.3753, 0.7325)	(0.2554, 0.5927)	(0.5087, 0.8429)

### WARNINGS AND ERROR MESSAGES:

Chi-square goodness of fit not calculated because some expected cell frequencies are less than 5.

Chi-square goodness of fit not calculated because some expected cell frequencies are less than 5.

## B.5 I tura – oryginał, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista

### DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing strongest evidence of positivity (e.g., that abnormality is present).

Number of actually negative cases = 36

Number of actually positive cases = 66

### RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	36	0	0	0	0
Actually positive cases	27	8	20	9	2

### OBSERVED OPERATING POINTS:

FPF: 0.0000 0.0000 0.0000 0.0000 0.0000 1.0000

TPF: 0.0000 0.0303 0.1667 0.4697 0.5909 1.0000

### WARNINGS AND ERROR MESSAGES:

Data are degenerate and imply perfect decision performance.

## B.6 II tura – oryginał, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista

### DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing  
strongest evidence of positivity (e.g., that abnormality is  
present).

Number of actually negative cases = 36

Number of actually positive cases = 66

### RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	22	3	4	5	2
Actually positive cases	26	7	6	9	18

### OBSERVED OPERATING POINTS:

FPF: 0.0000 0.0556 0.1944 0.3056 0.3889 1.0000

TPF: 0.0000 0.2727 0.4091 0.5000 0.6061 1.0000

### INITIAL VALUES OF PARAMETERS:

A = 0.3738

B = 0.6349

Z(K): 0.2818 0.5081 0.8615 1.5936

LOGL = -139.7922

### FINAL VALUES OF PARAMETERS:

Procedure converges after 5 iterations.

A = 0.4463

B = 0.7062

Z(K): 0.2659 0.5815 0.9177 1.5060

LOGL = -138.8566

### VARIANCE-COVARIANCE MATRIX:

A	0.0599	0.0323	0.0348	0.0275	0.0193	0.0027
B	0.0323	0.0485	0.0134	0.0012	-0.0129	-0.0420
Z(1)	0.0348	0.0134	0.0445	0.0375	0.0311	0.0210
Z(2)	0.0275	0.0012	0.0375	0.0426	0.0390	0.0352
Z(3)	0.0193	-0.0129	0.0311	0.0390	0.0498	0.0532
Z(4)	0.0027	-0.0420	0.0210	0.0352	0.0532	0.0952

### CORRELATION MATRIX:

A	1.0000	0.5983	0.6742	0.5446	0.3528	0.0354
B	0.5983	1.0000	0.2891	0.0273	-0.2628	-0.6179
Z(1)	0.6742	0.2891	1.0000	0.8605	0.6597	0.3222
Z(2)	0.5446	0.0273	0.8605	1.0000	0.8455	0.5533
Z(3)	0.3528	-0.2628	0.6597	0.8455	1.0000	0.7717
Z(4)	0.0354	-0.6179	0.3222	0.5533	0.7717	1.0000

### SUMMARY OF ROC CURVE:

Area = 0.6423

Std. Dev. (Area) = 0.0672

### ESTIMATED BINORMAL ROC CURVE WITH ASYMMETRIC 95% CONFIDENCE INTERVAL:

FPF	TPF	95% Conf. Interv.
0.005	0.0849	(0.0112, 0.3218)

*B.7. II TURA – PRZETWORZONE, DWÓCH BARDZIEJ DOŚWIADCZONYCH  
RADIOLOGÓW: EKSPERT, SPECJALISTA*

0.010	0.1157	(0.0222, 0.3509)
0.020	0.1576	(0.0430, 0.3852)
0.030	0.1888	(0.0626, 0.4085)
0.040	0.2147	(0.0813, 0.4271)
0.050	0.2372	(0.0990, 0.4429)
0.060	0.2572	(0.1160, 0.4569)
0.070	0.2756	(0.1322, 0.4697)
0.080	0.2925	(0.1478, 0.4816)
0.090	0.3083	(0.1627, 0.4928)
0.100	0.3232	(0.1771, 0.5035)
0.110	0.3373	(0.1909, 0.5138)
0.120	0.3507	(0.2042, 0.5238)
0.130	0.3635	(0.2170, 0.5334)
0.140	0.3758	(0.2294, 0.5429)
0.150	0.3876	(0.2413, 0.5521)
0.200	0.4412	(0.2946, 0.5964)
0.250	0.4881	(0.3393, 0.6386)
0.300	0.5304	(0.3771, 0.6792)
0.400	0.6055	(0.4380, 0.7553)
0.500	0.6723	(0.4866, 0.8228)
0.600	0.7340	(0.5290, 0.8804)
0.700	0.7929	(0.5695, 0.9275)
0.800	0.8510	(0.6122, 0.9638)
0.900	0.9117	(0.6654, 0.9886)
0.950	0.9461	(0.7051, 0.9963)

ESTIMATES OF EXPECTED OPERATING POINTS ON FITTED ROC CURVE:

Expected Operating Point ( FPF , TPF )	95% C.I. of Lower Bound ( FPF , TPF )	95% C.I. of Upper Bound ( FPF , TPF )
(0.0660, 0.2686)	(0.0174, 0.1482)	(0.1837, 0.4246)
(0.1794, 0.4201)	(0.0877, 0.3048)	(0.3156, 0.5427)
(0.2805, 0.5142)	(0.1621, 0.4013)	(0.4298, 0.6260)
(0.3951, 0.6020)	(0.2485, 0.4867)	(0.5586, 0.7090)

WARNINGS AND ERROR MESSAGES:

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.

**B.7 II tura – przetworzone, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista**

DATA CHARACTERISTICS:

Data collected in 5 categories with category 5 representing  
strongest evidence of positivity (e.g., that abnormality is  
present).

Number of actually negative cases = 36

Number of actually positive cases = 66

RESPONSE DATA:

Category	1	2	3	4	5
Actually negative cases	22	1	5	4	4

DODATEK B. OBLICZENIA Z PROGRAMU ROCKIT, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH

Actually positive cases      18      4      11      6      27

OBSERVED OPERATING POINTS:

FPF: 0.0000 0.1111 0.2222 0.3611 0.3889 1.0000  
 TPF: 0.0000 0.4091 0.5000 0.6667 0.7273 1.0000

INITIAL VALUES OF PARAMETERS:

A = 0.7674  
 B = 0.8637  
 Z(K): 0.2818 0.3550 0.7645 1.2208  
 LOGL = -137.5617

FINAL VALUES OF PARAMETERS:

Procedure converges after 5 iterations.  
 A = 0.8353  
 B = 0.9336  
 Z(K): 0.2654 0.4078 0.8519 1.1536  
 LOGL = -135.5960

VARIANCE-COVARIANCE MATRIX:

A	0.0908	0.0612	0.0467	0.0418	0.0246	0.0113
B	0.0612	0.1010	0.0197	0.0104	-0.0217	-0.0461
Z(1)	0.0467	0.0197	0.0446	0.0412	0.0317	0.0259
Z(2)	0.0418	0.0104	0.0412	0.0424	0.0355	0.0316
Z(3)	0.0246	-0.0217	0.0317	0.0355	0.0495	0.0524
Z(4)	0.0113	-0.0461	0.0259	0.0316	0.0524	0.0695

CORRELATION MATRIX:

A	1.0000	0.6389	0.7338	0.6730	0.3671	0.1425
B	0.6389	1.0000	0.2928	0.1585	-0.3068	-0.5499
Z(1)	0.7338	0.2928	1.0000	0.9461	0.6753	0.4643
Z(2)	0.6730	0.1585	0.9461	1.0000	0.7739	0.5822
Z(3)	0.3671	-0.3068	0.6753	0.7739	1.0000	0.8941
Z(4)	0.1425	-0.5499	0.4643	0.5822	0.8941	1.0000

SUMMARY OF ROC CURVE:

Area = 0.7293  
 Std. Dev. (Area) = 0.0580

ESTIMATED BINORMAL ROC CURVE WITH ASYMMETRIC 95% CONFIDENCE  
INTERVAL:

FPF	TPF	95% Conf. Interv.
0.005	0.0582	(0.0020, 0.3969)
0.010	0.0906	(0.0062, 0.4314)
0.020	0.1395	(0.0182, 0.4711)
0.030	0.1785	(0.0332, 0.4976)
0.040	0.2120	(0.0500, 0.5184)
0.050	0.2418	(0.0679, 0.5359)
0.060	0.2688	(0.0866, 0.5513)
0.070	0.2937	(0.1057, 0.5653)
0.080	0.3168	(0.1249, 0.5782)
0.090	0.3385	(0.1442, 0.5903)
0.100	0.3589	(0.1634, 0.6018)
0.110	0.3783	(0.1823, 0.6128)
0.120	0.3968	(0.2010, 0.6234)
0.130	0.4144	(0.2193, 0.6337)

**B.8. II TURA – PRZETWORZONE+AWPKM, DWÓCH BARDZIEJ DOŚWIADCZONYCH RADIOLOGÓW: EKSPERT, SPECJALISTA**

0.140 0.4312 (0.2372, 0.6438)  
 0.150 0.4474 (0.2547, 0.6537)  
 0.200 0.5198 (0.3344, 0.7009)  
 0.250 0.5816 (0.4011, 0.7461)  
 0.300 0.6354 (0.4558, 0.7891)  
 0.400 0.7255 (0.5376, 0.8652)  
 0.500 0.7982 (0.5967, 0.9230)  
 0.600 0.8580 (0.6442, 0.9619)  
 0.700 0.9073 (0.6868, 0.9847)  
 0.800 0.9475 (0.7295, 0.9957)  
 0.900 0.9789 (0.7798, 0.9995)  
 0.950 0.9911 (0.8153, 0.9999)

**ESTIMATES OF EXPECTED OPERATING POINTS ON FITTED ROC CURVE:**

Expected Operating Point ( FPF , TPF )	95% C.I. of Lower Bound ( FPF , TPF )	95% C.I. of Upper Bound ( FPF , TPF )
(0.1243, 0.4045)	(0.0474, 0.2345)	(0.2621, 0.5951)
(0.1971, 0.5159)	(0.0989, 0.3568)	(0.3387, 0.6726)
(0.3417, 0.6753)	(0.2085, 0.5310)	(0.4984, 0.7971)
(0.3953, 0.7216)	(0.2484, 0.5797)	(0.5590, 0.8350)

**WARNINGS AND ERROR MESSAGES:**

Chi-square goodness of fit not calculated because  
 some expected cell frequencies are less than 5.

Chi-square goodness of fit not calculated because  
 some expected cell frequencies are less than 5.

**B.8 II tura – przetworzone+AWPKM, dwóch bardziej doświadczonych radiologów: Ekspert, Specjalista**

**DATA CHARACTERISTICS:**

Data collected in 5 categories with category 5 representing  
 strongest evidence of positivity (e.g., that abnormality is  
 present).

Number of actually negative cases = 36

Number of actually positive cases = 66

**RESPONSE DATA:**

Category	1	2	3	4	5
Actually negative cases	22	1	5	4	4
Actually positive cases	15	3	13	7	28

**OBSERVED OPERATING POINTS:**

FPF: 0.0000 0.1111 0.2222 0.3611 0.3889 1.0000

TPF: 0.0000 0.4242 0.5303 0.7273 0.7727 1.0000

**INITIAL VALUES OF PARAMETERS:**

A = 0.9638

B = 0.9985

Z(K): 0.2818 0.3550 0.7645 1.2208

LOGL = -136.4597

**FINAL VALUES OF PARAMETERS:**

DODATEK B. OBLICZENIA Z PROGRAMU ROCKIT, PRACUJĄCEGO  
NA WYNIKACH TESTÓW KLINICZNYCH

Procedure converges after 4 iterations.

A = 1.0109

B = 1.0457

Z(K): 0.2682 0.3809 0.8561 1.1598

LOGL = -134.8701

VARIANCE-COVARIANCE MATRIX:

A	0.1085	0.0749	0.0524	0.0482	0.0277	0.0124
B	0.0749	0.1225	0.0220	0.0139	-0.0243	-0.0519
Z(1)	0.0524	0.0220	0.0446	0.0419	0.0318	0.0258
Z(2)	0.0482	0.0139	0.0419	0.0427	0.0347	0.0304
Z(3)	0.0277	-0.0243	0.0318	0.0347	0.0494	0.0528
Z(4)	0.0124	-0.0519	0.0258	0.0304	0.0528	0.0699

CORRELATION MATRIX:

A	1.0000	0.6497	0.7526	0.7074	0.3777	0.1421
B	0.6497	1.0000	0.2969	0.1924	-0.3129	-0.5614
Z(1)	0.7526	0.2969	1.0000	0.9595	0.6768	0.4627
Z(2)	0.7074	0.1924	0.9595	1.0000	0.7554	0.5568
Z(3)	0.3777	-0.3129	0.6768	0.7554	1.0000	0.8981
Z(4)	0.1421	-0.5614	0.4627	0.5568	0.8981	1.0000

SUMMARY OF ROC CURVE:

Area = 0.7576

Std. Dev. (Area) = 0.0547

ESTIMATED BINORMAL ROC CURVE WITH ASYMMETRIC 95% CONFIDENCE  
INTERVAL:

FPF	TPF	95% Conf. Interv.
0.005	0.0462	(0.0009, 0.4018)
0.010	0.0775	(0.0035, 0.4414)
0.020	0.1277	(0.0125, 0.4870)
0.030	0.1695	(0.0252, 0.5173)
0.040	0.2061	(0.0407, 0.5409)
0.050	0.2390	(0.0580, 0.5607)
0.060	0.2692	(0.0767, 0.5781)
0.070	0.2972	(0.0964, 0.5937)
0.080	0.3233	(0.1167, 0.6081)
0.090	0.3478	(0.1374, 0.6216)
0.100	0.3709	(0.1582, 0.6342)
0.110	0.3929	(0.1790, 0.6463)
0.120	0.4138	(0.1997, 0.6580)
0.130	0.4337	(0.2202, 0.6692)
0.140	0.4527	(0.2402, 0.6801)
0.150	0.4710	(0.2599, 0.6907)
0.200	0.5521	(0.3503, 0.7410)
0.250	0.6202	(0.4259, 0.7877)
0.300	0.6783	(0.4875, 0.8308)
0.400	0.7723	(0.5783, 0.9024)
0.500	0.8440	(0.6426, 0.9512)
0.600	0.8989	(0.6935, 0.9796)
0.700	0.9405	(0.7384, 0.9934)
0.800	0.9707	(0.7823, 0.9987)
0.900	0.9906	(0.8322, 0.9999)
0.950	0.9968	(0.8660, 1.0000)

*B.8. II TURA – PRZETWORZONE+AWPKM, DWÓCH BARDZIEJ  
DOŚWIADCZONYCH RADIOLOGÓW: EKSPERT, SPECJALISTA*

ESTIMATES OF EXPECTED OPERATING POINTS ON FITTED ROC CURVE:

Expected Operating Point ( FPF , TPF )	95% C.I. of Lower Bound ( FPF , TPF )	95% C.I. of Upper Bound ( FPF , TPF )
(0.1231, 0.4200)	(0.0467, 0.2286)	(0.2605, 0.6330)
(0.1960, 0.5461)	(0.0982, 0.3670)	(0.3371, 0.7161)
(0.3517, 0.7299)	(0.2160, 0.5750)	(0.5097, 0.8500)
(0.3943, 0.7675)	(0.2475, 0.6169)	(0.5580, 0.8777)

WARNINGS AND ERROR MESSAGES:

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.

Chi-square goodness of fit not calculated because  
some expected cell frequencies are less than 5.



## Dodatek C

---

# Współczynniki filtrów falkowych, używanych w eksperymentach z poprawą percepcji

---

Używane jądra falkowe, zaczerpnięte z [32, 124]:

- ortogonalne *Daubechies 8*  
filtr dolnoprzepustowy do analizy:

```
[0.2303778133088964, 0.7148465705529154, 0.6308807679398587,  
-0.0279837694168599, -0.1870348117190931, 0.0308413818355607,  
0.0328830116668852, -0.0105974017850690]
```

- biortogonalne *Coiflet 22/14*  
filtr dolnoprzepustowy do analizy (pierwszy indeks to -10):

$\sqrt{(2)}^*$

```
[-0.00004270, -0.00005047, 0.00068975, 0.00085361, -0.00465364,  
-0.00659508, 0.02604553, 0.01279669, -0.10097515, 0.05573021,  
0.51620125, 0.51620125, 0.05573021, -0.10097515, 0.01279669,  
0.02604553, -0.00659508, -0.00465364, 0.00085361, 0.00068975,  
-0.00005047, -0.00004270]
```

filtr dolnoprzepustowy do syntezy (pierwszy indeks to -6):

$\sqrt{(2)}^*$

```
[-0.00176239, 0.00208282, 0.01527405, -0.01963806, -0.06873322,  
0.11455536, 0.45822144, 0.45822144, 0.11455536, -0.06873322,  
-0.01963806, 0.01527405, 0.00208282, -0.00176239]
```

- biortogonalne 6/10  
filtr dolnoprzepustowy do analizy (pierwszy indeks to -2):

```
[-0.12907777, 0.04769893, 0.78848562, 0.78848562, 0.04769893,  
-0.12907777]
```

filtr dolnoprzepustowy do syntezy (pierwszy indeks to -4):

```
[0.01891423, 0.00698950, -0.06723693, 0.13338923, 0.61505077,  
0.61505077, 0.13338923, -0.06723693, 0.00698950, 0.01891423]
```

DODATEK C. WSPÓŁCZYNNIKI FILTRÓW FALKOWYCH, UŻYWANYCH  
W EKSPERYMENTACH Z POPRAWĄ PERCEPCJI

- biortogonalne *Taswell 10/10 biorthogonal symmetric most-regular*  
filtr dolnoprzepustowy do analizy (pierwszy indeks to -4):

[0.02691342, -0.03230335, -0.24110982, 0.05410042, 0.89950611,  
0.89950611, 0.05410042, -0.24110982, -0.03230335, 0.02691342]

filtr dolnoprzepustowy do syntezy (pierwszy indeks to -4):

[0.01984354, 0.0238176, -0.02325784, 0.14557075, 0.54113273,  
0.54113273, 0.14557075, -0.02325784, 0.0238176, 0.01984354]

- biortogonalne *Villasenor 18/10*  
filtr dolnoprzepustowy do analizy (pierwszy indeks to -4):

[0.02885256501123136, 0.00008244478227504624,  
-0.1575264469076351, 0.07679048884691438,  
0.7589077294537618, 0.7589077294537619,  
0.07679048884691436, -0.1575264469076351,  
0.00008244478227504624, 0.02885256501123136]

filtr dolnoprzepustowy do syntezy (pierwszy indeks to -8):

[0.0009544158682436510, -0.000002727196296995984,  
-0.009452462998353147, -0.002528037293949898,  
0.03083373438534281, -0.01376513483818621,  
-0.08566118833165798, 0.1633685405569902,  
0.6233596410344172, 0.6233596410344158,  
0.1633685405569888, -0.08566118833165885,  
-0.01376513483818652, 0.03083373438534267,  
-0.002528037293949898, -0.009452462998353147,  
-0.000002727196296995984, 0.0009544158682436510]

## Dodatek D


---

# Szczegółowe wyniki klasyfikacji


---

Wyniki skuteczności klasyfikatorów dla różnej liczby cech wejściowych w zastosowaniu do opisu potencjalnych mikrozwapnień – klasyfikacja: potencjalne mikrozwapnienie-norma (tkanka prawidłowa) – zostały przedstawione na rysunkach: D.1, D.2, D.3, D.4.


Wyniki skuteczności klasyfikatorów dla różnej liczby cech wejściowych w zastosowaniu do klasyfikacji kształtów pojedynczych mikrozwapnień zostały przedstawione na rysunkach: D.5, D.6, D.7.




Rysunek D.1: Skuteczności klasyfikacji najbliższego sąsiada (1-NN) dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba*, *infogain*, *corrcoeff* i *relief* [54]) w zastosowaniu do opisu potencjalnych mikrozwapnień (klasyfikacja potencjalne mikrozwapnienie-norma).




Rysunek D.2: Skuteczności maszyny wektorów nośnych z jądrem liniowym dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba*, *infogain*, *corrcoeff* i *relief* [54]) w zastosowaniu do opisu potencjalnych mikrozwapnień (klasyfikacja potencjalne mikrozwapnienie-norma).




Rysunek D.3: Skuteczności maszyny wektorów nośnych z jądrem wielomianowym dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba*, *infogain*, *corrcoeff* i *relief* [54]) w zastosowaniu do opisu potencjalnych mikrozwapnień (klasyfikacja: potencjalne mikrozwapnienie-norma).




Rysunek D.4: Skuteczności maszyny wektorów nośnych z jądrem RBF dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba*, *infogain*, *corrcoeff* i *relief* [54]) w zastosowaniu do opisu potencjalnych mikrozwapnień (klasyfikacja: potencjalne mikrozwapnienie-norma).



Rysunek D.5: Skuteczności klasyfikacji SVM (z jądrem RBF) dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba*, *infogain* i *corrcoeff* [54]) w zagadnieniu różnicowania klas kształtów typowych mikrozwapnień — klasyfikacji kształtów mikrozwapnień na ziarniste i liniowe.



Rysunek D.6: Skuteczności klasyfikacji SVM (z jądrem RBF) dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba* i *corrcoeff* [54]) w zagadnieniu różnicowania klas kształtów typowych mikrozwapnień — klasyfikacji kształtów mikrozwapnień na okrągłe i liniowe.



Rysunek D.7: Skuteczności klasyfikacji SVM (z jądrem RBF) dla różnej liczby automatycznie wyselekcjonowanych cech wejściowych (metodami: *simba*, *logratio* i *relief* [54]) w zagadnieniu różnicowania klas kształtów typowych mikrozwapnień — klasyfikacji kształtów mikrozwapnień na okrągłe i ziarniste.

Dodatek E

---

## **MammoViewer – dokumentacja systemu do analizy i obróbki obrazów mammograficznych**

---

