

Komputerowe wspomaganie
obrazowej diagnostyki medycznej

przygotował zespół pod kierunkiem Artura
Przelaskowskiego

Warszawa, 2006

Przedmowa

Opracowanie to dotyczy istotnego z punktu widzenia rozwoju nowoczesnej obrazowej diagnostyki medycznej zagadnienia wspomagania pracy radiologa z wykorzystaniem wszystkich dostępnych technologii, metod i sposobów z zakresu szeroko rozumianych technik komputerowych i informacyjnych, w tym elektroniki i informatyki medycznej.

Jest próbą syntetycznego ujęcia problemu na użytek prowadzonej dydaktyki oraz badań naukowych, w tym rozwoju zespołu składającego się z kilku doktorantów i pracowników nauki, techniki i medycyny.

Zespół autorski pracuje w składzie: Artur Przelaskowski, Anna Wróblewska, Paweł Bargieł, Piotr Boniński, Teresa Podsiadły-Marczykowska, Dariusz Radomski

Warszawa, czerwiec 2006

Spis treści

1	Wprowadzenie	9
1.1	Definicje, cele i zamierzenia	9
1.2	Podstawowe operacje na obrazie	12
1.2.1	Percepcja informacji obrazowej - model HVS	12
1.2.2	Metody interpretacji obrazów medycznych	15
1.2.3	Specyfika obrazowej informacji diagnostycznej	17
1.2.4	Podstawowe metody przetwarzania obrazów	17
1.3	Wspomaganie medycyny techniką: historia i współczesność	18
1.3.1	Relacja lekarz-inżynier	19
1.3.2	Biosystemy, biotechnologie	22
1.3.3	Aparatura medyczna	23
1.3.4	Biomateriały, biomechanika i sztuczne organy	29
1.3.5	Obrazowanie medyczne	32
1.3.6	Informatyka medyczna	36
1.3.7	Oblicze medycyny jutra	37
1.4	Medycyna bazująca na dowodach	39
1.5	Informacja, inteligencja, komputer	44
1.5.1	Informacja	44
1.5.2	Inteligencja	46
1.5.3	Wspomaganie diagnostyki obrazowej	48
3	Środowisko: centra radiologii cyfrowej, PACS, RIS, telemedycyna, CAD	51
3.1	Centra radiologii cyfrowej	51
3.1.1	Klucz: radiografia cyfrowa	52
3.1.2	Szpitalny system informacyjny HIS	52
3.1.3	Radiologiczny system informacyjny RIS	53
3.1.4	Systemy archiwizacji i transmisji obrazów	54
3.1.5	PACS pierwszej generacji	55
3.1.6	PACS drugiej generacji	56

3.1.7	Integracja HIS-PACS	57
3.1.8	DICOM	59
3.1.9	IHE	59
3.2	Referencyjne bazy danych obrazowych	61
3.2.1	Wprowadzenie do indeksowania obrazów zawartością	62
3.2.2	Systemy indeksowania zawartością w medycynie	63
3.2.3	Systemy indeksowania zawartością	65
3.2.4	System Flexible Image Retrieval Engine	66
4	Interpretacja informacji obrazowej i weryfikacja narzędzi wspomagania	67
4.1	Informacja obrazowa	67
4.1.1	Ocena jakości obrazów medycznych	67
4.1.2	Ocena wiarygodności diagnostycznej obrazów	70
4.2	Proces interpretacji obrazów medycznych	73
4.2.1	Wstępna ocena jakości i treści diagnostycznej	75
4.2.2	Analiza wybranych cech lokalnych	76
4.2.3	Analiza zmiany	76
4.2.4	Drugie spojrzenie	77
4.2.5	Ocena, raport	78
4.3	Metody weryfikacji systemów komputerowego wspomagania diagnozy radiologicznej	79
4.3.1	Parametry służące ocenie dokładności diagnostycznej	80
4.3.2	Metody porównywania wiarygodności modeli diagno- stycznych	85
4.3.3	Metodologia klinicznych ocen modeli diagnostycznych	87
5	Metody opisu obrazów	91
5.1	Obraz: kontury, tekstury, tło	91
5.2	Metody modelowania obrazów	91
5.3	Model procesu akwizycji mammogramu jako przykład mo- delowania obrazu medycznego	92
5.3.1	Podstawy	92
5.3.2	Kompensacja rozmycia okładek wzmacniających	94
5.3.3	Estymacja promieniowania rozproszonego	95
6	Analiza obrazów w wielu skalach	101
6.1	Metody falkowe	101
6.1.1	Falkowa dekompozycja obrazów	102
6.1.2	Dwukanałowy schemat analizy i syntezy	104
6.1.3	Realizacje za pomocą liftingu	108

6.2	Transformacja heksagonalna	110
6.3	Transformacja <i>contourlet</i>	114
7	Metody poprawy percepcji informacji obrazowej	117
7.1	Poprawa percepcji z użyciem przekształceń wielorozdzielczych	119
7.2	Transformacja heksagonalna	120
7.3	Transformacja <i>contourlet</i>	123
8	Charakterystyka systemów wspomaganie diagnostyki w mam-	
	mografii	129
8.1	Badania mammograficzne i powstające obrazy	129
8.1.1	Podstawowe patologie istotne w CAD – charakterystyka	134
8.1.2	Guzy	135
8.1.3	Mikrozwapnienia	136
8.1.4	Wczesne oznaki złośliwości	141
8.1.5	Raport z badania mammograficznego	143
8.2	Charakterystyka stosowanych metod CAD	143
8.2.1	Cel komputerowego wspomaganie diagnozy	143
8.2.2	Zastosowania CAD	144
8.2.3	Przydatność CAD w procesie diagnozy	145
8.2.4	Schemat przetwarzania informacji w CAD	145
8.2.5	Przegląd rozwiązań komercyjnych	147
8.2.6	Kryteria oceny systemów CAD	148
8.2.7	Szczegółowa ocena wybranych systemów	148
8.2.8	Systemy CAD w praktyce klinicznej	149
8.2.9	Systemy wspomaganie detekcji - wyzwania światowe	149
9	Wybrane metody i narzędzia CADD	151
9.1	Metody detekcji guzów w mammografii	151
9.1.1	Metody uwydatniania	151
9.1.2	Lokalizacja i segmentacja	153
9.1.3	Ekstrakcja cech	155
9.1.4	Klasyfikacja regionów (weryfikacja detekcji i diagnoza)	156
9.2	Metody detekcji mikrozwapnień w mammografii	156
9.2.1	Metody uwydatniania mikrozwapnień	157
9.2.2	Lokalizacja i segmentacja mikrozwapnień	158
9.2.3	Ekstrakcja cech	159
9.2.4	Klasteryzacja i segmentacja mikrozwapnień w Mam-	
	moViewer	159
9.3	MammoViewer – narzędzie do wielorozdzielczej analizy ob-	
	razów medycznych	166

9.3.1	Proste operacje na obrazach	166
9.3.2	Wielorozdzielcza analiza obrazów	168
9.3.3	Poprawa percepcji	168
9.3.4	Metody detekcji patologii	169
9.3.5	Metody diagnozy patologii	169
9.3.6	Kompresja i indeksowanie	169
9.3.7	Zastosowania	172
9.3.8	Wnioski i kierunki dalszego rozwoju	172
10	Inne metody wspomagania radiografii cyfrowej	173
10.1	Ontologia	173
10.1.1	Pojęcie ontologii w filozofii	173
10.1.2	Pojęcie ontologii w systemach informatycznych . . .	173
10.1.3	Budowa ontologii - metodologie	177
10.1.4	Edytor ontologii Protege-2000	182

Rozdział 1

Wprowadzenie


1.1 Definicje, cele i zamierzenia

Definicja komputerowego wspomagania obrazowej diagnostyki medycznej CAD (ang. *computer-aided diagnosis*) nie jest łatwa. Spotykane w literaturze definicje nie są precyzyjne, jednoznaczne ani przynajmniej w ogólnym sensie zgodne.

Zamiarem jest humanizacja medycyny, a nie odczłowieczona automatyzacja. Rutyna, przyzwyczajenie, monotonia wyłączająca czujne postrzeganie, schematyzm w podejściu do człowieka są przejawami słabości medycyny. Celem komputerowego wspomagania diagnostyki obrazowej jest przede wszystkim podkreślenie wyjątkowej roli człowieka, stworzenie narzędzi, które wzmocnią ludzkie zdolności i sprawią maksymalne ich wykorzystanie do rozwiązywania kluczowych problemów interpretacji obrazów. Najbardziej ambitnym zadaniem jest wspomaganie człowieka w twórczej interpretacji empirii (tj. całej dostępnej informacji diagnostycznej), ontologii danej dziedziny medycznej oraz uwarunkowań chwili w podejmowaniu decyzji. Sprawność diagnostyczna i terapeutyczna, umiejętność wyciągania wniosków i podejmowania trafnych decyzji w sytuacjach nietypowych, przy ograniczonej zdolności poznawczej i braku unormowanych reguł decyzyjnych (protokołu analizy badań obrazowych) będą mogły być udoskonalane w maksymalnie korzystnych warunkach technologiczno-informatycznych. Metody CAD bazujące na nowoczesnych technologiach obrazowania są ważnym elementem realizacji takich uwarunkowań. Środowisko komputerowego wspomagania decyzji diagnostycznych przedstawiono na rys. 1.1.

Możemy przyjąć uproszczoną, wstępną definicję systemów wspomagania detekcji i diagnozy badań obrazowych w następującej postaci:

Definicja 1.1 *System CAD do badań obrazowych*



Rys. 1.1: Środowisko komputerowego wspomagania decyzji diagnostycznych.

System komputerowego wspomaganie detekcji zmian patologicznych CAD to zestaw wyrafinowanych metod (algorytmów, rozwiązań technologicznych, narzędzi sztucznej inteligencji etc) detekcji cech związanych z patologią.

□

Definicja 1.2 *System CADD do badań obrazowych*

System komputerowego wspomaganie diagnozy zmian patologicznych CADD to zestaw wyrafinowanych metod (algorytmów, rozwiązań technologicznych, narzędzi sztucznej inteligencji etc) analizy i interpretacji określonych cech obrazowych w celu sformułowania diagnozy różnicującej (w kategoriach zmiany złośliwej lub łagodnej)

□


Historię rozwoju metod wspomaganie można krótko zarysować w sposób następujący:

- 1980-1990: metody poprawy percepcji (bez entuzjazmu)
- początek 1990: metody sztucznej inteligencji
- połowa lat 90: obrazowanie 3W
- koniec lat 90: radiologia cyfrowa (sprzęt, jakość obrazów)
 - poprawa percepcji (wizualizacja)
 - przetwarzanie obrazów, CADD
 - kompresja, przetwarzanie kontrastu
 - obiektywizacja, standardy
 - ustalenie warunków pracy (możliwości, ograniczenia radiologa)
- przyszłość:
 - badania interdyscyplinarne w zakresie:
 - * percepcja (charakterystyka pracy radiologa)
 - * CADD
 - * wizualizacja (filmy, 3W, optymalizacja interfejsu)
 - * referencyjne bazy danych, integracja medycznych systemów informacyjnych
 - * ocena diagnostyczna (obiektywizacja procedur, protokoły badań)
 - stacja robocza i nowy sposób interpretacji badań obrazowych (wyznaczanie parametrów na danych dokładnych i automatyczne ustalenie uproszczonych warunków wizualizacji)

1.2 Podstawowe operacje na obrazie

Obraz to mieszanina 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 (inaczej odczytywaną czy ustalaną) przez obserwatora lub też algorytmy i metody wspomagające diagnostykę obrazową.

Sposób wykorzystania różnego typu operacji na obrazie do wspomagania diagnostyki obrazowej przedstawiono na rys. 1.2.




Rys. 1.2: Ogólna charakterystyka operacji na obrazie wykorzystywanych w systemach CADD.

1.2.1 Percepcja informacji obrazowej - model HVS


Znane właściwości ludzkiego systemu widzenia (ang. *human visual system*), tj. niedoskonałość ludzkiego wzroku, określone zasady percepcji treści obrazowej, odczuwalne kryteria jakości, subiektywizm i zmienność ocen (po czasie i po różnych realizacjach), a także określony sposób pracy z obrazem wymagają dostosowania metod wizualizacji (inaczej prezentacji) zarejestrowanej informacji obrazowej do charakterystyki odbiorcy.

Czułość kontrastu decyduje o możliwości rozróżniania obiektów poprzez postrzeganie różnic w poziomie jasności obiektu f_o względem jednorodnego tła f_t . Próg widoczności $\Delta f = f_o - f_t$ nie jest stały w całym zakresie wartości f_t - czułość spada przy ciemnym i jasnym tle, tak jak to pokazano na rys. 1.3. Okazuje się, że jeszcze trudniej jest dostrzec zróżnicowanie poziomów jasności w obiekcie $\Delta f = f_{o2} - f_{o1}$ przy odmiennej jasności tła - zobacz rys. 1.4.



Rys. 1.3: Określenie czułości kontrastu: a) krzywe Webera uzyskane przy jednorodnym obiekcie wyróżnianym z tła, b) przykładowe obrazki z eksperymentu. Typowa czułość kontrastu JND (ang. *just noticeable difference*) w środkowym zakresie wartości funkcji jasności wynosi 2% zarówno w teście ze stałą jasnością obiektu, jak też ze stałą jasnością tła.

Mózg ludzki podczas analizy obrazu uwzględnia otoczenie w jakim występuje dany obiekt. Zależnie od cech kontekstu może pojawić się wrażenie deformacji, zmiany koloru, czy wręcz pojawiania się nowych elementów w obrazie albo znikania drobnych obiektów. Przykładem mogą być dwa odcinki jednakowej długości przedstawione na rys. 1.5a), które są odbierane jako dłuższy i krótszy (efekt rozciągania i ściskania przez groty strzałek).




Rys. 1.4: Określenie czułości kontrastu: a) krzywe Webera uzyskane przy niejednorodnym obiekcie wyróżnianym z tła, b) przykładowe obrazki z eksperymentu. Typowa wartość JND w środkowym zakresie wartości funkcji jasności wynosi 4% przy jasności tła odmiennej od obiektu oraz 2% przy równej jasności tła i części obiektu.

Innym przykładem są dwie równoległe linie (rys. 1.5b)), których wzajemna relacja fałszowana jest poprzez wyraźną preferencję kierunku rozchodzenia się symulowanej fali.

Nieobiektywność ludzkiego wzroku potwierdzają więc różnego typu iluzje (rys. 1.6) będące przede wszystkim efektem adaptacji zdolności widzenia do zróżnicowanego kontrastu w otoczeniu obiektu czy też odmiennej jasności otaczającego tła. Dodatkowo wzmacniane są niewielkie różnice cech porównywanych obiektów (kolor, kontrast, rozmiar). Symetria widzenia obszarów jasnych i ciemnych powoduje wrażenie występowania obiektów pozornych, które niekiedy w określonych warunkach mogą zakłócić proces poprawnej, tj. odpowiadającej realnym cechom obiektów, interpretacji obrazów.

Kolejny przykład przedstawia okręgi w centralnym punkcie obrazu bę-




Rys. 1.5: Iluzje wynikające z określonych cech ludzkiego wzroku: a) odcinki o jednakowej długości wydają się różne, b) linie odbierane są jako nierównoległe.

dące podmiotem obserwacji, otoczone okręgami wyraźnie mniejszymi lub większymi. Przy odbiorze informacji obrazowej trudno jest określić czy interesujące okręgi mają jednakowe rozmiary - zobacz rys. 1.7.

1.2.2 Metody interpretacji obrazów medycznych


Protokół badań obrazowych określa sposób oceny informacji obrazowej z wykorzystaniem innej, dostępnej i koniecznej wiedzy. Interpretacja silnie zależy m.in. od rodzaju badań, modalności obrazowania, cech osobowych pacjenta, stylu pracy i doświadczenia lekarza, przypadku chorobowego, dostępnych informacji, wyników oceny wstępnej, warunków pracy w danym ośrodku oraz reguł określonych prawem. W wielu przypadkach brakuje standardów czy chociażby powszechnie uznanych wzorców procedur interpretacji. Dlatego też proces obiektywizacji diagnostyki obrazowej stający się wymogiem chwili w dużym stopniu zależy od ustalenia referencyjnych



Rys. 1.6: Iluzje wynikające z określonych cech ludzkiego wzroku: a) pojawiają się pozorne obiekty, b) lewa część każdego z pasków wydaje się jaśniejsza, c) prawy prostokąt (na jaśniejszym tle) jest pozornie bardziej szary.

protokołów badań oraz powstających w ich efekcie raportów.

Prześledźmy schemat postępowania radiologa na przykładzie interpretacji badań mammograficznych opisanej w rozdziałach 4 oraz 8.



Rys. 1.7: Iluzja Ebbinghausa. Obserwator odnosi wrażenie, że na rys. po lewej stronie środkowy okrąg otoczony mniejszymi okręgami jest większy od okręgu otoczonego okręgami dużymi, natomiast na rys. po prawej oba centralne okręgi wydają się jednakowe. W rzeczywistości na lewym rysunku interesujące obiekty są jednakowych rozmiarów, a na prawym większy jest okrąg otoczony dużymi okręgami.

1.2.3 Specyfika obrazowej informacji diagnostycznej

Użyteczność obrazów zwykle określa sposób ich wykorzystania. W przypadku obrazowej diagnostyki medycznej zarówno jakość obrazu, jak i charakter informacji użytecznej jest silnie zróżnicowany i w wielu przypadkach daleki od ustalonych standardów. Ponieważ ostatecznym interpretatorem, weryfikatorem i decydentem jest lekarz, wszelkie próby obiektywizacji sposobów oceny, jak też uwiarygodnienia kryteriów obliczeniowych stosowanych w obróbce obrazów muszą być dokonywane w ścisłej współpracy z lekarzem, przy założeniu jego podmiotowości oraz subiektywnej weryfikacji finalnej. Mniejszą rolę odgrywają tutaj obliczeniowe kryteria oceny jakości, przy rosnącej roli subiektywnego kryterium wiarygodności diagnostycznej obrazów.

1.2.4 Podstawowe metody przetwarzania obrazów

Ze względu na cel można wyróżnić metody przetwarzania obrazów służące:

- poprawie ogólnej jakości obrazu, czyli poprawie kontrastu lokalnego i globalnego, redukcji szumów, redukcji artefaktów,
- poprawie percepcji poprzez uwzględnienie właściwości ludzkiego systemu widzenia,
- uwydatnieniu cech sygnału użytecznego ze względu na dalszą automatyczną analizę obrazów,
- innym, bardziej specjalistycznym zastosowaniom.

Wśród podstawowych operacji wykonywanych na obrazie (lub wybranym regionie) należy wyróżnić:

- przetwarzanie punktowe jak regulacja kontrastu i jasności, nieliniowa korekcja gamma, korekcja histogramu (wyrównywanie, rozciąganie), sumowanie (miksowanie) obrazów, pewne formy steganografii;
- filtracja uśredniająca, w celu wykrycia lub podkreślenia krawędzi, transformacji obrazu do innej dziedziny (np. falkowej);
- interpolacja i aproksymacja (*zooming*);
- kompresja, wyznaczanie efektywnej reprezentacji informacji obrazowej;
- przekształcenia geometryczne lub graficzne całego obrazu (regionu).

1.3 Wspomaganie medycyny techniką: historia i współczesność

Od lat różne przejawy obecności techniki w medycynie są efektem poszukiwań odpowiedzi na kilka zasadniczych pytań:

- jak wspomóc lekarzy, by ich działania były skuteczniejsze, szybsze, bardziej trafne, dokładne i niezawodne (tj. jak udoskonalić diagnozę i terapię)?
- jak pomóc dotkniętym chorobą, nieszczęściem, by mogli 'normalniej' żyć, wrócić w możliwie pełny sposób do przerwanych zajęć, obowiązków, być znów samodzielny (tj. jak zwiększyć skuteczność rehabilitacji)?
- jak wspierać zdrowy styl życia, zwiększyć świadomość zagrożeń i poprawić warunki życia (tj. jak prowadzić działania profilaktyczne)?

Różnorakie sposoby i formy odpowiedzi na te pytania przedstawiono poniżej. Nie jest to zbiór ani wyczerpujący, ani nawet reprezentatywny. Jest to natomiast próba krótkiego zarysowania kontekstu, w którym od lat dwięćdziesiątych pojawiają się komputerowe systemy wspomaganie obrazowej diagnostyki medycznej.

Nie sposób wymienić wszystkich istotnych rozwiązań techniki wspomagających medycynę. Niektóre z nich, ze względu na swą szczególną wagę i znaczenie w naszej subiektywnej opinii, nie mogą zostać jednak pominięte w

tym krótkim przeglądzie. Technika, nowoczesne technologie są powszechne w dzisiejszej medycynie. Czy można sobie wyobrazić najbardziej skuteczne metody leczenia bez nowoczesnych rozwiązań technicznych w zakresie materiałów, urządzeń oraz we wspomaganiu metod diagnostycznych i terapeutycznych?


Technika zmienia medycynę od lat. Warto wspomnieć stetoskop, urządzenie powszechnie używane przez lekarzy do dziś, a wynalezione przez R.T. Laenneca w 1816. Podglądanie wnętrza ludzkiego ciała za pomocą słuchu stanowiło kiedyś podstawę diagnostyki. Kolejna ważna data to 1895 rok i odkrycie promieniowania X przez W.K. Roentgena, czyli narodziny obrazowania medycznego. Na rysunku 1.8 widać, jak wyglądało badanie rentgenowskiego na początku zeszłego wieku – pacjent musiał trzymać kasetę z filmem na piersiach. Początki elektrokardiografii to rok 1903 i wynalazek W. Einthovena, zaś na pierwszy stymulator serca trzeba było czekać do 1931 r. (A. Hyman), a na pierwszą transplantację serca do roku 1967 (C. Barnard). Warto także wspomnieć rok 1938, kiedy to za sprawą A. Fleminga pojawiła się penicylina kładąc kres szerzącym się na szeroką skalę w szpitalach zakażeniom bakteryjnym. Częsteczkę DNA w 1953 roku odkryli J.D. Watson i F. Crock, co jest tak dzisiaj ważne i znamienne w skutkach. Wreszcie w 1971 roku G. Hounsfield skonstruował pierwszy tomograf rentgenowski do przestrzennych badań mózgu. Z czasem te i wiele innych odkryć i wynalazków zmieniały znacząco i nieodwracalnie oblicze medycyny ...

Trudno jest dokonać systematycznej klasyfikacji wszystkich obszarów wspomagania medycyny techniką. Interdyscyplinarność tej dziedziny, łączącej nauki przyrodnicze, medycynę, różne dyscypliny techniczne powoduje zatarcie wyraźnych granic. Przedstawiony podział stosowany jest często w inżynierii biomedycznej. Posłużę się nim w prezentacji poszczególnych rozwiązań technicznych wykorzystywanych we współczesnej medycynie zatrzymując się nieco dłużej przy szczególnie istotnych obszarach wspomagania.

Technika to pojęcie bardzo pojemne, podobnie jak medycyna. Nasze krótkie rozważania zawężiliśmy do materiałów, urządzeń i technik (inaczej metod, procedur) wykorzystywanych w działaniach profilaktycznych, diagnostyce, terapii i rehabilitacji leczniczej.

1.3.1 Relacja lekarz-inżynier

Ta symboliczna relacja dotyczy bardzo istotnej kwestii efektywnej współpracy ludzi techniki i medycyny (rys. 1.9), teoretyków i praktyków, specjalistów od nowoczesnych technologii, informatyki, matematyki, biochemii i biologii, mechaniki i elektroniki, radiologów, klinicystów, psychologów i wielu innych. Interdyscyplinarny charakter zagadnienia wymaga ciągłego



Rys. 1.8: Kluczowe wydarzenia z historii technicznych odkryć i wynalazków w medycynie: a) pierwszy stetoskop zbudowany przez Francuza R.T. Laenneca; b) badanie rentgenowskie z przełomu XIX i XX w.; c) pierwszy stymulator serca; d) pierwszy kliniczny prototyp skanera mózgu zainstalowany w Atkinson Morley's Hospital w Londynie; e) jedno z pierwszych obrazowych badań mózgu (źródło: Internet).

doskonalenia form współpracy, sposobów wymiany wiedzy i doświadczeń, obiektywizacji tego co subiektywne, a także subiektywnych kryteriów w algorytmach obliczeniowych.

Różne światy ludzi odmiennych dyscyplin nauki, upodobań, sposobów



Rys. 1.9: Współpraca dwóch różnych światów: nowoczesnej techniki i współczesnej medycyny (źródło: zdjęcia własne ze Szpitala Wolskiego oraz Internet).

pracy i rozwiązywania problemów są wyzwaniem, któremu sprostać niełatwo. Jednak sukces na tym polu jest nie do przecenienia. Wydaje się, że przyszłość zależy od jakości relacji lekarza z inżynierem, od tego, czy i jak nauczymy się wspólnie pracować by służyć człowiekowi.

Inżynierowie występowali tradycyjnie jako inicjatorzy rozwoju technologicznego uczestnicząc w projektowaniu, unowocześnianiu, a następnie wykorzystaniu w praktyce klinicznej rozwiązań technicznych. Doskonalenie metod wspomagania w medycynie wymaga silnej integracji wiedzy technicznej i medycznej, wzajemnego przenikania i zrozumienia. Faktem jest, że inżynierowie stają się w coraz większym stopniu współtwórcami efektywnych procedur diagnozy i terapii, lekarze zaś formułują swoje opinie w sposób coraz bardziej zobiektywizowany, formalny, powtarzalny posługu-

jąc się umiejętnie najnowocześniejszymi technologiami. Na naszych oczach dokonuje się zmiana statusu inżynierów klinicznych (biomedycznych), od dostarczycieli nowoczesnych technologii i operatorów urządzeń o wyrażenie niższej pozycji w strukturze ochrony zdrowia, do współtwórców metod interpretacji, oceny i leczenia, ekspertów sterujących rozwojem technologicznym o rosnącej randze.

Na bazie tej współpracy inżynierowie tworzą nowe metody funkcjonalnej diagnostyki na styku narząd system technologiczny, określają działania interwencyjne w przypadkach dysfunkcji narządów (szybkość działania), symulują procedury operacyjne i określają zasady optymalnych działań chirurgicznych (lecniczych).

1.3.2 Biosystemy, biotechnologie


Pierwszy obszar wspomagania to biosystemy i biotechnologie. Dotyczy on badań układu nerwowego, krwionośnego, oddechowego czy odpornościowego, analizy biochemicznej funkcji białek, przemian metabolicznych, badań składu ludzkiego genomu. Na rysunku 1.10 pokazano przykłady urządzeń stosowanych w analizie DNA, testach nowych leków, czy w inżynierii tkanek.

Nie sposób tutaj nie wspomnieć o największej nadziei dzisiejszej medycyny, czyli terapii genowej, która być może otwiera przed nami szansę znacznie bardziej skutecznego leczenia chorób nowotworowych, cukrzycy, choroby Alzheimera i wielu innych. Pierwszą pacjentką tej terapii była 4 letnia Ashanti De Silva (1990 r), cierpiąca na zespół ciężkiego niedoboru odporności SCID. W jądra białych krwinek wprowadzono prawidłowe kopie uszkodzonego genu. 10 lat po zabiegu Ashanti bawi się z rówieśnikami i żyje normalnie, choć przyjmuje regularne serie zastrzyków stymulujących produkcję brakującego białka.

W analizie kodu DNA bardzo istotną rolę odgrywa analiza komputerowa, głównie złożone metody rozpoznawania wzorców służące odczytywaniu łańcuchów kwasu, poznawaniu genotypu, poszukiwaniu genowych czy białkowych źródeł najgroźniejszych chorób.

W obszarze biopomiarów należy wspomnieć przede wszystkim o efektywnych bioczułnikach do pomiaru różnych wielkości biochemicznych, fizycznych, mechanicznych, tj. temperatury, ciśnienia, badania składu krwi itd. Przykłady termometrów skroniowych, głowic ultradźwiękowych wysokiej częstotliwości do badań struktur oka, czujnika genów do detekcji określonych sekwencji DNA itd. przedstawiono na rys. 1.11.

Biosensory przetwarzają „biologiczną odpowiedź” mierzonej rzeczywistości na sygnał elektryczny. Pozwalają ustalić koncentrację określonej sub-



Rys. 1.10: Sprzęt biotechnologiczny: a) system do oceny skutków działania leków, przemian metabolicznych, b) system detekcji komórek, c) urządzenia do analizy DNA (źródło: Internet).

stancji lub inne parametry biologiczne, wykorzystują enzymy, pozwalają śledzić metabolizm komórek, reakcje antygen-antyciało itp. Główne komponenty bioczuJNIKÓW to biokatalizator (przekształca substraty na produkty), przetwornik na sygnał elektryczny, wzmacniacz, układ przetwarzający i wyświetlający.

1.3.3 Aparatura medyczna

W zakresie aparatury biomedycznej długo można wymieniać różnego typu najnowocześniejsze urządzenia o dużej precyzji, wytrzymałości, stabilności parametrów, wykorzystywane w elektroencefalografii, do pomiaru sygnału EKG, itd. Przykład pompy infuzyjnej do precyzyjnego dozowania leków, wzmacniacza obrazu z fotopowielaczem wykorzystywanego w nowoczesnych systemach radiografii cyfrowej czy też aparatury do EKG i EEG przedstawiono na rys. 1.12.



Rys. 1.11: Przykładowy sprzęt zawierający różnego typu bioczuJNIKI (głównie ultrasonograficzną, czujnik genów, temperatury ciśnienia, składu krwi) (źródło: Internet).




Rys. 1.12: Przykłady aparatury medycznej: urządzenia i oprogramowanie do EEG, wzmacniacz obrazu, pompa infuzyjna, urządzenia do defibrylacji i EKG (źródło: Internet).

Warto zwrócić szczególną uwagę na urządzenia wspomagające pracę serca. Według danych opublikowanych w 1998 roku widać skalę problemu: blisko 12 milionów chorych na niewydolność serca w Europie i USA

przy rocznej umieralności na poziomie ponad pół miliona. Dane te można porównać z liczbą blisko 150 tys. wszczepień nowych stymulatorów pracy serca oraz wymianą kolejnych 40 tys. na świecie (głównie Europa i USA) w 1997 roku. Implantowano w tym samym okresie 174 tys. defibrylatorów szczególnie użytecznych w ratowaniu ludzkiego życia (z badań wynika, że nastąpiła 54% redukcja śmiertelności w grupie osób z implantowanym defibrylatorem).

Na rys. 1.13 pokazano nowoczesne defibrylatory, ich budowę, a także schematycznie sposób ich implantowania. Do wprowadzenia elektrod (jednej do prawej komory, drugiej do naczyń wieńcowych) wykorzystuje się odpowiednio przygotowany cewnik. Na zdjęciu rentgenowskim widoczne jest urządzenie implantowane w ciele pacjenta.



Rys. 1.13: Wszczepiane defibrylatory jako skuteczny ratunek dla chorych na serce: wygląd, budowa, sposób umieszczenia w ciele pacjenta (źródło: Internet).

Opieka nad chorymi na niewydolność serca lub pacjentami z innych grup podwyższonego ryzyka wykorzystuje często systemy stałego nadzoru, telemetryczne urządzenia monitorujące układ sercowo - krążeniowy. Stan zdrowia pacjentów śledzony jest za pomocą specjalnej aparatury przez 24 godziny na dobę (rys. 1.14). Współczesne systemy pozwalają nadzorować jednocześnie ponad 1000 osób, rejestrowane są różne parametry fizjologiczne ułatwiające kontrolę, bieżącą ocenę diagnostyczną i planowanie skutecznej terapii, a w razie jakichkolwiek komplikacji czy nagłych zagrożeń udzie-


lana jest natychmiastowa pomoc.



Rys. 1.14: Telemetryczny nadzór (źródło: Internet).

W tym kontekście warto wspomnieć o **telemedycynie**, bardzo intensywnie rozwijających się, dzięki osiągnięciom teleinformatyki, nowych metodach konsultacji i diagnozy, zdalnej kontroli stanu pacjenta, czy też zakrojonej na szeroką skalę działalności profilaktycznej i uświadamiającej. Przykładem bardzo użytecznego urządzenia, które można wykorzystać do diagnostyki w sytuacjach kryzysowych, klęsk żywiołowych, w odległych rejonach o niewielkim zaludnieniu czy też w krajach biednych - brak szpitala w promieniu setek kilometrów, jest walizkowy aparat 3D USG (rys. 1.15). Pozwala on wykonać przestrzenne badania morfologiczne (np. struktury naczyń), przepływowe, umożliwia bardzo złożone badania diagnostyczne (np. trójwymiarowa USG daje ok. 60% wzrost skuteczności diagnozy pło-

dowych wad rozwojowych), a jednocześnie jest urządzeniem przenośnym, lekkim, które można podłączyć do lokalnych łącz telekomunikacyjnych i użyć w celach telekonsultacji ze specjalistami z renomowanych ośrodków.



Rys. 1.15: Telemedyczna stacja diagnostyczna trójwymiarowej ultrasonografii 3D USG (źródło: Internet http://a7www.igd.fhg.de/projects/teleinvivo/teleinvivo_project.html).

Warto podkreślić rosnącą rolę telemedycyny we współczesnej opiece zdrowotnej. Chodzi przede wszystkim o szybkość i interakcję w przekazywaniu informacji, możliwość konsultacji z wysokiej klasy specjalistą, poprawa efektywności poprzez analizę badań wzorcowych (referencyjnych), a wreszcie znaczne obniżenie kosztów i progresję nowoczesnej technologii. Ciekawostką jest fakt, iż podobne pomysły zanotowano już w 1924 roku, gdzie w czasopiśmie *Radio News* przedstawiono pomysł radio-doktora. Kolejnym etapem rozwoju są zastosowania internetowych i globalnych technologii sieciowych w medycynie i publicznej opiece zdrowotnej, czyli tzw. cybermedycyna¹. Ten nowy obszar przenikania medycyny techniki jest ułożony na przecięciu informatyki i publicznej opieki zdrowotnej, a o jego potrzebie świadczy gwałtowny wzrost zapotrzebowania na rzetelną informację

¹pojęcie zaczerpnięte z literatury anglojęzycznej

medyczną (pokazano silny wzrost liczby użytkowników Internetu w USA poszukujących informacji dotyczących ochrony zdrowia). Cybermedycyna podnosi poziom powszechnej wiedzy medycznej, daje dostęp do niektórych usług, ułatwia wymianę informacji na linii lekarz-pacjent i pacjent-pacjent, umożliwia promocję zdrowia i prowadzenie działań profilaktycznych na szeroką skalę. Problemem jest natomiast jakość informacji umieszczanej w Internecie, brak standardów, nierówne szanse dostępu do źródeł informacji.


Innym przykładem wykorzystania nowoczesnej aparatury w medycynie, budzącym duże nadzieje to różnego typu roboty i mikroroboty. Podejmowane są próby, by niektóre operacje wykonywane były przez chirurga bezpośrednio lub pośrednio sterującego robotem. Zwiększa to znacznie precyzję zabiegu, poprzez wykorzystanie metod obrazowania pozwala wyznaczyć bezpieczne trajektorie nawigacji narzędzi lub drogi robota, zapewnia wysoką precyzję lokalizacji struktur ukrytych, daje lepszą koordynację oko-ręka itd.

Trwają intensywne prace nad konstrukcją mikrorobotów do wykonywania różnego typu zadań. Najmniejsze mikroroboty o długości niespełna pół milimetra i szerokości około 200 mikrometrów mogą wykonywać złożone zadania we wnętrzu tkanek, w płynach ustrojowych (krwi, moczu), w trudnodostępnych miejscach bez konieczności zabiegów chirurgicznych. Umożliwiają przykładowo selektywny transport leku podawanego miejscowo.

Warto odnotować też próby wykonywania zdalnych operacji. Wyobraźmy sobie zabieg na odległość wykonywany przez wybitnych kardiochirurgów lub neurochirurgów z liczących się ośrodków za pomocą zdalnie sterowanego robota chirurgicznego w lokalnym szpitalu, gdzie czeka pacjent wymagający skomplikowanej operacji serca lub mózgu. Stan zdrowia pacjenta nie pozwala na jego przewiezienie, wymagana jest szybka interwencja chirurgiczna. Miejscowy lekarz wraz z personelem medycznym przygotowuje salę i pacjenta do operacji, podłącza wyrafinowanego robota, uruchamia zdalne łącze ze specjalistą, który sterując robotem wykonuje precyzyjną operację. Dodatkowy kanał telekonferencyjny umożliwia bieżący kontakt z miejscowym personelem, który wykonuje rutynowe czynności, zapewnia dodatkową, interaktywną wymianę niezbędnych informacji. Operacja się udaje, pacjent jest uratowany.

W 2001 roku zautomatyzowaną, udaną operację pęcherzyka żółciowego na 68-letniej kobiecie w szpitalu w Strasburgu przeprowadzili specjaliści z odległego o 6500 km Nowego Jorku. Wykorzystano wtedy telerobot Zeus (rys. 1.16), opracowany przez Computer Motion Inc. z USA, wyposażony m.in. w funkcje precyzyjnej kontroli ruchowej i głosowej, mechanizmy

eliminacji drżenia ręki, korekcji różnego typu błędów i zakłóceń. Oddzielnym problemem jest zestawienie łącza telekomunikacyjnego z koniecznym w tym przypadku poziomem niezawodności, minimalizacją opóźnień. Od tego czasu przeprowadzono za pomocą Zeusa wiele udanych operacji, m.in. serca, prostaty, woreczka żółciowego. Dalszy rozwój telechirurgii jest pożądanym i możliwym. System Zeus otrzymał w 2002 roku amerykański certyfikat FDA, a w 2003 jego odpowiednik kanadyjski. Pozwala on na zastosowanie systemu przy minimalnie inwazyjnych operacjach w chirurgii ogólnej i laparoskopowej, pod warunkiem że sterujący nim chirurg przejdzie wymagane szkolenie.



Rys. 1.16: Telerobot Zeus umożliwiający zdalne operacje (źródło: Internet http://trueforce.com/Medical_Robotics/Medical_Robotics_Companies/zeus.htm).

1.3.4 Biomateriały, biomechanika i sztuczne organy

Bardzo interesującym przejawem korzystania ze zdobyczy techniki w medycynie są biomateriały. Materiały ceramiczne, polimery, kompozytowe, implanty zębowe, mikroelektrody Ag-AgCl. Warto też wspomnieć o implan- cie ślimakowym tak istotnym w leczeniu chorób narządu słuchu. Mikrofon

podłączony jest do procesora mowy, a zakodowany sygnał transmitowany jest do implantu umieszczanego operacyjnie w uchu. Rozwiązanie to pozwala pomóc ludziom z większym upośledzeniem słuchu, kiedy nie wystarczają klasyczne aparaty słuchowe.

Niezwykle użyteczne rozwiązania z zakresu biomechaniki i inżynierii rehabilitacyjnej to przede wszystkim modele mechanicznych funkcji organizmu, układu głowa-szyja, badanie biodynamiki serca, rekonstrukcje naczyń, tkanki kostnej i mięśniowej, mięśni szkieletu, konstrukcje nowoczesnych protez nóg, rąk, palców, piersi, stawu biodrowego itd. (zobacz rys. 1.17).



Rys. 1.17: Protezy nóg, rąk, palców, zębów, piersi, stawu biodrowego (źródło: Internet).

W zakresie inżynierii rehabilitacji warto wspomnieć funkcjonalne fotele znacznie zwiększające komfort i skuteczność badań oraz rehabilitacji. Należy zwrócić uwagę na opracowania nowoczesnych wózków inwalidzkich, bardzo ergonomicznych, lekkich i funkcjonalnych, konstruowanych z nowych, niezawodnych materiałów, z zasilaniem elektrycznym, zaawansowaną technologią komputerową, elementami robotyki. Dają one duże poczucie samodzielności, pozwalają wręcz na niezależność. Nowe rozwiązania dotyczą elementów tele-rehabilitacji, inteligentnych sposobów kontroli stanu jelit i pęcherza, bardziej dostępnych systemów transportu, usprawnień protez itp.

Wykorzystywanie udoskonalanych protez, implantów, sztucznych narządów staje się coraz bardziej powszechne. Na rysunku 1.18 przedstawiono cały zestaw elementów i urządzeń wykonanych w zasadniczej części z tytanu i plastiku (poliestru i polipropylenu), takich jak sztuczne serce, płuco,

oko, stymulator nerwu przeponowego, implanty zębów, silikonowe protezy chrząstek nosa, ucha, bródki, drobnych chrząstek stawowych, implant ślimakowy, protezy piersi, protezy rąk i nóg, sztuczna skóra i naczynia (udaje się na razie wiernie rekonstruować dłuższe fragmenty mniej elastycznych tętnic), pęcherz moczowy, endoprotezy stawów, protezy kończyn górnych i dolnych, pompa insulinowa (zastępująca istotne funkcje trzustki).



Rys. 1.18: Sztuczne organy jako części zamienne wspomagające leczenie (źródło: Internet oraz Pan Wawrzyniec Świącicki).

Szczególne znaczenia nabiera konstrukcja sztucznego serca i płuca. Na dziś nie są to jeszcze urządzenia doskonałe. Pierwsze serce wszczepiono w 2001 roku, najdłuższy okres "przeżycia" z wszczepionym sztucznym sercem to półtora roku (widoczne na rys. 1.18 urządzenie pozwoliło przeżyć pacjentowi 215 dni). Na sztuczne płuco trzeba jeszcze poczekać. Dotąd opracowano jedynie tzw. natleniacze, które montuje się w żyłach głównych, by wspomagały wymianę gazową.

Ze "sztucznych części" można złożyć niemal całego człowieka, jednak sztuczne organy mogą stanowić obecnie co najwyżej uzupełnienie niedoboru ludzkich narządów, są pomocne w okresie przejściowym, przy okresowej dysfunkcji niektórych narządów, często konieczne wobec braku organów z przeszczepu. Decydujące w naprawie organów są bowiem przeszczepy, a badania wykorzystujące najnowsze pomysły z biotechnologii m.in. odtwarzania zdrowych narządów z komórek macierzystych pobranych od chorej osoby wydają się obiecujące.

1.3.5 Obrazowanie medyczne

Intensywny rozwój technologiczny kilku ostatnich dekad spowodował rewolucję w diagnostyce obrazowej. W Europie 65% rynku należy do aparatury diagnostycznej, w dużym stopniu obrazowej (dane z Deloitte & Touche, The emerging european health telematics. Market Analysis Study, 2000). Technologiczne "oczy" pozwalają na różny sposób sięgać do wnętrza ludzkiego ciała, otwierają nowe możliwości w diagnostyce i terapii, ich stosowanie w wielu przypadkach jest konieczne. Dają olbrzymie możliwości poznania, ciągle jednak mają szereg ograniczeń. Poprawna interpretacja obrazów medycznych, możliwie czuła i trafna percepcja zmian wymaga dużego oświadczenia i znajomości technicznych uwarunkowań konkretnego systemu obrazowania.

Tomografia komputerowa CT oraz metoda rezonansu magnetycznego MR pozwalają wykonać badania z submilimetrową dokładnością ukazując zróżnicowaną informację przestrzenną określonych cech tkanek (rys. 1.19). W badaniach tych można rozróżnić tkankę miękką i kostną, różnicować tkankę miękką, odczytać przestrzenną strukturę naczyń.

Jedno z najnowszych rozwiązań tomografii rezonansu magnetycznego pozwala z wysoką rozdzielczością zobrazować całe ciało (2,15m) w 12 minut, w dowolnej płaszczyźnie cięcia. Tomografia całego ciała jest szczególnie przydatna w ocenie skrzywień kręgosłupa i leczeniu schorzeń kończyn. W takich badaniach bardzo dokładnie można ocenić szczegóły morfologii drobnych struktur.

Z coraz większą dokładnością wykonywane są badania dynamiczne, kontrastowe i perfuzyjne. Tomograficzna rekonstrukcja przestrzennych cech obrazowanych obiektów pozwala wyznaczyć szereg parametrów pojemnościowych, określić wzajemną relację struktur i dokładniej ocenić zarówno morfologię jak i fizjologię obrazowanych narządów.

W obrazowaniu funkcjonalnym szczególnie przydatne są techniki medycyny nuklearnej, tomografie SPECT i PET, badania scyntygraficzne. Jednym z istotnych zastosowań jest dynamiczna ocena aktywności mózgu



Rys. 1.19: (źródło: dr Michael Lell, Earlangen).

w badaniu funkcjonalnym PET. Słuchając muzyki, oglądając rysunek czy rozwiązując zadanie wykorzystujemy różne ośrodki kory mózgowej (płaty skroniowy, potyliczny, czołowy). Szczególnego znaczenia nabiera obrazowanie naczyń: 3D obrazowanie struktur drzewa tętniczego (CT, MR, USG), objętościowe obrazy naczyń statycznych oraz prezentacja ruchomych struktur naczyniowych (EBCT, spiralne CT, MRA).


Za pomocą funkcjonalnego rezonansu magnetycznego możemy tworzyć mapy mózgu (aktywności neuronalnej), wyszczególniać w badaniach czynnościowych obszary mózgu odpowiedzialne za odbiór bodźców zewnętrznych i kontrolę funkcji motorycznych. Warto podkreślić, że jest to badanie nieinwazyjne, bez środków cieniujących, a badania wykonywane są coraz szybciej i dokładniej.

Należy też wspomnieć o obrazowaniu multimodalnym, które pozwala złożyć np. informacje o morfologii z badań CT oraz funkcji z PET i w ten sposób dokładnie lokalizować np. zmiany nowotworowe (widoczne na rysunku zmiany w klatce piersiowej). Budowane są sprzężone tomografy PET/CT

pozwalające synchronizować geometrię i czas obu badań, a w konsekwencji dokładniej przestrzennie pasować informację z obu modalności. Przykład badań dynamicznych i multimodalnych przedstawiono na rys. 1.20.

Stosując metody odtwarzania powierzchni i objętości za pomocą 3D USG można uzyskać efektowne obrazy struktur kostnych dzieci w łonie matki, przestrzenny obraz struktur naczyniowych czy kolorowych przepływów. Systemy ultrasonografii 3D powodują nie tylko korzyści natury jakościowej (lepiej widać morfologię struktur poprzez możliwość przestrzennej ich interpretacji, jak też charakterystykę przepływów i ukrwienia narządów) i ilościowej (wyznaczanie parametrów objętościowych), ale także wprowadzają nowe możliwości diagnostyczne, np. dynamiczną ocenę sprawności kończyn i układu kostnego dzieci w okresie prenatalnym w badaniach 4D.

Według wybranych rezultatów testów porównawczych badań 2D i 3D, przestrzenne badania wątroby i przewodu żółciowego dostarczają 28% dodatkowej informacji diagnostycznej. W ginekologii i położnictwie niektóre badania 3D USG mogą zastąpić znacznie droższe i złożone badania CT i MRI. Odnotowano 62% wzrost w skuteczności diagnozy płodowych wad rozwojowych i ginekologii (brak decyzji fałszywych) oraz poprawę dokładności pomiaru parametrów objętościowych: błąd od 11% do +11% w porównaniu z błędem badań 2D: -14%-+39%).




Rys. 1.20: Dynamiczne badania PET, funkcjonalnego MR oraz badania multimodalne CT/PET (źródło: Internet).

Radiografia dzisiejsza bardzo różni się od badań z czasów Roentgena. Powstają coraz wyższej jakości systemy cyfrowe, doskonałe są sposoby archiwizacji, transmisji i zarządzania przepływem informacji obrazowej. Przy-

kładem możliwości współczesnych systemów radiografii są obrazy angiograficzne na rys. 1.21 dokładnie odtwarzające strukturę naczyniową dłoni. Bardzo duże znaczenie diagnostyczne ma mammografia cyfrowa, zwiększająca efektywność diagnozy w stosunku do analogowych badań na kliszy, m.in. poprzez większe skonstrastowanie obrazów i możliwość wspomagania komputerowego. Systemy cyfrowe pozwalają zmniejszyć dawkę, zredukować znacząco czas niewygodnych dla pacjentki badań, ograniczyć liczbę powtórnych badań.

W systemach obrazowania wykorzystuje się także elementy grafiki komputerowej, na podstawie badań warstwowych odtwarza się wybraną powierzchnię lub całą objętość. Na rys. 1.21 przedstawiono rekonstrukcję stawu łokciowego z obrazów tomografii komputerowej w celu opracowania protezy dopasowanej do struktury kostnej konkretnego pacjenta. Coraz chętniej stosuje się wirtualną endoskopię, rekonstruując z badań planarnych dynamiczne obrazy wnętrza naczyń, jelit itd. (rys. 1.21).



Rys. 1.21: Badanie angiograficzne dłoni, rekonstrukcja stawu łokciowego z obrazów CT oraz wirtualna kolonoskopia (źródło: Internet).

Jako przykład nowych, niemal kieszonkowych rozwiązań systemów obrazowania można wspomnieć wizualny stetoskop USG do badań 2D i kolorowego Dopplera, który umożliwia szybką ocenę funkcji lewej komory, zastawek, rozmiaru komór i wysięku osierdziowego, daje możliwość podjęcia natychmiastowych działań terapeutycznych [J.R. Roelandt, *A personal ultrasound imager (ultrasound stethoscope): a revolution in the physical cardiac diagnosis*. European Heart Journal (2002) 23, 523527].

1.3.6 Informatyka medyczna

Bardzo silnie rozwijającym się w ostatnich latach zastosowaniem techniki w medycynie jest informatyka medyczna, narzędzia dostarczające lekarzowi kompleksowej wiedzy o pacjencie poprzez wykorzystanie skutecznych metod wyszukiwania, przesyłania i gromadzenia różnego typu informacji o pacjentach w szpitalnych systemach informacyjnych.

Na przykładzie mammografii i radiografii płuc trzeba odnotować rosnące znaczenie komputerowego wspomaganie diagnostyki (CAD) z poprawą percepcji zmian patologicznych, automatyczną detekcją potencjalnych zmian. Proces interpretacji obrazów mammograficznych jest niezwykle trudny (stosunkowo duża liczba decyzji fałszywie pozytywnych, ale też fałszywie negatywnych) - bardzo ważne przy ocenie informacji z mammogramu jest doświadczenie radiologa. Do tej pory nie wyznaczano bowiem jednoznacznego standardu dla określenia prawidłowego sutka (ocena jest względna).

Jednym ze sposobów poprawy skuteczności systemów CAD jest próba normalizacji mammogramów. Opracowano metodę SMF (ang. *standard mammogram form*), która poprzez modelowanie procesu akwizycji i wydzielenie tkanki gruczołowej pozwala uzyskać postać mammogramu niezależną od parametrów procesu akwizycji. Można w ten sposób normalizować metody detekcji zapewniając ich wysoką skuteczność w silnie zróżnicowanych przypadkach badań (badania tej samej kobiety wykonane w dwóch różnych ośrodkach różnią się niekiedy bardziej niż badania dwóch różnych pacjentek wykonanych danym mammografem). Takie rozwiązanie próbowano zastosować w europejskim projekcie rozproszonej bazy danych z inteligentnym przeszukiwaniem, opartej na nowoczesnej technologii typu GRID, z wbudowanymi narzędziami wspomaganie decyzji klinicznych.

Przykładem wspomaganie terapii jest symulacyjne wspomaganie sprawności lekarza poprzez rozwiązania wirtualnych narzędzi i środowisk operacyjnych, przestrzennych obrazów narządów (generowanych za danych rzeczywistych) do analizy kształtu i morfologii badanych narządów, np. jako trening przedoperacyjny. Można bezkrwawo uczyć (lub sprawdzać) różnych metod chirurgicznych, obserwować skutki działań, symulować stany krytyczne itd. Można też przewidywać wariantowo przebieg operacji testując skutki podejmowanych w jej trakcie decyzji itp. Automatyczne wspomaganie chirurga w czasie operacji (elementy robotyki) oraz wykorzystanie wiarygodnych urządzeń obrazujących przed i w trakcie operacji zapewnia wysoką precyzję lokalizacji struktur ukrytych, wyznaczanie trajektorii bezpiecznej nawigacji narzędzi, lepszą koordynację oko-ręka, krótsze procedury. Zastosowanie wirtualnej endoskopii, tj. obrazów pustych struktur anatomicznych

(drogi oddechowe, przewód żołądkowo-jelitowy, naczynia krwionośne), powstających z planarnych badań 2D CT lub MRI za pomocą technik odtwarzania objętości lub powierzchni pozwala bez ingerencji zabiegowej na skuteczną diagnozę, zaplanowanie terapii, operacji.

1.3.7 Oblicze medycyny jutra

Skrótowno przedstawione przykłady rozwiązań technicznych w medycynie pozwalają na sformułowanie trzech zasadniczych kierunków technologicznego rozwoju medycyny: a) doskonalenie narzędzi i procedur klinicznych (diagnostycznych i terapeutycznych, w tym rozwój medycyny bazującej na dowodach)); b) kształtowanie globalnego, zdrowego społeczeństwa wiedzy medycznej poprzez upowszechnienie różnych form cybermedycyny; c) realizacja osobistej opieki medycznej (stały nadzór, systematyczna kontrola, opieka domowa, adaptacja urządzeń, samodzielna obsługa przez pacjentów).

Trudno jest obiektywizować, ujednolicić, uschematyzować sposoby podejmowania decyzji, trudno więc stworzyć narzędzia do doskonalenia lekarzy w podejmowaniu decyzji (większej ich obiektywizacji, wiarygodności). Psychologia mówi o obciążeniu (błędzie systematycznym) podejmowanych decyzji, także przez lekarzy. Filozofia działań inżynierów winna przede wszystkim zakładać pokorne uznanie służebnej roli techniki względem medycyny. Chodzi o wspomaganie, a nie zastępowanie, tj. przyjęcie założenia, że lekarz zawsze jest ostatecznym weryfikatorem w procesie diagnostyczno-terapeutycznym, jest nie do zastąpienia. Trzeba mu jedynie pomóc w określonym zakresie, wzmocnić jego możliwości i udoskonalić pracę.

Przykładowo, de Dombal w 1972 roku opracował program, którego wynikiowe decyzje diagnostyczne były bardziej wiarygodne niż lekarzy (przeprowadzono odpowiednie testy w diagnostyce ostrego bólu brzuszego). Program ten wykorzystywał dane z podstawowych badań pacjentów. Lekarze na podstawie tych samych danych mylili się częściej.

Obok skutecznej diagnozy ważny jest także sposób zarządzania procesem leczenia pacjenta, wykonywaniem kolejnych badań i testów, podejmowaniem decyzji odnośnie procedur terapeutycznych. Tutaj także zdarzają się błędy lekarzy.

Kierunkiem działań, obok coraz doskonalszych metod wspomaganie detekcji i diagnozy w nowych obszarach medycyny może być więc komputerowo wspomagane nauczanie (CAL, ang. *computer-aided learning*). Chodzi o próbę przeprowadzania doświadczeń nad metodami podejmowania decyzji w medycynie, aby ukształtować wiedzę na temat sposobów podejmowania takich decyzji. Potrzebne są narzędzia, które podejmą krytyczną analizę

sposobów rozwiązywania problemów klinicznych, wprowadzą wizualizacje całego procesu podejmowania decyzji o różnorodnym charakterze i konsekwencjach. Powstają interaktywne, multimedialne środowiska nauczania, estymacji skutków podejmowanych decyzji. Wskazywane są błędy w podejmowanych działaniach, proponowane są korekty. Można w ten sposób opierając się na rzeczywistych, wiarygodnych danych o pacjentach prze-testować umiejętności lekarza, ucząc go jednocześnie określonego sposobu podejmowania decyzji, używania obiektywnych kryteriów, uwzględniania wyjątkowości każdego przypadku. Ważne są też narzędzia wspomagania rozumienia fizycznych podstaw procesu akwizycji, wpływu parametrów tego procesu na jakość obrazu. Dobrym przykładem takiego narzędzia jest VirtualMammo (www.VirtualMammo.com), stosowany do edukacji w dziedzinie badań mammograficznych. Pozwala on obserwować zmiany obrazu radiograficznego przy różnym napięciu na lampie rentgenowskiej, różnej charakterystyce filmu, ekspozycji (możliwość ustawienia automatycznej regulacji ekspozycji), przy czym widoczny jest obraz obu piersi.

Przedstawiono zaledwie mały fragment, sygnalizujący bogactwo technicznych rozwiązań w medycynie. Wydaje się, że nauka i technika dynamicznie zmieniają oblicze medycyny, dziś bardziej niż kiedykolwiek dotąd. Podsumowując, zasadnicze działania wspomagające są ukierunkowane na:

- Doskonalenia działań lekarza:
 - więcej rozumieć (badania DNA, badania funkcjonalne mózgu)
 - lepiej widzieć (nowoczesne systemy obrazowania, urządzenia rejestrujące sygnały)
 - mieć kompleksową wiedzę (cyfrowe systemy akwizycji i gromadzenia informacji, informatyka medyczna)
 - skuteczniej leczyć (farmakologicznie, analitycznie, operacyjnie, radiologicznie)
 - doskonalej uzupełniać i zastępować (sztuczne organy, protezy, implanty)
- Oszczędzanie pracy lekarza:
 - koncepcja medycyny automatycznej
 - upowszechnienie wiedzy medycznej (internet, telemedycyna)
 - domowa opieka medyczna
- Uzupełnianie pracy lekarza:
 - rehabilitacja lecznicza

- w zakresie medycyny sportowej Pragnę przedstawić interesujące przykłady działań wspomagających
- Zwiększanie niezawodności pracy lekarza
 - trafniej decydować (komputerowe systemy wspomaganie, systemy ekspertowe)
 - naśladować naturalny sposób rozumowania lekarza


Ukoronowaniem zabiegów wspomaganie jest trafniejsza decyzja lekarza. Chodzi o umiejętne łączenie bogatej wiedzy z faktami dotyczącymi danego przypadku w celu uzupełnienia pracy lekarza na etapie decyzyjnym. Jest to zagadnienie trudne, lecz ze wszech miar frapujące i użyteczne. Choć można je sprowadzić do problemu maszyny Turinga, taki kierunek badań może na kolejnych etapach przynosić ogromne korzyści praktyczne.

W stosowaniu coraz nowocześniejszych technologii nie chodzi w żadnym wypadku o redukcję roli lekarza. Poprzez redukcję błędów wynikających z ludzkiej natury, ograniczenie zbędnych zaangażowań i wykorzystanie pełni umiejętności lekarza w przypadkach najtrudniejszych, szczególnie ważnych diagnostycznie uzyskuje się coraz doskonalszy efekt jego pracy.

Zastrzeżenia dotyczą w niektórych przypadkach moralnych aspektów stosowania nowoczesnych technologii. Drugą obawą jest powszechność dostępu do najnowszych rozwiązań techniki w medycynie. Biednych nie stać na nowoczesną opiekę zdrowotną. Kraje rozwijające się muszą wydawać olbrzymie pieniądze na licencje i tantiemy pozyskując zagraniczne technologie, co często przerasta ich możliwości finansowe i znacznie ogranicza zasięg walki z powszechnym ubóstwem i szerzącymi się epidemiami. Mamy do czynienia z paradoksem, że w dobie Internetu, lawinowo rosnących możliwości porozumiewania się, upowszechnienia dostępu do niezliczonych źródeł informacji, szanse korzystania z zaawansowanych technologii medycznych mogą być tak nierówne, jak nigdy dotąd.

1.4 Medycyna bazująca na dowodach

Na przestrzeni dziejów medycyna była utożsamiana ze sztuką. W początkowej fazie rozwoju medycyny podejmowanie decyzji przez „lekarza szamana” odbywało się na podstawie ludycznych przesądów i wierzeń. Wraz z postępem wiedzy z zakresu nauk podstawowych i klinicznych, podejmowanie decyzji medycznych podlegało stopniowej racjonalizacji. Przesłanki bazujące na indywidualnych doświadczeniach lekarza były zastępowane modelami



Rys. 1.22: Model postępowania klinicznego zgodny z paradygmatem medycyny opartej o dowody

decyzyjnymi tworzonymi na przesłanek teoretycznych oraz badań epidemiologicznych. Obserwowany do chwili obecnej trend racjonalizacji decyzji klinicznych doprowadził do powstawania nowego stylu postępowania klinicznego nazywanego *medycyną opartą o dowody*. Założenia medycyny opartej o dowody zostały sformułowane w 1980 roku przez McMastera [108]. Według zasad medycyny opartej o dowody, podejmowanie decyzji klinicznych składa się z następujących etapów:

1. zapewnienie możliwie najbardziej obiektywnej oceny (pomiaru) stanu zdrowia pacjenta
2. jednoznaczne zdefiniowanie problemu klinicznego
3. dokonane krytycznej analizy dostępnych metod diagnostycznych w oparciu o najnowsze piśmiennictwo medyczne
4. wybranie strategii diagnostycznej (lub terapeutycznej) dającej w świetle wyników badań najlepsze wyniki diagnostyczne (terapeutycznej)
5. zastosowanie wybranej metody diagnostycznej (terapeutycznej) do rozwiązywanego problemu klinicznego.
6. weryfikacja poprawności podjętych decyzji, ocena skutków podjętych decyzji

Powyższe zalecenia dotyczące praktyki klinicznej prowadzą do modelu postępowania klinicznego lekarza, który został przedstawiony na rys. 1.22

Zasadniczym elementem procesu podejmowania decyzji klinicznych jest systematyczna obserwacja stanu klinicznego pacjenta, sprowadzająca się *explicite* lub *implicite* do pomiaru wybranych cech pacjenta. Odbyna się on

poprzez: wywiad lekarski, badanie kliniczne pacjenta, badanie laboratoryjne pobranego materiału biologicznego, badanie obrazowe. W zależności od specjalności medycznej udział poszczególnych składowych obserwacji klinicznej jest różny. Przykładowo, w psychiatrii dominującym źródłem informacji jest wywiad lekarski, w endokrynologii – oznaczenie stężeń hormonów w surowicy krwi, zaś w radiologii – badanie obrazowe.

Obserwacja kliniczna, podobnie jak każdy pomiar, jest zawsze obciążona niepewnością. Źródłami niepewności obserwacji klinicznej są:

- niekompletna informacja przekazana przez pacjenta (głównie podczas zbierania wywiadu lekarskiego),
- niekompletna informacja uzyskana przez lekarza podczas badania klinicznego (czynniki niezależne mogą utrudniać badanie, np. tłumienie tonów serca przez grubą warstwę tkanki tłuszczowej podczas osłuchiwania stetoskopem),
- błędna informacja przekazana przez pacjenta (świadoma lub nieświadoma manipulacja pacjenta, unikanie precyzyjnej odpowiedzi na „wstydlive” pytania),
- błędy pomiarowe podczas badania klinicznego, laboratoryjnego lub obrazowego,
- utrata percepcji bądź zgromadzonej wcześniej informacji przez badającego lekarza.

Zebrane wyniki badania klinicznego stanowią wektor danych opisujący stan kliniczny badanego pacjenta. Należy jednak zauważyć, że wynik badania nie musi być tożsamy ze oszacowaniem stanu zdrowia. Stwierdzenie w badaniu radiologicznym przerwania ciągłości tkanki kostnej świadczy o stanie klinicznym – złamaniu kości. Jednakże wartość stężenia danego hormonu w surowicy krwi nie stanowi bezpośredniej informacji o stanie układu hormonalnego. Zatem należy dokonać przekształcenia wektora obserwacji klinicznych na wektor stanu klinicznego pacjenta. Operację tą nazwano obserwatorem stanu klinicznego, poprzez analogię do znanego w teorii sterowania pojęcia obserwatora stanu obiektu [109].

Mając oszacowany wektor danych opisujący stan kliniczny pacjenta, możemy zbudować model diagnostyczny pacjenta, który pozwoli nam postawić właściwą diagnozę. Model taki jest tworzony *implicite* w umyśle lekarza i integruje informacje o stanie klinicznym pacjenta oraz wiedzę z zakresu prawidłowego i patologicznego funkcjonowania organizmu ludzkiego. Zadaniem modelu diagnostycznego jest także dokonanie różnicowania

pomiedzy różnymi rozpoznaniem diagnostycznymi charakteryzującymi się zbliżonym stanem klinicznym. Przykładowo (w uproszczeniu), obserwacja kliniczna: ostry ból za mostkiem; stan kliniczny: niedotlenienie mięśnia sercowego; potencjalne diagnozy: zawał serca lub ostry napad dusznicowy bolesnej. Zastosowany model diagnostyczny powinien prowadzić do decyzji diagnostycznej rozstrzygającej ostateczne rozpoznanie.

Można wyróżnić trzy rodzaje strategii diagnostycznych. Pierwszą z nich jest diagnostyka na podstawie pojedynczego testu diagnostycznego. Metoda ta stosowana jest bardzo rzadko, w sytuacjach wymagających szybkiej decyzji lub w badaniach przesiewowych. Najczęściej stosuje się diagnostykę opartą o serię szeregowych testów klinicznych, zwiększając w ten sposób wiarygodność diagnostyczną.

Jeżeli dla danej jednostki chorobowej istnieje zestaw specyficznych objawów, możliwa jest strategia polegająca na rozpoznawaniu wzorca (ang. *pattern recognition based diagnosis*). Ten sposób diagnostyki często jest stosowany w systemach komputerowego wspomagania diagnozy. W koncepcji medycyny opartej o dowody, komputerowe systemy wspomagające diagnostykę medyczną stanowią jedno z narzędzi pracy klinicysty. Znajdują one zastosowanie szczególnie w radiologii przy ocenie przesiewowej zdjęć mamograficznych.

Powyższe strategie diagnostyczne można było opisać modelami decyzyjnymi typu „czarnej skrzynki”, gdyż abstrahowały od relacji przyczynowo skutkowych między objawami, a etiopatogenezą danej choroby. Podejście to znajduje zastosowanie wówczas, gdy etiopatogeneza choroby jest nieznana, lub istnieją sprawdzone testy diagnostyczne, będące uznanym standardem klinicznym.

Trzecią strategią diagnostyczną jest diagnoza oparta o analizę wiedzy patofizjologicznej i epidemiologicznej, która wykorzystuje rozumowanie dedukcyjne (ang. *knowledge based diagnosis*). Ten sposób podejmowania decyzji diagnostycznych jest szczególnie zalecany, gdy mamy do czynienia z kazuistyką. Obserwacja kliniczna pacjenta prowadzi do niespecyficznego stanu klinicznego (co uniemożliwia zastosowanie rozpoznania wzorca) i jednocześnie zastosowane testy diagnostyczne prowadzą do sprzecznych decyzji diagnostycznych.

Wybranie odpowiedniej strategii diagnostycznej dla danego pacjenta tworzy model diagnostyczny. Model ten jest zawsze obciążony niepewnością estymacji stanu klinicznego pacjenta oraz jego niedokładnością, wynikającą z ograniczonej wiedzy ilościowej i jakościowej dotyczącej etiologii i patomechanizmów większości schorzeń.



Rys. 1.23: Wielokryterialny charakter decyzji klinicznych

Podjęcie przez lekarza decyzji diagnostycznej pozwala wyznaczyć model terapeutyczny rozpoznanej jednostki chorobowej, uwzględniając stan kliniczny chorego oraz najnowszą wiedzę z zakresu farmakologii, chirurgii oraz rehabilitacji. Analiza tego modelu prowadzi do wybrania możliwie najskuteczniejszej i możliwie najmniej szkodliwej (inwazyjność, skutki uboczne leków) decyzji terapeutycznej. Globalnym wskaźnikiem celu wszystkich decyzji podejmowanych przez lekarza jest odzyskanie przez pacjenta zdrowia lub stanu maksymalnie zbliżonego do zdrowia.

Według paradygmatu medycyny opartej o dowody, każda decyzja kliniczna musi być podejmowana na podstawie bilansu argumentów i kontrargumentów związanych z daną decyzją. Zgodnie z modelem przedstawionym na rys. 1.23 decyzje kliniczne mają charakter wielokryterialny. Muszą one uwzględniać: stan kliniczny pacjenta, przesłanki wynikające z najnowszej wiedzy medycznej, preferencje i możliwości pacjenta oraz ograniczenia bioetyczne. Spośród wymienionych czterech uwarunkowań podejmowania decyzji, tylko jedno dostarcza jednoznacznych wskazówek. Są to uwarunkowania bioetyczne regulowane przez odpowiednie przepisy prawa i deontologii lekarskiej. Przesłanki dostarczane przez kliniczne obserwacje pacjenta są obciążone błędami pomiarowymi. Wskazania wynikające z aktualnej wiedzy medycznej są obciążone błędami zastosowanych modeli. Z kolei uwarunkowania decyzyjne uwzględniające preferencje pacjenta mogą być także obciążone błędem samoświadomości chorego.

Wprowadzenie do codziennej praktyki lekarskiej zasad medycyny opartej o dowody przyczynia się do standaryzacji metodologii podejmowania

decyzji lekarskich. Przedstawiony model postępowania klinicznego jest pomostem między sztuką lekarską a medycyną naukową wspomaganą techniką. Na każdym etapie proces decyzji klinicznych może być wspierany przez zaawansowane systemy komputerowego wspomagania decyzji.

1.5 Informacja, inteligencja, komputer

1.5.1 Informacja

Jesteśmy świadkami ery informacji o technologicznych podstawach, którą charakteryzuje intensywny rozwój społeczeństwa informacyjnego, przekształcającego się stopniowo w społeczeństwo szeroko dostępnej (tzw. wolnej) wiedzy. Wobec rosnącej roli Internetu można mówić również o zjawisku tworzenia się społeczeństwa sieciowego (prace Castellsa [1]). Coraz większe znaczenie rozwoju technologicznego, zdominowanego przez zagadnienie efektywnej wymiany informacji oraz świata nauk przyrodniczych i ścisłych widać chociażby w propozycjach tzw. trzeciej kultury [2].

Statystyczna teoria informacji jest znacznie częściej wykorzystywana w metodach efektywnej reprezentacji i analizy danych, jednak w nowoczesnych rozwiązaniach coraz większą rolę odgrywa semantyczny aspekt informacji. Semantyczna analiza obrazów, ekstrakcja informacji diagnostycznej staje się najważniejszym elementem metod komputerowego wspomagania diagnozy.

Teoria statystyczna

Prace C. Shannona sprzed ponad 50 lat określiły matematyczne podstawy statystycznej teorii informacji formalizując m.in. pojęcia statystycznego źródła informacji z modelem procesu losowego o ciągłym zbiorze wartości, entropii jako miary informacji, zniekształceń źródeł informacji.

Zaproponowany przez Shannona opis informacji znalazł powszechne zastosowanie w różnych dziedzinach nauki, m.in. w biologii, medycynie, filozofii. Występuje w nim stochastyczne rozumienie informacji jako "poziomu niepewności" odbiorcy związanej z analizą dostępnych danych. Trudno podważyć ogromne znaczenie teorii Shannona w rozwoju współczesnej nauki. Jednak warto zwrócić uwagę na ograniczenia tej teorii, szczególnie w zakresie uproszczonych, nierealistycznych założeń statystycznych oraz poprzez pominięcie semantyki w definiowaniu źródeł informacji.

W statystycznej teorii informacji dominuje składniowy (syntaktyczny) aspekt informacji. Nie prowadzi się rozważań dotyczących prawdziwości czy użyteczności danych. Informacja rozumiana jest wtedy jako rozważany

ciąg symboli źródła informacji nad ustalonym alfabetem z ogólnie przyjętą wartością semantyczną (znaczeniem).

Teoria semantyczna

W niektórych przypadkach semantyka obrazów odgrywa na tyle znaczącą rolę w interpretacji (użytkowaniu, odczytaniu zawartej informacji) przekazywanych danych, że powinna stanowić ważny element w procesie optymalizacji algorytmów kompresji jako "uzupełnienie" statystycznej teorii informacji. Ważnym obszarem zastosowań jest tutaj obrazowanie medyczne.

Dwa zasadnicze cele teorii Shannona to: a) obliczanie ilości informacji dostarczanej przez źródła możliwie wiernie opisujące przesyłane dane, b) opracowanie efektywnych kodów bazujących na właściwych modelach statystycznych źródeł informacji. Oba te elementy wymagają ustalenia znaczeń pojedynczej danej, kontekstu jej wystąpienia, charakteru reprezentowanej informacji.

Należy tutaj odwołać się do podstaw ogólnej teorii informacji, w której występuje pojęcie semantycznej teorii informacji. Początki tej teorii stanowią prace Bar-Hillela i Carnapa [?] również z lat 50 zeszłego wieku, a istotą jest określanie dodatkowo znaczenia poszczególnych symboli alfabetu źródła informacji. Wykorzystanie ontologicznych i aksjologicznych aspektów rozumienia informacji jest trudne do przełożenia na formalny i algorytmiczny opis modeli źródeł informacji, jednak wykorzystanie elementów tych teorii wydaje się konieczne w takich zastosowaniach jak np. analiza, rekonstrukcja i indeksowanie treści obrazów medycznych w sposób wiarygodny diagnostycznie.

Algorytmiczne wykorzystanie zasad semantycznej teorii informacji może być nieco łatwiejsze poprzez skorzystanie z tych metod matematycznych, które ułatwią semantyczną selekcję w algorytmach rozpoznawania. Chodzi tu o wykorzystanie analizy funkcjonalnej, które pozwala w większym uwolnić się od nierealistycznych założeń statystycznych dobierając bazy przekształceń przybliżających efektywnie lokalne, chwilowe właściwości sygnału. Ułatwia to także dostosowanie metody analizy do semantyki źródła informacji poprzez większe uporządkowanie informacji (zhierarchizowanie jej opisu) i dokładniejszy jej opis (czasową charakterystykę wielu skal ułatwiającą rozdzielenie sygnału od szumu) w nowej dziedzinie przekształcenia.

W latach 50 zeszłego stulecia powstała "moskiewska szkoła teorii informacji" z jej najznakomitszym przedstawicielem A.N. Kołmogorowem. Obok probabilistycznych sposobów modelowania źródeł informacji wykorzystano tam także teorię przybliżania (aproksymacji) źródeł z wykorzystaniem me-

tod analizy funkcjonalnej. Stochastyczny proces opisujący źródło informacji zastąpiony jest przez klasę funkcji (sygnałów) f określonych w dziedzinie T . Dowolna funkcja jest aproksymowana i dyskretyzowana przez koder za pomocą sieci aproksymacji. Sieć aproksymacji według koncepcji Kołmogorowa [?] jest zbiorem funkcji możliwie zupełnym i mało-licznym (kontrolowanym przez inne pojęcie entropii), aproksymującym istotne cechy sygnałów (funkcji) źródłowych. Kryteria doboru i optymalizacji postaci sieci formułowane jako minimalizacja błędu przybliżenia definiują proces reprezentacji (modelowania) danych z dopuszczeniem strat.

Na poziomie ogólności proponowanym przez teorię Kołmogorowa bardzo niewiele można powiedzieć o strukturze optymalnej dla danego problemu sieci aproksymacji. Chociaż alternatywna teoria opisu informacji nie prowadzi to dokładnych oszacowań relacji złożoności modelu źródła do ilości reprezentowanej informacji, to jest istotna ze względu na sugestie funkcjonalnego modelowania źródeł. Chodzi o wyznaczenie efektywnych baz przekształceń obrazów w celu lepszego opisu informacji.

Wykorzystanie doświadczeń semantycznej teorii informacji, dodatkowo coraz doskonalszej wiedzy medycznej na temat zasad percepcji psychowizualnej danych obrazowych i obiektywizacji metod ich interpretacji pozwala konstruować doskonalsze sposoby selekcji i porządkowania analizowanej informacji na podstawie optymalizowanych metod opisu danych (duża rola analizy funkcjonalnej, przede wszystkim analizy harmoniczej, czyli analizy funkcji z wykorzystaniem transformacji o bazie wielu skal dobieranej w przestrzeni czas-częstotliwość).

1.5.2 Inteligencja

W roku 1883 F. Galton twierdził mało wnikliwie: inteligencja to podstawowa zdolność umysłu, decydująca o sukcesie jednostki w „walce o byt”. Znacznie trafniej definiował to pojęcie A. Binet (1905): inteligencja to przede wszystkim zdolność do wydawania trafnych sądów, zwłaszcza w odniesieniu do problemów i sytuacji dnia codziennego. Warte podkreślenia jest bardzo praktyczne rozumienie inteligencji. Inteligencję utożsamiano ze sprawnością w zakresie: 1) rozumienia słów, 2) używania słów („płynność słowna”), 3) posługiwania się liczbami, 4) zapamiętywania, 5) szybkości spostrzegania, 6) rozumowania przez indukcję, 7) wyobraźni przestrzennej (jest to 7 pierwotnych zdolności umysłowych).

Inteligencja (słownikowo) to cecha umysłu odpowiadająca za sprawność w zakresie myślenia, rozwiązywania problemów i innych czynności poznawczych. Od poziomu inteligencji zależy poprawność rozumienia złożonych problemów i skuteczność poszukiwania trafnych rozwiązań, a także spraw-

ność działania w warunkach trudnych, nieznanach, przy silnych ograniczeniach, w stresie. Inteligencja to sprawne uczenie się, myślenie abstrakcyjne, adaptacja do bieżącej sytuacji, podejmowanie skutecznych decyzji, ale i świadomość.

Sztuczna inteligencja

Sztuczna inteligencja kojarzona jest z maszyną myślącą, czyli są to metody, algorytmy, urządzenia posiadające funkcje ludzkiego umysłu. Inaczej, sztuczna inteligencja jest nauką o maszynach wykonujących zadania, które wymagają inteligencji, gdy są rozwiązywane przez człowieka.

Według słownika PWN **inteligencja sztuczna**, ang. *artificial intelligence (AI)*, to dział informatyki, którego przedmiotem jest badanie reguł rządzących tzw. inteligentnymi zachowaniami człowieka, tworzenie modeli formalnych tych zachowań i w rezultacie implementacji (algorytmów, programów, sprzętu) komputerowych symulujących te zachowania. Do zachowań inteligentnych zalicza się przede wszystkim postrzeganie, rozpoznawanie, uczenie się, operowanie symbolami, posługiwanie się językiem, rozwiązywanie problemów, kreatywność (twórczość, oryginalność) i in.

Realizacje komputerowe wykorzystuje się do rozpoznawania kształtów (np. pisma, elementów obrazów), dźwięków (np. mowy), do gry (np. w szachy), dowodzenia twierdzeń, w celu komponowania muzyki, tłumaczenia testów, formułowania ekspertyz (ocen, opinii), sterowania robotami, złożonymi procesami technologicznymi, a nawet do sugerowania prostych diagnoz lekarskich.

Toczy się spór o świadomość, tj. możliwość wytworzenia świadomych systemów sztucznej inteligencji. Wielu przedstawicieli nauki o procesach poznawczych (ang. *cognitive science*), m.in. M. Minsky, widzi taką możliwość, zaś sceptycy (m.in. J.R. Searle, R. Penrose) twierdzą, że świadomość jest jedyną w swoim rodzaju właściwością ludzkiego mózgu, który nie przypomina w działaniu komputera.

Komputer (nie)może być inteligentny

Ponieważ termin "inteligencja" trudno precyzyjnie zdefiniować, zmierzyć, jednoznacznie ocenić, Turing zaproponował test oceny subiektywnej z kryterium weryfikacji: nie sposób odróżnić komputera od człowieka na podstawie udzielanych odpowiedzi. Celem jest stwierdzenie, czy maszyna jest inteligentna. Osoba oceniająca zadaje pytania, na które odpowiadają w sposób anonimowy maszyna oraz człowiek. Jeśli maszyna zostanie uznana za człowieka, to można o niej powiedzieć, że jest inteligentna.

1.5.3 Wspomaganie diagnostyki obrazowej

Niewątpliwie wspomaganie metodami komputerowymi obrazowej diagnostyki medycznej należy w dużym stopniu do obszaru sztucznej inteligencji. Występuje przede wszystkim wykorzystanie wielu wspólnych sposobów analizy danych, algorytmów przetwarzania, detekcji i klasyfikacji informacji. Jednak równie istotne jest stosowanie teorii przetwarzania obrazów, dostarczającej narzędzi ekstrakcji informacji i modelowania percepcji zmian w obrazach. Trzecim niezwykle ważnym elementem jest wykorzystanie wiedzy medycznej, charakterystyki subiektywnych ocen zmian, procesu interpretacji obrazów i weryfikacji ocen w niepowtarzalnych uwarunkowaniach klinicznych.

Zadania stawiane przed systemami wspomagania są wymagające. Kilka problemów ważnych z medycznego punktu widzenia, których nie sposób zalgorytmizować w sposób wiarygodny to:

- Poprawa warunków pracy ("okulary" - większa zdolność postrzegania, usprawnienie pracy, wyznaczenie parametrów obliczeniowych):
 - wydobywanie informacji ukrytej z obrazów, uwydatnianie cech (metodami przetwarzania)
 - wyszukiwanie, semantyczny opis (indeksowanie, gromadzenie, przesyłanie) informacji diagnostycznej
 - poprawa percepcji zmian (wizualizacja cech o dużym znaczeniu diagnostycznym)
 - liczbowa (parametryczna) charakterystyka struktur wykrytych
- Zwiększenie czułości ("większa czujność"):
 - selekcja cech istotnych diagnostycznie
 - obiektywizacja: diagnozy, oceny, procesów podejmowania decyzji
 - rozpoznawanie, wskazywanie symptomów
- Zwiększenie trafności ("wzrost nieomyślności"):
 - wspomaganie decyzji
 - planowanie: terapii
 - kontrola: leki
 - sterowanie i monitorowanie
 - prognozowanie
 - uczenie lekarzy

Jak dotąd stosowanie metod komputerowego wspomagania w medycznej diagnostyce obrazowej jest rzadkie. Powodów takiego stanu rzeczy jest wiele. Przede wszystkim jest to zagadnienie złożone, niepoddające się formalnej czy numerycznej obiektywizacji, cierpiące na brak standardów, bardzo silnie zależne od czynnika ludzkiego. Są jednak obszary w medycynie, gdzie metody te są z sukcesem wykorzystywane od wielu lat.

Przykłady znanych zastosowań metod komputerowego wspomagania medycyny:

- Inteligentne wspomaganie decyzji: diagnozy medyczne, zalecenia dodatkowych testów, decyzje w nagłych przypadkach;
- Klasyfikacja struktur: rozpoznawanie symptomów, klasyfikacja stanu zdrowia, zachowań człowieka, sensu wypowiedzi;
- Kontrola: sprawdzanie dawek leków, możliwych interakcji leków, potencjalnych przeciwwskazań;
- Planowanie: terapii, diety, optymalizacja działań w trakcie jej przebiegu;
- Sterowanie: urządzeń podtrzymujących funkcje życiowe, monitorowanie stanu pacjenta i ostrzeganie w sytuacjach kryzysowych;
- Analiza obrazów: rozpoznawanie i interpretacja obrazów z aparatury medycznej, kontrola jakości obrazu;
- Detekcja regularności: wykrywanie niebezpiecznych symptomów w sygnałach EKG, EEG i innych;
- Separacja sygnałów z wielu źródeł: oczyszczanie obrazów z szumów, filtracja sygnałów elektrycznych (np. mrugania powiek z EEG);
- Prognozowanie: rozwoju choroby;
- Gry strategiczne: uczenie się na błędach w symulowanej rzeczywistości;
- Szukanie wiedzy w medycznych bazach danych, wniosków z obserwacji, inteligentne szukanie informacji (szukanie semantyczne);
- Selekcja cech: na co warto zwrócić uwagę;
- Redukcja wymiarowości problemu, możliwości oglądania danych w relacji do innych;

- Optymalizacja wielokryterialna i optymalne spełnianie ograniczeń;
- Zrozumienie umysłu: doświadczeń psychologicznych, sposobu rozumowania i kategoryzacji, poruszania się i planowania, procesów uczenia - przydatne każdemu;
- Opieka pooperacyjna (wymaga dużego doświadczenia), wspomaganie decyzji w oparciu o monitorowanie symptomów i obserwację oczekiwanych zmian;
- Określenie składu pozajelitowego odżywiania noworodków na oddziałach intensywnej opieki (system ekspertowy);
- Zarządzanie systemem sztucznego oddychania dla oddziałów intensywnej opieki (system ekspertowy).
- Inne

Rozdział 3

Środowisko: centra radiologii cyfrowej, PACS, RIS, telemedycyna, CAD

3.1 Centra radiologii cyfrowej

Współczesne trendy technologicznie warunkujące rozwój radiologii to:

- środowisko w pełni cyfrowe, czyli zintegrowane medyczne systemy informacyjne;
- włączenie wszystkich oddziałów szpitala (w tym centrum radiologii) w kompleksową sieć gromadzenia i wymiany informacji - szpitalny system informacyjny (HIS);
- powszechny dostęp sieciowy, Internet;
- rozwój telemedycyny (w tym teleradiologii, telekonsultacji, teledygnozy);
- doskonalenie zintegrowanych systemów obrotu informacją obrazową (typu PACS-RIS);
- rozwój nowoczesnych metod zarządzania przepływem informacji (w tym zabezpieczenia, standaryzacja procedur wymiany, synchronizacji etc.).

Podstawowe elementy zintegrowanego środowiska informacyjnego to PACS, RIS, HIS, CAD, telemedycyna, rozliczenia, statystyka i nadzór, standardy DICOM, HL-7.

3.1.1 Klucz: radiografia cyfrowa

Definicja 3.1 *Radiologia*

Radiologia to nauka zajmująca się wykorzystaniem obrazowania medycznego w celach diagnostycznych i leczniczych.

□

Definicja 3.2 *Radiologia cyfrowa*

Radiologia cyfrowa to zastosowanie technik komputerowych w systemach obrazowania medycznego.

□

Definicja 3.3 *Radiografia cyfrowa*

Radiografia cyfrowa to operacje na obrazach cyfrowych zastosowane do prześwietleniowych badań rentgenowskich.

□

Definicja 3.4 *Centrum radiologii cyfrowej*

Centrum radiologii cyfrowej to zintegrowane środowisko akwizycji, gromadzenia, wymiany, wizualizacji, przeszukiwania, opisu badań obrazowych z komputerowym wspomaganie diagnostyki.

□

Kluczem do ośrodków radiologicznych w pełni cyfrowych jest radiografia cyfrowa. Udział radiografii w rynku badań obrazowych jest dominujący (3.1).


3.1.2 Szpitalny system informacyjny HIS

Definicja uproszczona (wstępna): HIS to zbiór komputerowych aplikacji wykorzystywanych przez wszystkie oddziały szpitalne (w tym wyspecjalizowane).

Definicja ideowa (docelowa): HIS to zintegrowany system obiegu informacji (obsługi informatycznej) szpitala. Podstawowe cechy systemu szpitalnego to: otwartość, złożoność, moduły, sprzęganie, standaryzacja, dostępność, niezawodność. Do zadań należy rejestracja, nadzór ruchu pacjentów, zlecenia, stosowanie leków, wyniki badań (laboratoria, radiologia, telemetria, intensywny nadzór), opisy i zalecenia, raportowanie, kosztorysy itp.

HL7

Jest to norma definiująca przesyłanie (wymianę) danych (informacji) tekstowych w medycznych środowiskach informacyjnych (informatycznych).



Rys. 3.1: Podział rynku obrazowych badań medycznych.

Bazuje na warstwie aplikacyjnej (warstwa 7) modelu OSI (*Open Systems Interconnect*) opracowanego przez ISO. Istotne cechy to:

- wymiana informacji za pomocą transakcji (bloków danych) złożonych z segmentów (tj. pól, elementów pól, podelementów pól)
- najważniejsze segmenty: początek-aplikacja wysyłająca i odbierająca (MSH), nagłówki transakcji (MSG), dane pacjenta (PID), dane z pobytu w szpitalu (PV1), treść zlecenia (ORC), dane zlecenia (OBR), wyniki badań (OBX), potwierdzenie odbioru (MSA), uwagi i komentarze (NTE)
- kodowanie znaków w ASCII oraz kodów narodowych
- wymiana poprzez zdarzenia (przesłanie) i potwierdzenia odbioru

3.1.3 Radiologiczny system informacyjny RIS

Jest to system zapewniający (wspomagający) obsługę informatycznych procedur (zadań) wykonywanych w ramach diagnostyki obrazowej w zakresie

wymiany (obrotu) danych tekstowych:

- dane pacjenta
- zlecenia
- terminy
- wykonanie badania
- zużyty materiał, obsługa magazynu
- raporty
- statystyka, rozliczenia
-

Podstawowym założeniem uzasadniającym istnienie takich systemów jest możliwie ścisła integracja ze źródłami danych obrazowych (zarządzanymi poprzez PACS) oraz siecią stacji diagnostycznych.

3.1.4 Systemy archiwizacji i transmisji obrazów

Historyczny rozwój tych systemów można zamknąć w następujących etapach:

- PACS I generacji działające według schematu: źródło badań obrazowych → transmisja (sieć) → archiwum (serwer) → stacja diagnostyczna;
- PACS II generacji: większa standaryzacja oraz zarządzanie informacją (DICOM);
- PACS III generacji: dodatkowo wykorzystanie metod CAD, kontroli jakości obrazowania i wymiany danych, przeszukiwanie bazy obrazowej po zawartości.

Celem systemów archiwizacji i transmisji obrazów jest obsługa informatyczna procedur (zadań) wykonywanych w ramach diagnostyki obrazowej w zakresie danych obrazowych. Elementami wykorzystywanymi w PACS są systemy obrazowania, monitory, serwery zapasowe, archiwa - magazyny danych, drukarki, skanery, czytniki itp.

Koncepcja systemu archiwizacji i transmisji obrazów (*ang. PACS*) pochodzi z lat osiemdziesiątych. Pierwsze rozwiązania tego typu zbiegły się w czasie z rewolucją komputerów osobistych, które stały się dostatecznie

tanie i proste w obsłudze, by stać się narzędziem pracy lekarzy i służb medycznych. Szybki rozwój technologiczny, umożliwiający zapis obrazów diagnostycznych w postaci cyfrowej, zmienił sposób ich analizy oraz przyczynił się do ich reorganizacji, archiwizacji i łatwiejszej dystrybucji. Obrazy, wcześniej otrzymywane jedynie na materiałach światłoczułych, zaczęły być przechowywane na różnego rodzaju nośnikach magnetycznych, magneto-optycznych. Oprócz korzyści wynikających z samej formy archiwizacji mamy szereg korzyści z możliwości komputerowego przetwarzania tak zapisanych obrazów - oprócz samego wyświetlania należy do nich możliwość ich przesłania, zarówno pomiędzy różnymi punktami np. tego samego szpitala, jak i pomiędzy szpitalami. Skraca to czas dostępu do informacji obrazowej oraz redukuje koszty.

3.1.5 PACS pierwszej generacji

Jak już wspomniano, systemy PACS swoje korzenie mają w latach osiemdziesiątych, kiedy to zrodziła się koncepcja systemu archiwizacji i transmisji obrazów. Później została ona określona mianem systemu PACS pierwszej generacji. Według tej koncepcji system zapewniał transmisję obrazów poprzez sieć komputerową ze punktu akwizycji do miejsca archiwizacji. Stamtąd obrazy mogły zostać przesłane do jednostek komputerowych zdolnych do ich wyświetlania i przetwarzania.

PACS pierwszej generacji zawierał więc 4 główne elementy składowe: [73]

- stacje akwizycyjne
- serwer
- stacje robocze
- sieć komputerową

Stacje akwizycyjne odpowiedzialne są za rejestrację obrazów w postaci cyfrowej. Do najczęściej spotykanych rodzajów stacji akwizycyjnych należą:

- tomografy komputerowe (*computed tomography* - *CT*)
- tomografy emisyjne (*single photon emission computed tomography* - *SPECT*, *positron emission tomography* - *PET*)
- rezonans magnetyczny (*magnetic resonance* - *MR*)
- radiografię komputerową (*computed radiography* - *CR*)

- ultrasonografię (*ultrasonography* - *USG*)

Często spotykane jest też wprowadzanie do PACS obrazów zarejestrowanych na klasycznych nośnikach i następnie poddanych skanowaniu.

W systemach pierwszej generacji zadaniem serwera jest zarządzanie przysyłanymi obrazami, ich dystrybucja do stacji diagnostycznych oraz archiwizacja. Warto wspomnieć w tym momencie o wadze i sporej ilości problemów związanych właśnie z archiwizacją. Przede wszystkim mamy tu do czynienia z bardzo dużą ilością informacji. Typowy obraz mammograficzny to kilka tysięcy na kilka tysięcy punktów, z kilkunastoma bitami na piksel. Inne modalności to bardzo często całe sekwencje obrazów. Łatwo więc sobie wyobrazić skalę problemu dla większego ośrodka obrazowania medycznego. Typowo stosowanymi nośnikami w jednostce archiwizującej były szybkie dyski magnetyczne, taśmy magnetyczne oraz pamięci magneto-optyczne. Wybór typu nośnika był kompromisem między ceną a czasem dostępu do informacji. Wysoka cena pamięci magnetycznej oraz długi czas dostępu dla pamięci taśmowej sprawiały, że rozsądnym kompromisem były stacje wielodyskowe (*ang. jukebox*) wykorzystujące dyski magneto-optyczne. Pojemności tych stacji wahały się od kilkuset gigabitów do kilku terabitów [73]. Z pewnością też szybką popularność uzyskują nośniki optyczne, bazujące na technologii stosowanej w płytach DVD, co daje nadzieje na tanie i dające rozsądny kompromis między szybkością dostępu i pojemnością, rozwiązanie.

Stacje robocze przeznaczone do wyświetlania i przetwarzania obrazów, wyposażone były w jeden lub kilka monitorów o rozdzielczości od 512 do 2048 linii. Monitory o rozdzielczości 512 linii wykorzystywano głównie do wstępnego przeglądu obrazów. Monitory średniej rozdzielczości (ok. 1024 linii) wykorzystywane były do analizy obrazów TK, MR, USG, SPECT. Monitory o wysokiej rozdzielczości były wykorzystywane do szczegółowej analizy obrazów CR oraz w analizie porównawczej badań pochodzących z różnych modułów akwizycyjnych. [73]

Do transmisji obrazów wewnątrz szpitala lub pomiędzy nimi stosowano różnorodne rozwiązania, najczęściej jednak były one oparte o Ethernet lub FDDI (Fiber Distributed Data Transfer). Szczegółowy dobór protokołu komunikacyjnego zależał jednak od producenta systemu i był cechą wysoce zindywidualizowaną.

3.1.6 PACS drugiej generacji

PACS pierwszej generacji powstawał jako system do przesyłania i archiwizacji obrazów. Jednak wraz z rozwojem i coraz śmielszym wkraczaniem

techniki komputerowej do różnych obszarów działalności szpitala narodziła się koncepcja systemu PACS drugiej generacji. Rozszerza on standard pierwszej generacji o standaryzację formatu protokołów komunikacyjnych oraz określa mechanizmy zarządzania danymi.

Ten rozwój systemów PACS pozostawał w ścisłym związku ze standardem umożliwiającym współpracę urządzeniom różnych producentów. Na początku lat 80 American College of Radiology i National Electrical Manufacturers Association ustanowili wspólnie standard ACR-NEMA w wersji 1.0 oraz 2.0, definiujący format zbioru danych oraz protokół komunikacyjny. Z początkiem lat 90 ACR-NEMA został rozszerzony do standardu DICOM 3.0 (Digital Imaging and Communication in Medicine). Standaryzacja objęła trzy obszary:[73]


- Archiwum (baza danych, formaty, serwer)
- Komunikacja (protokoły, serwer, konwertery)
- Integracja PACS w medycznych systemach informacyjnych (serwer)

Szczególnie ten ostatni punkt - integracja PACS-u z innymi systemami informacyjnymi w szpitalu należy uznać za kluczowy. Integracja z HIS (Hospital Information System) i RIS (Radiological Information System) znacząco rozszerza zakres funkcji realizowanych przez serwer PACS, który poza archiwizacją i udostępnianiem danych obrazowych pełni również funkcję ośrodka zarządzającego bazą danych. Coraz bardziej wyszukane funkcje wyszukiwania i zarządzania informacją obrazową (jak wyszukiwanie obrazów po zawartości, ang. content-based image retrieval) powodują coraz bardziej znaczące rozszerzają możliwości i funkcje serwera PACS (rys. 3.2).

3.1.7 Integracja HIS-PACS

Integracja systemów PACS z innymi rozwiązaniami wynika z idei jednokrotnego wprowadzania tej samej informacji. Z punktu widzenia użytkownika systemu informatycznego w szpitalu niezrozumiała jest konieczność wprowadzania tej samej informacji (jak np. dane osobowe pacjenta) kilkakrotnie, do różnych z technicznego punktu widzenia systemów. Choćby wspomniane dane osobowe - powinny być wprowadzone do systemu jednokrotnie, w momencie rejestracji, i być dostępne we wszystkich elementach systemu w których są potrzebne.

Generalnie rzecz biorąc, integracji systemów służą dwa standardy: HL7 oraz DICOM. Standard HL7 (*Health Level 7*) jest standardem wymiany danych cyfrowych pomiędzy instytucjami medycznymi. Jego podstawowym



Rys. 3.2: Schemat systemu PACS.

celem jest dostarczenie elastycznej i efektywnej metodologii wymiany informacji medycznej. Jest zdefiniowany jako niezależny od systemu komputerowego oraz protokołu komunikacyjnego używanego do wymiany danych. W odróżnieniu od większości innych standardów, które skupiają się na wymaganiach specyficznych dla określonych działów nauk medycznych, HL7 proponuje rozwiązania, które mogą być wykorzystywane w każdej instytucji medycznej, niezależnie od charakteru jej pracy.


HL7 jest więc, obok standardu DICOM, jedną z dwóch głównych obowiązujących wytycznych dotyczących informatyki medycznej. Istotne jest więc rozróżnienie celów obu rozwiązań. HL7 dotyczy w głównej mierze danych klinicznych i administracyjnych[95].

DICOM natomiast jest zbiorem standardów dotyczących przetwarzania, składowania i transmisji medycznych danych obrazowych. Jego podstawowym celem jest zapewnienie integracji medycznych urządzeń obrazujących, skanerów, serwerów, stacji roboczych i innych elementów infrastruktury ośrodka medycznego, związanej z akwizycją, przetwarzaniem i składowaniem danych obrazowych.

3.1.8 DICOM

Standard ten dotyczy przede wszystkim trzech istotnych zagadnień związanych z użytkowaniem badań obrazowych:

- archiwum (baza danych, formaty, serwer)
- komunikacji (protokoły, serwer, konwertery)
- integracji PACS w medycznych systemach informacyjnych (serwer)




Rys. 3.3: Bardzo ogólny schemat usług w standardzie DICOM.


3.1.9 IHE

Początki tej inicjatywy sięgają roku 1998, obecnie zaś uczestniczy w niej wiele podmiotów z Europy, Azji i Ameryki. Liczni producenci zamiast rywalizować i podkreślać specyfikę swoich produktów także na poziomie formatów zapisu i wymiany danych są współprojektantami i współtwórcami możliwie pełnej integracji informatycznej swoich produktów. Zasadniczym celem IHE jest bowiem pełna integracja medycznych środowisk informacyjnych. Poszukiwany jest więc wspólny język integracji systemów bazujący na strukturach XML, mechanizmach standardów DICOM i HL7. Zdefiniowano następujące profile integracyjne:

- sekwencji usług



jednostki, moduły, atrybuty



Rys. 3.4: Struktura informacji tekstowej w DICOM na przykładzie konkretnego badania TK mózgu.

- aktualizacji danych pacjenta
- spójnej prezentacji obrazu
- prezentacji zgrupowanych procedur
- obrazów kluczowych
- dostępu do informacji radiologicznych

- obrazów podstawowych i raportów numerycznych
- przepływu procedur zaawansowanego przetwarzania (CAD-PACS)
- rozliczania
- bezpieczeństwa

Więcej informacji można znaleźć na stronie: <http://www.ihe.net/>

3.2 Referencyjne bazy danych obrazowych

W ostatniej dekadzie dziedzina indeksowania obrazów stała się intensywnie eksplorowanym polem badawczym, poczynając od ośrodków rządowych [88, 89] poprzez organizacje komercyjne [90, 92, 93], aż do środowisk akademickich. Również organizacje standaryzacyjne, na przykład International Standard Organization (ISO/IEC), zajęły się tą tematyką. ISO/IEC powołał specjalną grupę roboczą, która pracuje nad zdefiniowaniem standardu opisu zawartości multimedialnej [94]. Powody tego wzmożonego zainteresowania tą tematyką są złożone, z pewnością jednak do głównych powodów zaliczyć należy lawinowo rosnącą ilość danych obrazowych pochodzących z urządzeń cyfrowych. Trend ten jest dostrzegalny zarówno w dziedzinie urządzeń profesjonalnych wszelkiego rodzaju, jak i w życiu codziennym, gdzie obserwujemy choćby ekspansję cyfrowych aparatów fotograficznych. Wywołuje to rosnącą potrzebę coraz efektywniejszych mechanizmów indeksowania i wyszukiwania danych. Tradycyjne techniki wyszukiwania informacji efektywnie spełniają swoje zadania w odniesieniu do informacji tekstowych. Treści informacyjne zawarte w obrazach, zbiorach dźwiękowych czy sekwencjach wideo wymagają nieco innego podejścia i w związku z tym nowych metod i algorytmów.

Mechanizmy indeksacji i wyszukiwania są powszechnie stosowane w naszym codziennym życiu. Wszyscy przecież korzystamy z internetowych mechanizmów wyszukiwania informacji, takich jak GoogleTM, AltaVistaTM czy YahooTM. Wszystkie one bazują jednak na klasycznym, opartym o tekst, sposobie wyszukiwania. Nawet usługi dedykowane do wyszukiwania informacji multimedialnych, takie jak Google Imagetrademark opierają się na informacji tekstowej, towarzyszącej obrazowi na stronie WWW, a nie na samym obrazie.

W dużej mierze ta nieobecność mechanizmów wyszukiwania innych niż tekstowe wynika z trudności zagadnienia indeksacji innymi metodami. Trudności te wynikają z kilku czynników. Przede wszystkim z bogactwa treści

informacyjnej, którą niesie obraz, dźwięk czy sekwencja wideo w porównaniu do tekstu. Znane powiedzenie, że "jeden obraz wart jest tysiąca słów" śmiało można uznać za niedoszacowanie. Kolejną kwestią jest fakt, że w dziedzinie obrazu trudno znaleźć odpowiednik słowa kluczowego z wyszukiwania tekstowego. Jeszcze trudniej jest określić, jak te "słowa kluczowe" dla obrazu uzyskać.

3.2.1 Wprowadzenie do indeksowania obrazów zawartością

Indeksowanie obrazów zawartością jest bardzo intensywnie rozwijającym się polem badawczym od lat 70. Duży wpływ na tą dziedzinę miał rozwój dwóch innych dziedzin wiedzy: teorii cyfrowego przetwarzania obrazu oraz technologii bazodanowych. Te pierwsze wpływały na rozwój cech obrazowych, używanych do indeksowania, drugie - wychodząc od indeksowania bazującego na opisie alfanumerycznym - na mechanizmy indeksujące i struktury danych.

Początków indeksowania obrazów, bazującego na opisie alfanumerycznym, można doszukać się w latach 70. Proponowane wówczas podejście polegało na manualnym opisaniu obrazów a następnie ich wyszukiwaniu z użyciem silnika bazodanowego (ang. database management system, DBMS).. Wiele technik, związanych w oceną efektywności zapytań, strukturami danych, metodami przechowywania indeksów, wywodzi się właśnie z badań nad indeksowaniem obrazów bazującym na opisie tekstowym.

Taka forma wyszukiwania informacji obrazowej wciąż oczywiście jest stosowana i trudno sobie wyobrazić, żeby w najbliższej przyszłości ten stan rzeczy uległ zmianie. Tym niemniej istnieją przynajmniej dwa punkty, gdzie podejście bazujące na zawartości obrazu wygląda atrakcyjnie - szczególnie gdy mamy do czynienia z dużymi zbiorami obrazów, liczącymi kilkadziesiąt czy kilkaset tysięcy elementów. W takiej sytuacji ręczny opis może stać się kłopotliwy. Co więcej jednak, alfanumeryczny opis bardzo rzadko, o ile w ogóle, może oddać bogactwo treści zawartej w obrazie. Opis zawsze jest zależny od kontekstu, sytuacja w jakiej jest dokonywany. Jeśli w momencie dokonywania opisu znany jest kontekst, w jakim obraz będzie wyszukiwany, sytuacja nie jest taka zła. Możemy dostosować charakter opisu do tego kontekstu. Jednak często kontekst ten nie jest dokładnie znany. Wówczas powstaje problem opisanie obrazu w taki sposób, aby nie utracić żadnej istotnej informacji w nim zawartej. Ale co będzie dla szukającego istotne ? Tego nie wiemy, więc koło się zamyka.

Mechanizm wyszukiwania po zawartości może w takiej sytuacji być pomocny. Cechy wyznaczane na podstawie samego obrazu mogą obejmować znacznie szerszy obszar semantyczny obrazu i, w związku z tym, są niejako

ko lepiej przygotowane do szerszej grupy zapytań, osadzonych w różnym kontekście i mających na celu wyszukanie obrazu pod innym kątem.


W latach 90. rozwój technik informatycznych sprawił, że duże bazy obrazowe stały się coraz powszechniejsze, również w medycynie. Przedstawione powyżej dwa problemy z alfanumerycznym opisem danych obrazowych stały się coraz poważniejsze. Koncepcja indeksowania obrazów zawartością jest próbą rozwiązania tych problemów. W miejsce manualnego opisu obrazów proponuje się tutaj opis bazujący na cechach samego obrazu, takich jak histogram, cechy teksturowe, itp. Co ważne, pozyskiwane są one z obrazu w sposób automatyczny, co bardzo znacząco zmniejsza koszt (dowolnie rozumiany - czasowy, ludzki, finansowy) utworzenia takiego opisu - w porównaniu do opisu tworzonego przez człowieka. Odpowiednio konstruując zestaw wykorzystywanych cech możemy też minimalizować kontekstowość opisu, starając się dopasować cechy do możliwie szerokiej gamy możliwych kryteriów wyszukiwania - przynajmniej teoretycznie.

3.2.2 Systemy indeksowania zawartością w medycynie

Jak już wspomniano, ostatnie lata to gwałtowny wzrost ilości powstających obrazów cyfrowych. Dotyczy to również obrazów medycznych. Często spotykanym w literaturze przykładem jest szpital genewski, gdzie w 2002 roku powstawało 12000 obrazów dziennie, w tej chwili ta liczba z pewnością nie zmniejszyła się za sprawą choćby coraz powszechniejszej obecności cyfrowych urządzeń obrazujących w ośrodkach medycznych. Zarządzanie i dostęp do takiej ilości danych staje się coraz bardziej kłopotliwy, w większości bowiem jest on oparty na danych identyfikujących pacjenta bądź charakteryzujących badanie (opis, modalność, itp.) [99] tak jak to definiuje standard DICOM [100].

Potrzeba systemu indeksowania zawartością dla obrazów medycznych jest więc jakościowo podobna do innych dziedzin życia. Znacząco inna jest jednak specyfika dziedziny obrazów medycznych. Zostanie ona szczegółowo omówiona w dalszej części pracy, w tym momencie istotne jest, że z tego powodu, całkiem bogata zresztą, ilość publikacji dotyczących tej tematyki zajmuje się potencjalnymi rozwiązaniami bądź omawia wstępne próby adaptacji CBIR (ang. *content-based image retrieval*) w medycynie (rys. 3.5). Niezwykle rzadkie są prace poparte rzetelną oceną efektywności proponowanego rozwiązania. Przykłady zastosowań klinicznych są jeszcze rzadsze.

A przecież potencjalne zastosowania CBIR w dziedzinie obrazów medycznych są bardzo szerokie. Cel działania systemu obrazującego w medycynie często zwykło się definiować jako dostarczenie właściwej informacji we właściwym czasie do właściwej osoby, żeby podnieść jakoś świadczo-



Rys. 3.5: Przykładowe ekrany systemu medycznego CBIR z interfejsem WWW

nej usługi medycznej (ang. right time, right place paradigm)[101]. Klasyczne podejście do wyszukiwania danych medycznych, oparte na nazwisku pacjenta, identyfikatorze badania czy serii nie jest w tym przypadku wystarczające[101]. W praktyce klinicznej istotna, a nawet niezbędna, byłaby możliwość wyszukania danych zawierających tę samą modalność, ten sam obrazowany organ, pokazany w tym samym rzucie, itp. Większość z tych informacji jest oczywiście przewidziana przez standard DICOM, a praktycznie wszystkie cyfrowe urządzenia obrazujące są z nim zgodne, jednak kilka kwestii jest problematycznych. W ramach projektu IRMA przeprowadzono badania[102], w których pokazano, że, przykładowo, w pewnym ośrodku medycznym 16% obrazów miało błędną informację odnośnie obrazowanego organu. W takiej sytuacji wsparcie wyszukiwania opartego na informacji z metadanych związanych z obrazem techniką typu CBIR wydaje się być uzasadnione.

Zastosowaniem, gdzie techniki CBIR mogą być bardzo pomocne, jest szeroko pojęta dydaktyka i badania naukowe. Spotykane w nich repozytoria i referencyjne bazy danych obrazowych często chcielibyśmy przeglądać według dość egzotycznych, trudnych do przewidzenia wcześniej kryteriów, innych niż w przypadku praktyki klinicznej. Atrybuty alfanumeryczne mogą w takiej sytuacji nienajlepiej pasować do naszego zapytania. Innym przykładem przydatności CBIR w przedstawianym zastosowaniu jest sytuacja, gdy chcemy znaleźć obrazy podobne wizualnie, lecz inaczej zdiagnozowane.

Wydaje się, że w zastosowaniach medycznych największą przyszłość mają rozwiązania łączące informację tekstową, z wyszukiwaniem opartym na znanych, tradycyjnych rozwiązaniach bazodanowych (text-based queries) z wyszukiwaniem po zawartości. Znane są już opracowania opisujące takie systemy, określa się je mianem CBIR2.[103]

3.2.3 Systemy indeksowania zawartością

QBIC QBIC (Query By Image Content)[96] jest pierwszym komercyjnym systemem indeksowania obrazów zawartością. Fakt, że był on w ogóle jednym z pierwszych rozwiązań tego typu, a także fakt, że został on wprowadzony na rynek przez tak znaczącą firmę jak IBM sprawił, że mimo swojej prostoty, jest to jeden z bardziej znanych systemów typu CBIR i z pewnością wpłynął na kształt późniejszych rozwiązań w tej dziedzinie.

QBIC obsługuje dużą gamę form zapytań. Może ono być w postaci obrazu przykładowego, konturu, rozkładu kolorystycznego bądź fragmentu tekstury. Wykorzystywane przez system indeksy są relatywnie proste i obejmują proste cechy histogramowe, zmodyfikowane cechy teksturowe Tamury[97] - kombinacja skrośności, kontrastu i kierunkowości[98]. Cechy kształtu w QBIC to cyrkularność, mimośród, orientacja głównych osi i grupa momentów inwariantnych[90].

Z racji prostoty wykorzystanych cech efektywność systemu QBIC nie jest wysoka, tym niemniej znalazł on zastosowanie komercyjne, a w chwili pisania niniejszej pracy był wykorzystywany choćby przez słynne muzeum Ermitaż.

Virage System Virage[92] jest kolejnym, po QBIC, szeroko znanym systemem typu CBIR, o rodowodzie komercyjnym. Obsługuje, tak jak QBIC, dużą gamę form zapytań - obraz przykładowy, kontur, tekstura, rozkład kolorystyczny. Nowa w porównaniu do QBIC jest możliwość stosowania równolegle kilku powyższych form, równolegle w jednym zapytaniu, wraz z przypisaniem każdej wagi do danego elementu zapytania.

System Virage znalazł zastosowanie w wielu instytucjach i firmach, choćby w stacji telewizyjnej CNN.

Zdecydowana większość prac nad systemami indeksowania zawartością prowadzona jest w środowisku akademickim, toteż tutaj właśnie znajdujemy największe bogactwo rozwiązań tego typu i największy dorobek teoretyczny w tym zakresie. Z racji tej ilości trudno o porównanie obejmujące wszystkie znaczące prace. Tym niemniej można wskazać kilka najbardziej znanych rozwiązań.

GIFT Bardzo interesującym i dostępnym w ramach fundacji GNU jest GNU Image Finding Tool (GIFT). Jest to opracowany na uniwersytecie w Genewie system typu CBIR, wykorzystujący do komunikacji z klientem protokół MRML (Multimedia Retrieval Markup Language) [104]. Jest to oparty o XML protokół komunikacji między klientem a serwerem typu CBIR, dający szereg możliwości takich jak uzyskanie informacji o kolekcjach obrazów na serwerze, dostępnych algorytmach, ich parametrach, itp. Jest to interesująca, rozwojowa platforma do budowy własnych rozwiązań tego typu. Istotny przy tym jest dostęp do pełnych kodów źródłowych.

3.2.4 System Flexible Image Retrieval Engine

Flexible Image Retrieval Engine (FIRE)[105] jest projektem związanym z projektem IRMA, mającym na celu zrealizowanie systemu typu CBIR o uniwersalnym przeznaczeniu, zapewniającym architekturę umożliwiającą łatwą rozbudowę systemu o nowe cechy, metryki i struktury danych.

Rozdział 4

Interpretacja informacji obrazowej i weryfikacja narzędzi wspomagania

4.1 Informacja obrazowa

Poprawna interpretacja informacji obrazowej wymaga szerokiej wiedzy dotyczącej przedmiotu badań, sposobu uzyskania obrazu (fizyczne podstawy obrazowania), charakterystyki danej metody obrazowania (specyfika obrazu, artefakty, zdolność rozdzielcza, czułość kontrastu, itd.), właściwości konkretnego urządzenia (systemu) obrazującego, w tym możliwości przetwarzania i wizualizacji badań obrazowych. Rozumienie obrazu jest więc procesem założonym, a kluczową rolę odgrywa szeroko pojęta semantyka zobrazowania.

4.1.1 Ocena jakości obrazów medycznych

Klasa obrazów medycznych wydaje się jedną z najbardziej wymagających pod względem wierności obrazowania przy zachowaniu wysokiej jakości prezentacji wszystkich istotnych szczegółów. Stosowanie w tym przypadku metod przetwarzania, poprawy jakości czy kompresji wymaga skutecznych, jednoznacznych i obiektywnych wskaźników jakości obrazów, najlepiej w kategoriach wartości diagnostycznej. Uśrednione miary o charakterze ogólnym mogą być niewystarczające, a lokalne wskaźniki i ich interpretacja są silnie zależne od semantyki sceny i znaczenia poszczególnych struktur i ich fragmentów. Brak wystarczająco pewnych metod oceny jakości obrazów diagnostycznych jest kłopotliwy przy doskonaleniu metod wspomaga-

nia diagnostyki obrazowej.

Ocena jakości jest zagadnieniem wieloaspektowym, trudnym i często niejednoznacznym, silnie subiektywnym. Ważnym elementem rozważań na temat sposobów oceny jakości obrazów przetworzonych jest analiza jakości obrazu oryginalnego. Trzeba pamiętać o tym, że każdy system obrazowania ma swoje ograniczenia, nie wszystkie cechy prezentowanych obiektów są odzwierciedlane w rejestrowanych obrazach. Każdy system obrazowania można scharakteryzować za pomocą czasowo-częstotliwościowej funkcji przenoszenia, która stanowi kompletny opis danego systemu. Funkcja ta określa częstotliwość graniczną, dopuszczającą określony poziom szczegółowości opisu informacji dotyczącej obiektów reprezentowanych w zarejestrowanym obrazie.

Ocena jakości przetwarzanych obrazów

Obraz jest "dobry" jakości zazwyczaj wtedy, gdy według percepcji wzrokowej wygląda "przyjemnie" (bez rzucających się w oczy zniekształceń), bądź też jest użyteczny do pewnych zastosowań (np. zachowuje pełną informację diagnostyczną oryginału, możliwe jest automatyczne wyznaczanie konturów obiektów bez zmian). Nie istnieje niestety jedna skuteczna miara pozwalająca określić jakość obrazu, szczególnie w zastosowaniach medycznych. Można wyróżnić:

- obiektywne miary zniekształceń (inaczej miary obliczeniowe) - wielkości skalarne bądź wektorowe, wyznaczone automatycznie według ustalonej zależności (obiektywizm rozumiany jest w sensie obliczeniowym);
- subiektywna ocena jakości (inaczej miary obserwacyjne) - psychowizualne testy oceny jakości (diagnostycznej) przeprowadzane przy pomocy grona specjalistów (użytkowników) 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 - bardziej złożone, dotyczące konkretnej aplikacji testy oparte na możliwie wiernej symulacji rzeczywistych warunków interpretacji obrazów medycznych oraz wnikliwej analizie statystycznej odpowiednio opracowanych wyników testów klasyfikacyjnych.

Miary obliczeniowe (obiektywne)

Do najbardziej pożądaných cech miary obiektywnej należy zaliczyć przede wszystkim: duży poziom korelacji z subiektywną oceną jakości (ostateczną weryfikacją przydatności miary obiektywnej jest jej zgodność z oceną psychowizualną) oraz wysoką podatność w analizie obliczeniowej, tj. łatwość obliczeniową, prostotę aplikacji, bogactwo narzędzi do analizy i optymalizacji oraz łatwość interpretacji. Połączenie tych dwóch cech okazuje się w praktyce bardzo trudne.

Miary skalarne W przypadku miar skalarnych uzyskanie dobrej korelacji z oceną subiektywną jest bardzo trudne. Miary te dają jednak łatwość interpretacji i analiz porównawczych. Niech oryginalny obraz cyfrowy, wielopoziomowy ze skalą szarości, o szerokości M i wysokości N będzie opisany funkcją jasności $f(m, n)$, $0 \leq m < M$, $0 \leq n < N$.

Wartości pikseli obrazu przetworzonego w tej samej dziedzinie oznaczono przez $\tilde{f}(m, n)$. Do najbardziej użytecznych (na podstawie eksperymentów własnych, a także analizy literaturowej) skalarnych miar jakości obrazów (z kategorii metod porównawczych) zaliczyć należy przede wszystkim takie miary jak:

- maksymalna różnica (ang. *maximum difference*), zwana też szczytowym błędem bezwzględnym PAE (ang. *peak absolute error*):

$$MD = \max_{m,n} \{|f(m, n) - \tilde{f}(m, n)|\} \quad (4.1)$$

- błąd średniokwadratowy (ang. *mean square error*):

$$MSE = \frac{1}{M \cdot N} \sum_{m,n} [f(m, n) - \tilde{f}(m, n)]^2 \quad (4.2)$$

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

$$PSNR = 10 \log \frac{M \cdot N \cdot [\max_{m,n} \{f(m, n)\}]^2}{\sum_{m,n} [f(m, n) - \tilde{f}(m, n)]^2} \quad (4.3)$$

przy czym wartość $\max_{m,n} \{f(m, n)\}$ jest zwykle ustalana na poziomie największej możliwej (a nie faktycznej) wartości funkcji jasności, np. 255 dla danych 8-bitowych;

- średnia różnica (ang. *average difference*):

$$AD = \frac{1}{M \cdot N} \sum_{m,n} |f(m, n) - \tilde{f}(m, n)| \quad (4.4)$$

Miary definiowane przez równania 4.1-4.4 odnoszą się do obrazów monochromatycznych. W przypadku obrazów kolorowych wartość miary zniekształcenia podaje się często jedynie dla składowej luminancji. Można także wyznaczyć wartości zniekształceń dla wszystkich składowych przestrzeni kolorów lub też określić miarę jako euklidesowa odległość w tej przestrzeni.

4.1.2 Ocena wiarygodności diagnostycznej obrazów

Wiarygodność diagnostyczna obrazu jest związana ze zdolnością obserwatora tegoż obrazu do detekcji symptomów patologicznych, a także wyciągania odpowiednich wniosków o charakterze diagnostycznym, a nawet terapeutycznym. Celem metod wspomagania diagnostyki obrazowej jest zwiększenie wiarygodności diagnostycznej obrazów. W przypadku stosowania nieodwracalnych (selektywnych) metod kompresji (w archiwizacji, teliagnostyce) opinie lekarzy specjalistów są niekiedy sceptyczne, głównie ze względu na dużą odpowiedzialność i ryzyko obniżenia jakości obrazów, a więc pogorszenia warunków diagnozy. Stąd też szczególnie istotne jest opracowanie takich miar wiarygodności diagnostycznej obrazów, które pozwolą określić rzetelne kryteria ocen metod selekcji i uwydatniania informacji diagnostycznej w obrazach.

Istotnym sposobem oceny wiarygodności jest wykorzystanie statystycznych miar symulacyjnych (SMS) w testach detekcji zmian, pozwalających kompleksowo ocenić jakość obrazu w kategoriach diagnostycznych, z uwzględnieniem warunków pracy oraz sposobu interpretacji informacji obrazowej w konkretnej aplikacji.

Charakterystycznymi cechami metod SMS w ocenie wiarygodności diagnostycznej są przede wszystkim:

- duża złożoność i czasochłonność,
- wykorzystanie subiektywnych opinii lekarzy specjalistów w danej dziedzinie, przy jednoczesnym dążeniu do maksymalnej obiektywizacji ocen,
- dokonywanie subiektywnych ocen wartości diagnostycznej obrazów w warunkach zbliżonych do codziennej praktyki lekarskiej.

Techniki SMS zostały oparte na możliwie realnej symulacji rzeczywistych warunków pracy z obrazami, na którą składają się odpowiednio zaprojektowane testy oceny subiektywnej przeprowadzane w maksymalnie rzeczywistych warunkach pracy klinicznej. Analiza wyników tychże testów sprowadza się zwykle do weryfikacji hipotez statystycznych mających związek z wiarygodnością danych grup obrazów. Miary symulacyjne oparte są

na założeniu, że obok istotnych elementów składających się na jakość obrazu (kontrast, rozdzielczość, stosunek sygnału użytecznego do szumów, poziom artefaktów, zniekształcenia przestrzenne), w odbiorze obrazu istotne są także warunki obserwacji, w których odbywa się interpretacja informacji w nim zawartej. Percepcja określonych obiektów, struktur lub innych cech obrazu silnie zależy od warunków pracy obserwatora. Chodzi tu z jednej strony o sposób prezentacji obrazu w danym systemie (jakość karty graficznej, monitora itp.), z drugiej zaś o warunki zewnętrzne, w których pracuje specjalista (oświetlenie pomieszczenia, czynniki powodujące zmęczenie, ergonomia pracy itp.). Sposób prezentacji obrazów powinien odpowiadać ich jakości oraz przeznaczeniu.

Schemat odbioru informacji obrazowej winien być uzupełniony o charakterystykę pracy specjalisty. Naśladując postępowanie standardowego obserwatora, nie sposób uwzględnić wszystkich czynników mających wpływ na jego pracę (podejmowanie decyzji diagnostycznych). Stosowane są więc uproszczone metody, oparte na subiektywnej zdolności obserwatora do wskazania określonych zależności, prawidłowego opisu informacji czy detekcji pewnych cech istotnych dla danej aplikacji na podstawie analizowanych obrazów. Najpopularniejszą obecnie taką metodą jest szeroko wykorzystywana w medycynie procedura wyznaczania krzywych ROC (ang. *Receiver Operating Characteristic*), która wywodzi się z teorii detekcji sygnału. Eksperci obserwujący odpowiednio przygotowane obrazy dokonują ich oceny, która dotyczy detekcji pewnych cech czy lokalnych własności obrazu noszących znamiona patologii. Wyniki ich binarnych decyzji (jest lub nie ma patologii), dokonanych na zbiorze obrazów testowanych (dla wiarygodnej statystyki koniecznych jest przynajmniej sto takich decyzji) nanoszone są w postaci punktów w układzie współrzędnych ROC, przy czym każdy punkt reprezentuje estymację prawdopodobieństwa prawdziwej i fałszywej decyzji kolejnego specjalisty, czyli skuteczność jego pracy.

Prostym, aczkolwiek mniej wiarygodnym sposobem oceny jakości diagnostycznej obrazów są metody subiektywne wykorzystujące skale ocen.

Ocena subiektywna

Ponieważ ostatecznym interpretatorem czy analitykiem obrazów są najczęściej specjaliści danej dziedziny lub też "popularni" użytkownicy, sposób oceny jakości oparty w zasadniczej części na opiniach odbiorców obserwujących testowane zbiory danych wydaje się rozwiązaniem naturalnym. To specjaliści wykorzystujący rozpatrywane zbiory danych wiedzą najlepiej, co decyduje o jakości obrazu, jakie cechy obrazu są brane pod uwagę przy jego analizie i to oni potrafią najlepiej sformułować kryteria przydatności

obrazów, a następnie według nich przeprowadzić proces oceny ich jakości. Jednak każda ludzka opinia zagrożona jest pewnym subiektywizmem, możliwością pomyłki, brakiem stałości kryteriów i powtarzalności ocen np., toteż kluczowym zadaniem przy opracowaniu miar obserwacyjnych jest (paradoksalnie) minimalizacja czynnika subiektywnego (wynikającego z samej natury tych metod) związanego z decyzjami poszczególnych osób. Chodzi o zobiektywizowanie ocen, czyli wyłonienie "obiektywnej prawdy" o jakości przetwarzania ze zbioru pojedynczych ocen subiektywnych, obarczonych mniejszym lub większym błędem.

W testach oceny subiektywnej biorą udział przeważnie dwie grupy obserwatorów: eksperci z danej dziedziny wykorzystywania obrazów lub ludzie zupełnie przypadkowi. Do testu można też zaprosić grupę specjalistów od analizy i przetwarzania obrazów, znających sposoby oceny jakości obrazów według różnych koncepcji, ogólne zasady percepcji czy odbioru informacji obrazowej.

Subiektywna ocena jakości przetworzonych obrazów może być przeprowadzana na wiele sposobów. Istnieją dwa zasadnicze rodzaje miar subiektywnych:

- miary absolutne (bezwzględne): obserwatorzy, stosownie do jakości danego obrazu, umieszczają go w odpowiedniej kategorii według przyjętej skali ocen, przy czym sama ocena zupełnie abstrahuje od jakości innych obrazów,
- miary porównawcze (względne): obserwatorzy ustalają wzajemną relację jakości obrazów z danej grupy, a następnie klasyfikują je według hierarchii jakości na podstawie równoczesnej obserwacji w pewnym porządku oraz porównań własności poszczególnych obrazów tej grupy.

Stosowana dla miar absolutnych skala ocen winna zawierać skalę liczbową i skojarzony z nią opis słowny, który trafnie wyrazi różne kategorie możliwych ocen obrazów danego typu (w zależności od aplikacji). W odpowiednio przygotowanych warunkach zbiór obrazów jest prezentowany obserwatorom, którzy oceniają je w powyższej skali. Na podstawie ocen cząstkowych poszczególnych osób biorących udział w teście obliczana jest zazwyczaj średnia ocena grupy obserwatorów według zależności:

$$S = \sum_{k=1}^K (s_k \cdot n_k) / \sum_{k=1}^K n_k \quad (4.5)$$

gdzie K - liczba kategorii w przyjętej skali ocen, s_k - wartość oceny związanej z kategorią k , n_k - liczba ocen z danej kategorii. Przykładowe skale

ocen, które mogą być wykorzystane w różnego typu testach subiektywnych, zarówno absolutnych jak i porównawczych, pokazana rys. 4.1.

a)

Kategoria: k	Wartość skali ocen: s_k	Opis słowny charakteryzujący jakość obrazów
1	5.0	Wyśmienita
2	4.0	Dobra
3	3.0	Średnia
4	2.0	Słaba
5	1.0	Zła

b)

Kategoria: k	Wartość skali ocen: s_k	Opis słowny charakteryzujący jakość obrazów
1	3.0	Zdecydowanie (bezwzględnie) lepsza
2	2.0	Wyraźnie lepsza
3	1.0	Nieznacznie lepsza
4	0.0	Porównywalna z oryginałem
5	-1.0	Nieznacznie gorsza
6	-2.0	Wyraźnie gorsza
7	-3.0	Zdecydowanie (bezwzględnie) gorsza

c)


Kategoria: k	Wartość skali ocen: s_k	Opis słowny charakteryzujący wiarygodność diagnostyczną obrazów
1	0.0	Brak symptomów patologicznych
2	1.0	
3	2.0	
4	3.0	Nieznacznie zarysowana zmiana, przypuszczalnie patologiczna
5	4.0	
6	5.0	
7	6.0	Rozróżnialne cechy patologiczne struktura
8	7.0	
9	8.0	
10	9.0	Wyraźne cechy o charakterze patologicznym
11	10.0	
		Niewątpliwa zmiana patologiczna w obrazie

Rys. 4.1: Przykładowe skale ocen jakości obrazów stosowane w psychowizualnych testach miar subiektywnych: a) absolutnych, b) porównawczych, c) przystosowanych do konkretnej aplikacji medycznej.

4.2 Proces interpretacji obrazów medycznych

Proces ten prześledzimy na przykładzie badań mammograficznych. Rak piersi jest zdecydowanym liderem wśród złośliwych przypadków zachorowań u kobiet w Polsce (rys. 4.2) i na całym świecie. Wszelkie metody poprawy efektywności wczesnej diagnozy mają tutaj olbrzymie znaczenie. Dobrze zorganizowane mammograficzne badania przesiewowe są skutecznym narzędziem w tej walce [106].

Duża zawodność, zmienność interpretacyjna diagnostyki przesiewowej badań mammograficznych (mmg), potwierdzona w licznych badaniach [107],




Rys. 4.2: Problem skutecznej diagnostyki raka piersi okazuje się bardzo istotny.

jest powodem intensywnych prac nad modyfikacją tej techniki obrazowania, wspomaganie komputerowym lub też poprawą protokołu badań, próbą standaryzacji ocen, protokołów itp. Wśród głównych przyczyn ograniczonej skuteczności interpretacji mammogramów wymienić należy m.in.:

- brak jednoznacznego standardu dla określenia prawidłowego sutka (brak normy),
- złożona, silnie zróżnicowana struktura tkanki sutka (rys. 4.3),
- duże różnice w wyglądzie tkanki normalnej,
- często delikatna, subtelna charakterystyka patologii,
- znaczący, niekontrolowany wpływ uwarunkowań technicznych mammografii,
- dominująca rola oceny względnej (porównawczej),
- fizyczne ograniczenia mammografii rentgenowskiej wspieranej przez inne metody obrazowania piersi (przede wszystkim USG i MRI),
- konieczność drugiej oceny (kontr-oceny),

- wymaganie dużych umiejętności w interpretacji i ocenie diagnostycznej (doświadczenie, wiedza i predyspozycje radiologów).



Rys. 4.3: Przykład zróżnicowania cech struktur obrazowanych w badaniach mammograficznych.


Dla powodzenia procesu diagnostyczno - terapeutycznego jasna i jednoznaczna komunikacja pomiędzy wszystkimi specjalistami uczestniczącymi na różnych etapach konsultacji, badań, leczenia, kontroli itp. jest szczególnie istotna.

Można wyróżnić kilka typowych elementów procesu interpretacji mammogramów.

4.2.1 Wstępna ocena jakości i treści diagnostycznej

Na początku dostępne są zwykle (np. z RIS) takie dane: dane pacjenta, wskazania do badania, opinia pacjenta (wywiad), historia badań, ewentualnie choroby (możliwie bogaty rekord pacjenta). Radiolog działa według zasady (w uproszczeniu): detekcja, opis, diagnoza, a systemy CAD często konstruowane są tak, by naśladować tę procedurę.

Specjalista radiolog ocenia wstępnie jakość badań, dokonuje ogólnej charakterystyki obrazów sutka w obu projekcjach (rys. 4.4), utkania, symetrii, wyszukuje zmiany i regiony o zwiększonej podatności na patologie. Następnie następuje dokładniejsza analiza symetrii sutków oraz porównanie z wcześniejszymi badaniami (jeśli są dostępne).




Rys. 4.4: Wstępna ocena cech obrazów, m.in. symetrii sutka w projekcjach CC i MLO przykładowych badań.

4.2.2 Analiza wybranych cech lokalnych

Kolejnym etapem jest bardziej szczegółowa analiza cech lokalnych w wybranych regionach, wykorzystanie narzędzi wizualizacji badań, powiększenie obrazu, poprawa kontrastu, dodatkowa filtracja, korekcja histogramu itp.

4.2.3 Analiza zmiany

Jeśli wykryto zmianę, następuje jej dokładna analiza według schematu:



Rys. 4.5: Analiza cech lokalnych, poprawa wizualizacji badań mammograficznych.

- Łagodna
- Złośliwa
 - Lokalizacja w 2 projekcjach
 - Porównanie badaniami wcześniejszymi
- Podejrzenie patologii
 - Lokalizacja w 2 projekcjach
 - Porównanie badaniami wcześniejszymi, przeszukanie historii badań
 - Intensyfikacja analizy
 - Dodatkowe badania

Etap ten kończy się opisem diagnostycznym zawierającym możliwie trafną, zweryfikowaną charakterystykę wykrytych zmian.

4.2.4 Drugie spojrzenie

W przypadkach trudniejszych, a niekiedy zawsze zależnie od uregulowań prawnych, korzysta się niezależnej z oceny drugiego specjalisty np. w formie

tele-konsultacji lub tele-diagnozy. Można także skorzystać z narzędzi CAD jako dodatkowej weryfikacji sposobu interpretacji.

4.2.5 Ocena, raport

Lekarz odpowiedzialny sporządza końcową ocenę w formie raportu zawierającego mniej lub bardziej sformalizowany, pełny opis zaobserwowanych cech obrazowanego narządu i wykrytych zmian, ewentualnie sugestii do dalszego postępowania.

W raporcie znajduje się zwykle:

- Uzasadnienie wykonania badania
- Ocena kompozycji tkanki sutka (tłuszczowa, tłuszczowa z ogniskami tkanki gruczołowej, o zróżnicowanej gęstości, skrajnie gęsta)
- Ustandaryzowany 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

Często sporządzane opisy są niepełne, trudne to porównać czy też niejednoznaczne w interpretacji. Oto kilka przykładów.

Przykład 1. *Sutki o gęstym nieregularnym utkaniu gruczołowym. Zmian ogniskowych podejrzanych o złośliwość nie stwierdzam. Kontrolna mammografia za rok. USG za 6 mcy.*

Przykład 2. *Sutki o resztkowej budowie gruczołowej. Sutek lewy- drobny guzek w kwadrancie górnozewnętrznym, 10 mm, radiologicznie łagodny. Sutek prawy- w pobliżu brodawki widoczny guzek 5 mm ze skorupkowatymi zwapnieniami. Radiologicznie może odpowiadać brodawczakowi, martwicy tłuszczowej, włókniako-gruczolakowi.*

Przykład 3. *Sutki z przewagą utkania tłuszczowego, w sutku prawym widoczne kleksowate zwapnienie, najprawdopodobniej zwapniały gruczolakowłókniak. Sutek lewy bez zmian ogniskowych. Obraz nie uległ zasadniczej zmianie w por. z badaniem poprzednim, węzły pachowe niepodejrzane. Do kontroli mammograficznej za 12 m-cy.*

Przykład 3. *Stan po lewostronnej mastektomii. Sutek prawy- na granicy dolnych kwadrantów 18mm guzowate zagęszczenie z mikrozwapnieniami o złośliwym charakterze. Węzły chłonne pachowe niepowiększone.*

W przypadku podejrzenia zmiany złośliwej (oceny 4-5) wykonywane jest badanie diagnostyczne, zaś w przypadku podejrzenia zmiany złośliwej po badaniu diagnostycznym zaleca zwykle kontynuację badań, krótkoczasową kontynuację badań lub biopsję.

4.3 Metody weryfikacji systemów komputerowego wspomaganie diagnozy radiologicznej

Celem każdego systemu służącego do wspomaganie decyzji jest zapewnienie możliwie najlepszej trafności podejmowanych decyzji. Omówione w poprzednim rozdziale metody obiektywnej oceny jakości obrazów abstrahowały od kontekstu diagnostycznego.

Zgodnie z rozważaniami przedstawionymi w punkcie 1.4 rozpoznawanie choroby jest elementem decyzji klinicznych podejmowanych przez lekarza. Dlatego każda decyzja diagnostyczna jest decyzją subiektywną. Zapewnienie wysokiej obiektywnej jakości obrazu medycznego może wpływać na wysoką dokładność diagnozy radiologicznej. Należy jednak pamiętać, że

Tabela 4.1: Rozkład prawdopodobieństw symboli (przybliżony metodą częstościową) oraz podprzedziały linii prawdopodobieństw dla przykładu ??

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


zależności między wskaźnikami obiektywnymi obrazu a wartościami diagnostycznymi najczęściej są nieliniowe. Stąd, nie jest uprawnione pozorne stwierdzenie, że każda poprawa wskaźników jakości opisanych w rozdziale 4.1.1 prowadzi do poprawy dokładności diagnostycznej. Z tego względu każdy system przetwarzania obrazów medycznych i wspomagania decyzji diagnostycznej musi zostać poddany ocenie przydatności klinicznej.

4.3.1 Parametry służące ocenie dokładności diagnostycznej


Każda decyzja diagnostyczna jest podejmowana na podstawie modelu diagnostycznego danej choroby. Model ten może być modelem kognitywnym wykreowanym *implicite* w umyśle klinicysty, może być wyrażony w postaci reguł decyzyjnych stosowanych do obrazów medycznych lub może być zrealizowany w postaci komputerowego systemu wspomagania diagnozy. Pomimo, że na podstawie modelu decyzyjnego lekarz podejmuje decyzję dotyczącą konkretnego pacjenta, dany model diagnostyczny będzie użyteczny wtedy tylko, gdy będzie umożliwiał rozpoznanie właściwej choroby u wszystkich (prawie wszystkich) pacjentów z daną jednostką chorobą. Zakładając, że obraz nozologiczny danej choroby jest „podobny” u prawie wszystkich osób, na podstawie wykazanej użyteczności klinicznej modelu dla określonej populacji pacjentów, można wnioskować o przydatności tego modelu dla konkretnego pacjenta. Powyższa zasada uzasadnia wykorzystanie modeli statystycznych do oceny wiarygodności diagnostycznej obrazu. Relacje między diagnozą konkretnego pacjenta a wynikami oceny wiarygodności statystycznej przedstawia rys. 4.6.

Z uwagi na istniejące u ludzi różnice międzyosobnicze, obrazy medyczne dotyczące wybranej patologii cechuje wyraźna zmienność. Źródła zmienności, przy założeniu stosowania tego samego modelu diagnostycznego przedstawiono na rys. 4.7.

Rozważmy na początek najprostszą sytuację diagnostyczną. Na podstawie obecności cechy patologicznej w obrazie radiologicznym należy określić czy dana patologia jest obecna u pacjenta. Niech $D = \{0, 1\}$ oznacza zmienną opisującą decyzję diagnostyczną odpowiadającą stanowi zdrowia i choroby. Zmienna $C = \{0, 1\}$ będzie oznaczać rzeczywisty stan pacjenta (zdrowy versus chory). Model diagnostyczny będzie miał użyteczny klinicznie wtedy tylko, gdy przy jego pomocy lekarz będzie mógł z dostatecznie dużym prawdopodobieństwem rozpoznać lub wykluczyć istnienie patologii. Dlatego najczęściej do oceny jakości diagnostycznej modelu stosuje się dwa parametry: swoistość oraz czułość, definiowane jako: $Sp = P(D = 0 | C = 0)$ oraz $Se = P(D = 1 | C = 1)$. Swoistość oznacza prawdopodobieństwo niewykrycia patologii u osoby zdrowej, zaś czułość opisuje prawdopodobieństwo wy-



Rys. 4.6: Relacja między statystyczną oceną wiarygodności diagnostycznej modelu a diagnozą wybranego pacjenta



Rys. 4.7: Źródła zmienności medycznych obrazów diagnostycznych

Tabela 4.2: Rozkład liczebności obrazów w testach oceniających dokładność diagnostyczną.

Choroba	Decyzja	
	$D=0$	$D=1$
$C=0$	n_{11}	n_{12}
$C=1$	n_{21}	n_{22}

krycia patologii u osoby zdrowej. Oszacowanie tych wielkości dokonuje się na podstawie testów klinicznych, których schemat przedstawia rys. 4.6.

Założmy, że diagnozę dokonuje jeden radiolog na podstawie N zdjęć radiologicznych wykonanych w tej samej fazie rozwoju choroby. Zastosowanie powyższego modelu do detekcji patologii prowadzi do rozkładu liczebności obrazu jak w tab. 4.2).

Wówczas otrzymuje się następujące estymatory swoistości i czułości

$$\begin{aligned}\widehat{Se} &= \frac{n_{22}}{n_{21}+n_{22}} \\ \widehat{Sp} &= \frac{n_{11}}{n_{11}+n_{12}}\end{aligned}\quad (4.6)$$

Wariancja tych estymatorów wyraża się następującymi wzorami:

$$\text{var}(\widehat{Se}) = \frac{Se(1-Se)}{n_{21} + n_{22}}, \quad \text{var}(\widehat{Sp}) = \frac{Sp(1-Sp)}{n_{11} + n_{12}} \quad (4.7)$$

Oszacowanie wartości specyficzności i czułości dla danego modelu diagnostycznego pozwala na ocenę dokładności diagnostycznej w przy zadanej patologii i lekarzu radiologu. Powtórzenie tego szacowania dla innej patologii lub innego radiologa może dać inne wyniki.

Opisane parametry oceny efektywności diagnozy zakładały, że wynik badania jest dychotomiczny. W badaniach radiologicznym kryterium diagnostycznym może być również wartość wybranego parametru obrazu, np. objętości obrazowanego narządu. Wówczas otrzymuje się wartości swoistości i czułości dla poszczególnych wartości parametru decyzyjnego $d_1, \dots, d_k$, tzn.

$Se(d_1), \dots, Se(d_k), Sp(d_1), \dots, Sp(d_k)$, gdzie $Se(d_i) = P(d \geq d_i | C = 1)$ dla $i = 1, \dots, k$.

Wygodną formą prezentacji otrzymanego zbioru parametrów jest krzywa ROC (ang. *receiver operating characteristic*). Jest krzywa powstała przez aproksymację funkcją ciągłą zbioru punktów $[Se(d_i), 1 - Sp(d_i)]$ dla $i = 1, \dots, k$. Tradycyjną metodą aproksymacji jest metoda najmniejszych kwadratów. Jeżeli liczebność próby obrazów jest dostatecznie duża (w praktyce > 50), można uznać, że wartości zmiennych decyzyjnych d^0 dla pacjentów zdrowych) i d^1 dla pacjentów chorych mają rozkłady normalne, tzn. $d^{0,1} \sim \mathcal{N}(\mu_{0,1}, \sigma_{0,1})$. Wówczas krzywą ROC możemy aproksymować następująco;

$$[1 - \Phi(d), 1 - \Phi(\hat{b}d - \hat{a})] \quad -\infty < d < \infty \quad (4.8)$$


gdzie Φ jest dystrybucją rozkładu normalnego i $\hat{b} = \hat{\sigma}_o / \hat{\sigma}_1$, $\hat{a} = (\hat{\mu}_1 - \hat{\mu}_o) / \hat{\sigma}_1$. Przykładową krzywą ROC prezentuje rys. 4.8.

Krzywa ROC pozwala wyznaczyć miarę określającą globalną właściwość testu, uwzględniając jego czułość i specyficzność. Miarą tą jest pole powierzchni pod krzywą ROC, czyli:

$$A = \int_{-\infty}^{\infty} Se(d) d[(1 - Sp(d))] \quad (4.9)$$

Stosując aproksymację (4.8) można w łatwy sposób znaleźć aproksymator pola powierzchni pod krzywą ROC, gdyż jest on dany wzorem;

$$\hat{A} = \Phi\left(\frac{\hat{a}}{\sqrt{1 + \hat{b}^2}}\right), \quad (4.10)$$



Rys. 4.8: Przykładowa krzywa ROC z punktami odpowiadającymi wartościami $d_1, \dots, d_k$

Zaś jego wariacja wynosi $\text{var}(\hat{A}) = \hat{\beta}^2 \text{var}(\hat{a}) + \hat{\gamma}^2 \text{var}(\hat{b}) + 2\hat{\beta}\hat{\gamma} \text{cov}(\hat{a}, \hat{b})$, gdzie

$$\hat{\beta} = \frac{\exp[-\hat{a}^2/2(1+\hat{b}^2)]}{\sqrt{2\pi(1+\hat{b}^2)}}, \quad \hat{\gamma} = -\frac{\hat{a}\hat{b} \exp[-\hat{a}^2/2(1+\hat{b}^2)]}{\sqrt{2\pi(1+\hat{b}^2)}^3}. \quad (4.11)$$

oraz

$$\begin{aligned} \text{var}(a) &= \frac{(a^2+2)+2b^2}{2N}, \quad \text{var}(b) = \frac{b^3}{N} \\ \text{cov}(a, b) &= \frac{ab}{2N} \end{aligned} \quad (4.12)$$

Wartość pola pod krzywą ROC jest również często stosowanym parametrem oceniającym jakość diagnostyczną modelu decyzyjnego.

Omówione dotychczas parametry oceny wiarygodności modeli diagnostycznych szacowały „globalne” parametry. Estymacja ich wartości pozwala obiektywnie ocenić jakość diagnostyczną, natomiast uniemożliwia ocenę poszczególnych cech jakościowych obrazu w kontekście podejmowania decyzji diagnostycznych. Dłaczego drugim sposobem oceny badania wiarygodności diagnostycznej obrazu jest zastosowanie skali umożliwiającej subiektywną ocenę radiologa. Skala jest najczęściej trójstopniowa (np. dobrze, nie wiem,

źle) i przypisana jest poszczególnym cechom diagnostycznym obrazu medycznego. Może dotyczyć oceny uwidocznienia w obrazie ważnych klinicznie rejonów zainteresowania. Standaryzacja ocen przez wprowadzenie kwestionariusza oceny jakości obrazu pozwala ujednolicić odpowiedzi udzielane przez radiologów. Współcześnie te dwie metody oceny wiarygodności diagnostycznej są stosowane komplementarnie.

4.3.2 Metody porównywania wiarygodności modeli diagnostycznych

Oszacowanie wybranych parametrów dostarcza informacji ilościowej o wartości klinicznej danej metody przetwarzania obrazu lub systemu wspomagającego decyzje diagnostyczne. Jednak bez odniesienia tych wartości do pewnych wartości referencyjnych, stają się one mało użyteczne. Trudno bowiem ocenić czy otrzymana wartość pola pod ROC jest maksymalnie duża, czy może nasz system zmniejszył „czytelność medyczną” obrazu dla radiologa. Dlatego metodologia weryfikacji diagnostycznej wiarygodności składa się zawsze z dwóch etapów: estymacji subiektywnych i obiektywnych parametrów jakości oraz ich porównanie z wartościami referencyjnymi. Wartości referencyjne są otrzymywane przez zastosowanie tzw. *złotego standardu diagnostycznego*, przez który rozumie się takie badanie, które zapewnia maksymalną wartość specyficzności i czułości. Dla bań radiologicznych złotym standardem zazwyczaj stanowią śródoperacyjne badania makroskopowe bądź histopatologiczne potwierdzające ostateczne rozpoznanie kliniczne.

Wartościami odniesienia mogą pochodzić też z badań radiologicznych tej samej modalności, ale przed i po wykonanej transformacji na obrazie. Obraz $f(x, y)$ pełni wtedy rolę „złotego standardu”, zaś obraz $\hat{f}(x, y) = \mathcal{T}[f(x, y)]$ jest obrazem testowanym. Z uwagi na stosowanie podejścia statystycznego do estymacji parametrów jakości diagnostycznej, nie jest możliwe bezpośrednio porównywanie wartości referencyjnych i badanych. Staje się konieczne zastosowanie testów statystycznych, pozwalających na ekstrapolację porównań na całą populację pacjentów. Najczęściej porównywanym parametrem jest pole powierzchni pod ROC, gdyż wyraża „uśrednioną” jakość danego modelu diagnostycznego.

Niech A_T, A_G oznacza odpowiednio pole pod krzywą otrzymane dla badanego modelu (obrazu) diagnostycznego i otrzymane po zastosowaniu złotego standardu diagnostycznego. Celem badania jest wykazanie, że pole $A_T > A_G$. Załóżmy, że liczebność próby obrazów jest dostatecznie duża, pozwalając na założenie rozkładu normalnego wartości pól pod krzywą ROC.

Wówczas testowane hipotezy statystyczne przyjmują postać

$$\mathcal{H}_0 : A_T = A_G \quad (4.13)$$

przy hipotezie alternatywnej

$$\mathcal{H}_1 : A_T > A_G \quad (4.14)$$

Ponieważ zarówno model diagnostyczny, jaki i złoty standard stosowany jest zawsze na tej samej grupie pacjentów, konieczne trzeba stosować test statystyczny dla prób powiązanych. Postać statystyki testowej jest następująca:

$$Z = \frac{A_T - A_G}{\mathcal{S}_E[A_T - A_G]} \quad (4.15)$$

gdzie $\mathcal{S}_E[A_T - A_G] = \sqrt{\frac{1}{N}\text{var}(A_T) + \frac{1}{N}\text{var}(A_G) + 2\frac{1}{N^2}\text{cov}(A_T, A_G)}$ jest błędem standardowym różnicy pól pod krzywą ROC. N oznacza liczebność próby obrazów, zaś $\text{cov}(A_T, A_G)$ jest dana wzorem przedstawionym w [110].

Pod warunkiem prawdziwości hipotezy $\mathcal{H}_0$ ma rozkład normalny standaryzowany. Należy jednak uwzględnić poziom istotności wynosi $\frac{\alpha}{2}$, gdyż test jest jednostronny.

Przedstawiony sposób pozwala określić czy dwa modele diagnostyczne dają takie same (w sensie statystycznym) wyniki dokładności diagnostycznej. Jeżeli nie ma podstaw do odrzucenia hipotezy zerowej, wiarygodność diagnostyczna obu modeli jest równoważna.

Podobną metodologię porównania jakości diagnostycznej można zastosować do subiektywnych ocen wiarygodności diagnostycznej. W tym celu można zastosować test McNemmara przedstawiony w [111]. Inną, prostszą metodą jest zastosowanie współczynnika zgodności ocen jakościowych κ .

Tabela 4.3: Rozkład częstości pacjentów przy określaniu płci metodą badania somatycznego i chromosomalnego

	Złoty standard		
Model badany	Cecha 1	Cecha 2	Suma
Cecha 1	p_{11}	p_{12}	$P_{1\cdot}$
Cecha 2	p_{21}	p_{22}	$P_{2\cdot}$
Suma	$P_{\cdot 1}$	$P_{\cdot 2}$	1

Symbole $p_{11}, p_{12}, p_{21}, p_{22}$ oznaczają odsetki pacjentów (prawdopodobieństwa) w poszczególnych podgrupach obrazów. Dla powyższej tabeli możemy

zdefiniować *współczynnik zgodności kappa* wyrażający się wzorem

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (4.16)$$

gdzie $P_o = p_{11} + p_{22}$, zaś $P_e = P_{.1}P_{1.} + P_{.2}P_{2.}$. Im wartość κ jest bliższa jedności, tym bardziej dwie metody pomiaru dają zgodne wyniki.

Dotychczasowe metody porównywanie modeli diagnostycznych zakładały, że decyzje są podejmowane przez jednego radiologa. W przypadku wprowadzenia dwóch radiologów, należy skorzystać z dwu czynnikowej analizy wariancji, opisaną np. w [112].

4.3.3 Metodologia klinicznych ocen modeli diagnostycznych

Największym wyzwaniem klinicznej walidacji modeli diagnostycznych jest opracowanie procedury weryfikacyjnych badań klinicznych. Etap ten poprzedzają badania z wykorzystaniem matematycznych lub fizycznych fantomów obrazowanych struktur anatomicznych. Opracowanie procedury badań klinicznych składa się z następujących etapów:

1. Określenie celu badania: zdefiniowanie diagnozowanej patologii, określenie przeznaczenia modelu diagnostycznego, fazy badania klinicznego i szacowanych parametrów
2. Określenie złotego standardu lub referencyjnego modelu diagnostycznego
3. Określenie populacji pacjentów, dla których będzie stosowany model diagnostycznych
4. Określenie sposobu pobierania i wielkości próby (randomizacja, reprezentatywność)
5. Określenie czynników zakłócających (ang. *confounders*), które mogą obciążać szacowane parametry dokładności statystycznej
6. Określenie populacji radiologów oceniających zdjęcia, uwzględniając czynniki wpływające na zdolność percepcji obrazu
7. Wybór radiologa uczestniczących w badaniu klinicznym
8. Określenie modelu statystycznego realizowanego badania
9. Estymacja parametrów oceniających wiarygodność diagnostyczną

10. Oszacowanie wyników porównań wiarygodności diagnostycznych

Podczas określenia celu badania należy pamiętać o ścisłym zdefiniowaniu diagnozowanej patologii, przy czym najczęściej pożądana jest definicja nozologiczna (poprzez zbiór poszukiwanych cech jakościowych i ilościowych obrazu). Określenie tych cech wymaga wielogodzinnych dyskusji z doświadczonymi klinicystami. Mogą one także wynikać z etiopatogenezy danego schorzenia.

Problemy z określeniem złotego standardu zostały już zasygnalizowane. Podstawą do jego wyboru jest rzetelna analiza literatury medycznej, czasem wsparta metaanalizą opublikowanych danych. W przypadku braku możliwości znalezienia, lub wykonania badania będącego złotym standardem, należy wybrać to badanie, którego wiarygodność diagnostyczna jest zbliżona do dokładności złotego standardu.

Bardzo ważnym elementem planowania weryfikacji klinicznej jest wybór populacji, dla której jest opracowywany dany model diagnostyczny. Przykładowo, inne wymagania zostaną narzucone dla modelu diagnostycznego stosowanego do badań przesiewowych, inne zaś do diagnozy różnicowej chorych pacjentów. W pierwszym przypadku będziemy mieć do czynienia z populacją ogólną (ang. *community based population*), w drugim, z populacją szpitalną (ang. *hospital based population*). Określenie badanej populacji także determinuje sposób pobierania próby. Jeżeli opracowywany model diagnostyczny będzie stosowany do badań celowanych (ang. *guided clinical studies*), wówczas można ograniczyć reprezentatywność pobieranej próby (np. określić przedział wiekowy).

Istotnym elementem procedury badania klinicznego jest wybranie zbioru czynników, które mogą obciążać estymowaną dokładność statystyczną. Typowymi, potencjalnymi czynnikami zakłócającymi mogą być: płeć pacjenta, wiek pacjenta, stan zaawansowania choroby, płeć i wiek oceniającego radiologa. Jeżeli wiadomo z modelu epidemiologicznego choroby, że jej czynnikiem ryzyka jest płeć (np. żeńska), to przypadkowa różnica w rozkładzie płci u badanych osób zdrowych i chorych będzie wpływać na szacowaną dokładność detekcji patologii. Uwzględnienie w badaniu klinicznym wszystkich potencjalnych czynników zakłócających wymaga dobrej znajomości etiologii rozpoznawanej choroby. Wiadomo także z psychologii poznawczej, że istnieją różnice w zdolnościach percepcyjnych między płciami, co może wpływać na jakość decyzji diagnostycznych dokonywanych przez różnych radiologów.

Znajomość czynników zakłócających proces diagnostycznych pozwala na eliminację ich negatywnego wpływu na etapie pobierania próby (tzw. metoda parowania) bądź na etapie analizy statystycznej (metoda korekcji,

standaryzacji) [113].

Pozostałe elementy procedury weryfikacji klinicznej modelu diagnostycznego zostały dokładnie omówione.

W każdej weryfikacji klinicznej, można wyróżnić trzy fazy badań klinicznych, które zostały przedstawione w tab. 4.4.

Tabela 4.4: Fazy badań klinicznych modeli diagnostycznych

Faza	Liczebność próby N	Grupy pacjentów	
Ocena wstępna	10-50	Chorzy, z typowym obrazem patologicznym	Zdrowi ochotnicy
Retrospektywne badania kliniczne	10-100	Chorzy z typowym i atypowym obrazem patologicznym	Zdrowi ze współistniejącymi chorobami
Prospektywne badania kliniczne	> 100	Reprezentatywna próba dla badanej populacji	

Faza pierwsza koncentruje się na określeniu zdolności dyskryminacyjnych modelu diagnostycznego. Jeżeli model diagnostyczny jest zależny od pewnych parametrów, faza pierwsza badań klinicznych może służyć także ocenie, które z tych parametrów mają decydujący wpływ na dokładność decyzyjną modelu. Jeżeli $\mathbf{X}$ będzie wektorem parametrów modelu, identyfikację istotnych parametrów można przeprowadzić przy wykorzystaniu wielowymiarowej regresji logistycznej o postaci:

$$P(C = 1|\mathbf{X}) = \frac{\exp(\alpha + \beta\mathbf{X})}{1 + \exp(\alpha + \beta\mathbf{X})}, \quad (4.17)$$

gdzie α, β są wektorami parametrów regresji logicznej, estymowane metodą największej wiarygodności [1]. Model (4.17) pozwala na identyfikację, które parametry modelu decyzyjnego (obrazu radiologicznego) są związane z występowaniem danej patologii u pacjenta.. Dokonując zamiany $P(C = 1|\mathbf{X})$ na $P(D = 1|\mathbf{X})$ można otrzymać model do identyfikacji parametrów związanych z detekcją patologii. W ogólności modele te nie muszą być tożsame.

Uzyskane wyniki badań fazy wstępnej pozwalają zoptymalizować model diagnostyczny. Faza druga badania musi już uwzględniać wszystkie kroki procedury weryfikacji klinicznej. W tej fazie nie powinno się dokonywać

żadnych modyfikacji modelu diagnostycznego wykraczającej poza kliniczne warunki pracy. Uzyskanie pozytywnej walidacji modelu w fazie drugiej upoważnia do implementacji modelu do standardowej praktyki klinicznej. Zebrane dane z prospektywnej oceny dokładności diagnostycznej, a więc dane z pracy modelu w „bojowych” warunkach klinicznych pozwala na najbardziej rzetelną i miarodajną ocenę systemu wspomagającego diagnostykę. Pozytywna weryfikacja prospektywna systemu pozwala na ubieganie się o włączenie zbudowanego modelu diagnostycznego w standard rozpoznania radiologicznego danej patologii

Rozdział 5

Metody opisu obrazów

5.1 Obraz: kontury, tekstury, tło

5.2 Metody modelowania obrazów

Metody modelowania obrazów można podzielić na cztery zasadnicze kategorie:

- geometryczne (proste elementy a priori),
- obiektowe (bardziej złożone elementy a posteriori),
- probabilistyczne (statystyczne),
- funkcjonalne (tj. wykorzystujące predykcję lub dekompozycję na bazie atomów czas-częstotliwość).

”Dobry” model powinien się wyróżniać takimi cechami jak:

- specyficzność (uwzględnia semantykę)
- wiarygodny opis szumów i artefaktów
- wielorozdzielczość (różne skale)
- hierarchiczność (uwzględnia różnego typu relacje)
- niestacjonarność (lokalność i adaptacyjność)
- elastyczność (łatwa zmiana parametrów)

Zasadniczym celem przybliżenia (aproksymacji) obrazu tworzonym na różny sposób modelem jest możliwie oszczędne, małoparametryczne opisanie istotnej treści diagnostycznej obrazu w celu identyfikacji zasadniczych cech obrazu w kategoriach diagnostycznych: obecności zmian, oceny ich właściwości, ogólnej charakterystyki obrazowanego narządu itp.

5.3 Model procesu akwizycji mammogramu jako przykład modelowania obrazu medycznego

5.3.1 Podstawy

Modelowanie obrazu jest procesem mającym na celu stworzenie reprezentacji danych obrazowych umożliwiających efektywniejszą ich analizę pod jakimś kątem. W przypadku obrazów medycznych zazwyczaj zależy nam na takiej poprawie właściwości obrazu aby miał on większą wartość diagnostyczną dla lekarza, toteż proces modelowania powinien prowadzić do tego celu.

Sama metodologia procesu modelowania jest silnie uzależniona od chociażby modalności. W niniejszym opracowaniu skupimy się na przykładzie obrazów mammograficznych oraz pracach zespołu Uniwersytetu Oksfordzkiego oraz własnych.

Koncepcja proponowanej reprezentacji mammogramu polega na przekształceniu reprezentacji pikselowej, w której dla każdego punktu w obrazie mamy zależny od wielu czynników poziom jasności, na taką w której dla każdego punktu obrazu mamy grubość odpowiadającą mu tkanki "interesującej" (nietłuszczowej). W podejściu tym zakładamy, że z punktu widzenia współczynnika osłabienia promieniowania X, możliwe jest podzielenie tkanki piersi na dwie grupy. Do pierwszej z nich zaliczamy tkankę tłuszczową, do drugiej - tkankę gruczołową, włóknistą, nowotworową, a także np. krew i skórę [75].

Dzięki temu, jeśli grubość tkanki interesującej w danym punkcie oznaczmy przez h_{int} , grubość tkanki tłuszczowej przez h_{fat} a całkowitą grubość piersi przez H , wówczas mamy

$$h_{int} + h_{fat} = H$$

Przyjmując za znane i jednakowe dla całej piersi H , możemy dla każdego punktu (piksela obrazu) wyznaczyć odpowiadającą mu wartość h_{int} . Doświadczenia literaturowe wskazują, że taka reprezentacja może być niezwykle użyteczną, efektywną podstawą do różnorodnych zagadnień związanych z cyfrową analizą obrazu mammograficznego [76].

W celu uzyskania znormalizowanej reprezentacji konieczne jest opracowanie modelu procesu powstawania obrazu mammograficznego. Proces wyznaczania h_{int} można w największym skrócie przedstawić w następujących krokach:

1. Konwersja poziomu jasności $P(x,y)$ do gęstości optycznej (*ang. film density*) $D(x,y)$
2. Konwersja gęstości optycznej $D(x,y)$ do energii dostarczonej do okładek wzmacniających E_{pse}^{imp}
3. Opcjonalna kompensacja E_{pse}^{imp} względem efektu rozmycia spowodowanego rozproszeniem fotonów wyemitowanych z okładek wzmacniających
4. Opcjonalna kompensacja E_{pse}^{imp} względem efektu utwardzania anody (*ang. anode heel-effect*) oraz dywergencji wiązki fotonów X
5. Estymacja promieniowania rozproszonego E_s^{imp}
6. Opcjonalna estymacja promieniowania pozaogniskowego
7. Wyznaczenie promieniowania podstawowego

$$E_p^{imp}(x,y) = E^{imp}(x,y) - E_s^{imp}(x,y) - E_e^{imp}(x,y)$$

gdzie $E^{imp}(x,y)$ jest całkowitą energią zawartą w obrazie, $E_s^{imp}(x,y)$ jest energią rozproszenia, a $E_e^{imp}(x,y)$ jest opcjonalnym czynnikiem energii promieniowania pozaogniskowego.

8. $E_p^{imp}(x,y)$ jest energią podstawową. Znając teoretyczną zależność na tą energię w zależności od $h_{int}(x,y)$ możemy, porównując obie wielkości, wyznaczyć wartość $h_{int}(x,y)$

$$E_p^{imp}(x,y) = \phi(V_t, x, y) A_p t_s \int_0^{\varepsilon_{max}} N_0^{rel}(V_t, \varepsilon) \varepsilon S(\varepsilon) G(\varepsilon) e^{-\mu_{luc}(\varepsilon) h_{plate}} e^{-h\mu(\varepsilon)} d\varepsilon \quad (5.1)$$

gdzie $S(\varepsilon)$ jest współczynnikiem absorpcji okładek wzmacniających, $G(\varepsilon)$ jest współczynnikiem transmisji okładek wzmacniających, $N_0^{rel}(V_t, \varepsilon)$ jest liczbą cząstek X o energii ε w stosunku do całkowitej liczby cząstek w oddziałującym spektrum [78], $\mu_{luc}(\varepsilon)$ jest względnym współczynnikiem osłabienia okładek wzmacniających, h_{plate} grubością tych okładek, natomiast

czynnik $\phi(V_t, x, y)A_p t_s$ jest ilością emitowanych z lampy cząstek promieniowania dla danego napięcia oraz prądu oraz:

$$h\mu(\varepsilon) = h_{int}(\mu_{int}(\varepsilon) - \mu_{fat}(\varepsilon)) + H\mu_{fat}(\varepsilon) \quad (5.2)$$

Za wyjątkiem h_{int} wszystkie wielkości w (5.1) i (5.2) są znane, co pozwala na rozwiązanie równania.

5.3.2 Kompensacja rozmycia okładek wzmacniających

Gdy foton X jest absorbowany w okładkach wzmacniających, fotony światła są praktycznie izotropowo emitowane we wszystkich kierunkach, co powoduje efekt rozmycia na obrazie (blure). W celu zredukowania tego efektu zaproponowano pewien model rozmycia okładek wzmacniających [74]. Zakładamy w nim, że fotony X są absorbowane równo na każdej części okładek wzmacniających. Dla danego piksela, znając jego rozmiar, możemy wyznaczyć kąty pomiędzy punktami absorpcji a sąsiednimi pikselami. Te kąty definiują proporcje fotonów, które absorbują okoliczne piksele. Kąty te są ważone odległościami od punktu absorpcji do piksela.


Do kompensacji rozmycia ekranu wzmacniającego wyznaczono funkcję rozmycia ekranu wzmacniającego. W tym celu zakładamy, że ekran podzielony jest na warstwy, a każda warstwa jest dalej podzielona na kawałki o rozmiarze poniżej piksela. Każdy z tych kawałków jest traktowany jako potencjalny punkt absorpcji cząstki promieniowania X. Teraz niech tp będzie grubością okładek wzmacniających. Rozpatrujemy okładkę podzieloną na n warstw, a więc każda będzie miała grubość tp/n . Warstwa jest podzielona na piksele (niezależnie od użytej rozdzielczości), a każdy piksel jest podzielony na 100 mniejszych części. Zakładamy przy tym, że klisza leży dokładnie na okładkach wzmacniających.

Dla każdej warstwy wyznaczamy teraz macierz wag $wz(x, y)$ (funkcja rozmycia dla tej warstwy), co daje procent fotonów światła wyemitowanych z punktu (xc, yc) na głębokości z , które docierają do kliszy w punkcie (x, y) . Stosunek fotonów z (xc, yc, z) dochodzących do (x, y) jest związany z kątem θ od (xc, yc) do (x, y) . Zakładamy symetrię wokół kąta azymutalnego i rozpatrujemy przypadek 1-wymiarowy. W tej sytuacji niektóre z fotonów światła emitowane z (xc, yc, z) są absorbowane przez fosfor, a więc wagę kąta θ możemy przedstawić korzystając z prawa Beera.

$$r = d\theta e^{-\mu_{lp}z/\cos(\theta)} \quad (5.3)$$

gdzie μ_{lp} jest średnim liniowym współczynnikiem osłabienia. Zbierając wartości dla każdej warstwy i każdego pod-piksela otrzymujemy maskę w . Ma-


ska definiuje funkcję rozmycia okładek wzmacniających, więc energia dostarczona do okładek wzmacniających jest splotem energii bez rozmycia na okładkach i maski. Osiągnięty wynik przykładowej kompensacji efektu rozmycia okładek wzmacniających zaprezentowano na rysunkach 5.1 i 5.2.



Rys. 5.1: Oryginalny obraz energii.

5.3.3 Estymacja promieniowania rozproszonego

Kluczowym zagadnieniem dla wyznaczenia h_{int} jest estymacja promieniowania rozproszonego. Właśnie rozproszenie jest czynnikiem najbardziej degradującym obraz mammograficzny. Promieniowanie rozproszone jest źródłem energii nie niosącej informacji o tkance piersi w danym pikselu, lecz, co potwierdza wiele publikacji, niesie pewną informację o jego najbliższym



Rys. 5.2: Obraz ze skompensowanym wpływem rozmycia okładek wzmacniających.

otoczeniu [79][80][81]. Wyznaczenie promieniowania rozproszonego można przedstawić w następujących krokach:

1. Stworzenie maski rozproszenia
 - (a) Wyznaczenie względnego rozproszenia docierającego do określonego punktu i pochodzącego z cylindra o grubości dr w odległości r bez zastosowania siatki przeciwrozproseniowej dla piersi o grubości H
 - (b) Podzielenie cylindra na cienkie plastry i wyznaczenie względnego rozproszenia dla każdego plastra.


- (c) Wykorzystanie wiedzy o współczynniku transmisji dla siatki przeciwwrozproszeniowej i wyznaczenie względnego rozproszenia po przejściu przez siatkę
 - (d) Zsumowanie rozproszenia dla każdego punktu po wysokości cylindra co umożliwia skonstruowanie maski w gdzie wartość w każdym punkcie jest wprost proporcjonalna do ilości promieniowania rozproszonego pochodzącego z tkanki leżącej "nad" danym punktem maski docierającego do rozpatrywanego piksela.
2. Wyznaczenie funkcji rozproszenia s która umożliwia przejście z sumy splotu energii E_{pse}^{imp} i maski w do składowej rozproszenia E_s^{imp}
 3. Splot energii E_{pse}^{imp} (czyli informacji, którą wprost reprezentuje obraz mammograficzny) z maską w a następnie zastosowanie funkcji rozproszenia s do wyznaczenia składowej rozproszonej E_s^{imp} .

Z przeprowadzonych badań, jak i z literatury [76] wynika, że funkcja rozproszenia nie zależy od założonego rozkładu tkanki pomiędzy tkankę "interesującą" i tłuszczową. Jest to niezwykle istotne z kilku powodów. Przede wszystkim ewentualna nieliniowość tej funkcji stawiałaby pod znakiem zapytania poprawność proponowanego modelu. Funkcja rozproszenia bowiem niesie informację o zależności energii rozproszenia od struktury tkanki. Jeśli teraz byłaby ona nieliniowa, wówczas musielibyśmy tak naprawdę znać ten rozkład dla każdego piksela i móc korygować wartość splotu w każdym punkcie. Dzięki jej liniowości możemy ją pominąć, jako że wymnożenie splotu przez czynnik liniowy jest zbędne. Niejako przy okazji liniowość funkcji rozproszenia zmniejsza znacznie złożoność numeryczną zagadnienia. W celu przyspieszenia obliczeń zaimplementowano, w miejsce standardowej funkcji splatającej, dwuwymiarowy splot z wykorzystaniem szybkiej transformaty Fouriera. Przyspieszyło to wyznaczanie splotu o rząd wielkości, niestety kosztem większego zapotrzebowania na pamięć.


Do przeprowadzenia prawidłowej estymacji potrzebny jest też obraz gruczołu piersiowego z możliwie dokładnie zaznaczonym kształtem (do obliczeń bierzemy tylko piksele należące do samego gruczołu). Do segmentacji wykorzystany został algorytm pochodzący z pakietu oprogramowania udostępnianego przez bazę DDSM, zaadaptowany do pracy w środowisku Windows. Przykładowy wynik segmentacji pokazany jest na rysunku 5.3.

Jako weryfikację poprawności osiągniętych wyników może posłużyć otrzymana zależność rozkładu promieniowania rozproszonego od odległości z siatką przeciwwrozproszeniową - rys. 5.5. Otrzymana zależność znakomicie pokrywa się z podobnymi charakterystykami znanymi z literatury [76]. Koń-


cowy wynik estymacji promieniowania rozproszonego prezentuje rysunek 5.4).



Rys. 5.3: Oryginalny obraz piersi z automatycznie wysegmentowanym gruczołem.



Rys. 5.4: Uzyskany obraz promieniowania rozproszonego.



Rys. 5.5: Procent promieniowania rozproszonego w funkcji odległości z której pochodzi dla piersi o grubości 3 i 6cm. Uzyskane charakterystyki znakomicie pokrywają się z wynikami prezentowanymi w [76]. Poza tym uzyskane obrazy energii promieniowania rozproszonego są zgodne z oczekiwaniami i przykładami znanymi z literatury [80]

Rozdział 6

Analiza obrazów w wielu skalach

Do metod wieloskalowych (inaczej wielorozdzielczych) w szczególności zaliczyć można takie transformacje jak piramidę Laplace’a, falkową (ang. *wavelet*), pakiety falek, a także przetksztalcenia z jądrem 2W (nieseparowalnym) takie jak *contourlets*, *wedgelets*, *ridgelets* i inne.

Zasadniczym celem stosowania metod analizy wielorozdzielczej jest możliwie silna separacja sygnału użytecznego i szumu, przy czym oba te pojęcia rozumie się zwykle w aspekcie semantycznym. Sygnałem jest struktura, zbiór cech, region lub rozkład krawędzi, które mają znacznie diagnostyczne (tj. wpływają na proces interpretacji diagnostycznej obrazu). Szumem więc jest to wszystko co się nie liczy, nie ma najmniejszego znaczenia w diagnozie.

6.1 Metody falkowe

Falkowe metody przetwarzania obrazów wykorzystują przekształcenie danych obrazowych w nową dziedzinę wielu skal, podpasm częstotliwościowych oraz przestrzennego rozkładu danych obrazowych (zachowuje informację o położeniu). Wykorzystywana analiza wielorozdzielcza umożliwia dobrą charakterystykę sygnałów niestacjonarnych, w tym obrazów. Każdy ze współczynników opisuje jedynie lokalne właściwości obrazu. O tym jak lokalne decyduje rozmiar nośnika funkcji bazowej, czyli skojarzonego filtru służącego dekompozycji. Uzyskuje się to poprzez stosowanie funkcji bazowych przekształcenia o skończonym (dokładniej zwartym) nośniku.

Realizowana w transformacji falkowej wielorozdzielcza dekompozycja obrazu pozwala upakować, niejako ”skoncentrować”, energię sygnału w

niewielkiej liczbie współczynników falkowych oraz uwypuklić cechy obrazu (takie jak rozkład konturów i krawędzi, własności tekstur i charakterystyka szumów), co daje większe możliwości analizy i klasyfikacji, selekcji informacji diagnostycznej czy poprawy jakości obrazów. Ważnym elementem takiej dekompozycji jest wybór podstawowej funkcji skalującej oraz falki matki (inaczej falki podstawowej), które określają właściwości bazy transformacji falkowej. Winny one uwzględniać cechy przetwarzanego obrazu, możliwie silnie upodabniając właściwości bazy do lokalnych trendów zmienności sygnału.


6.1.1 Falkowa dekompozycja obrazów

Dekompozycję falkową składającą się z etapu analizy (przekształcenie w zbiór podpasm podczas kodowania) i syntezy (odtworzenie oryginału podczas dekodowania) obrazu przedstawiono na rys. 6.1. Można ją realizować na wiele sposobów poprzez dobór banku filtrów analizy $\tilde{h}, \tilde{g}$ i syntezy h, g (dolno- i górnoprzepustowych) stosowanych do przekształceń w obu kierunkach przestrzeni obrazu. Wykorzystywane są także inne sposoby podziału na podpasma (np. równomierny, 'spacel', 'packet' lub 'fbi' ze standardu kompresji JPEG2000, adaptacyjny z pakietami falek itp.) [69].

Ze względu na niestacjonarny charakter modelu źródła informacji, dużą różnorodność cech różnego typu obrazów, różny poziom jakości przetwarzanych obrazów (stosunek sygnału do szumu, przestrzenna rozdzielczość, częstotliwościowe widmo sygnału itp.) brakuje skutecznych (tj. niezawodnych według przyjętego kryterium optymalności) metod doboru banków filtrów falkowych zależnie od zastosowania (przede wszystkim definicji sygnału, czyli informacji użytecznej diagnostycznie, oraz szumu).


Uzyskana struktura podpasm w postaci hierarchicznego drzewa dekompozycji Mallata została przedstawiona na rys. 6.2. Cztery podpasma składowych o najniższych częstotliwościach stanowią najwyższy poziom tego drzewa. Dane należące do tego poziomu nie mają rodzica i są rodzicami pierwszej generacji dla wszystkich skojarzonych przestrzennie współczynników. Każdy współczynnik, na poziomie różnym od podstawy drzewa, rozrasta się w grupę czterech współczynników kolejnego poziomu dokładniejszej skali, będąc z nimi w relacji rodzic-dzieci.

Pierwsze w hierarchii podpasmo najniższych częstotliwości LL_3 zawiera najwięcej informacji o obrazie (średnio na pojedynczy współczynnik). Potem występują kolejne podpasma największej skali: HL_3 , LH_3 oraz HH_3 , gdzie L oznacza podpasmo po filtracji dolnoprzepustowej, a H - górnoprzepustowej (najpierw po wierszach, potem po kolumnach - zgodnie z rys. 6.1). Zależności pomiędzy współczynnikami tych podpasm określa horyzontalna



Rys. 6.1: Falkowa analiza oraz synteza obrazu w algorytmach przetwarzania obrazów.

relacja drzewa dekompozycji, wyrażająca podobieństwa treści częstotliwościowych kolejnych podpasem tej samej skali w danym miejscu przestrzeni.



Rys. 6.2: Podstawowy schemat falkowej dekompozycji obrazu.

Następnie w hierarchii są trzy podpasma drugiego poziomu drzewa: HL_2 , LH_2 , HH_2 , których współczynniki pozostają w relacji rodzic-dzieci w stosunku do współczynników odpowiednich podpasem zarówno bardziej zgrubnej, jak i dokładniejszej skali. Na najniższym poziomie drzewa znajdują się trzy podpasma najdokładniejszej skali z indeksem 1, które nie mają węzłów potomnych.


6.1.2 Dwukanałowy schemat analizy i syntezy

Metoda filtracji sygnału wejściowego w celu redukcji nadmiarowości nie może być zrealizowana w schemacie jednokanałowym (za pomocą jednego filtru do analizy i jednego filtru do syntezy). Niemożliwy do spełnienia jest warunek doskonałej rekonstrukcji). Konieczna jest budowa co najmniej dwukanałowego modelu dekompozycji-rekonstrukcji (jak na rys. 6.1) i taka forma znajduje najczęstsze zastosowanie w algorytmach przetwarzania. Nie wyklucza to oczywiście stosowania schematów wielokanałowych, aczkolwiek ze względu na bardziej złożony proces konstrukcji takich banków filtrów, przy braku znaczącej poprawy efektywności w stosunku do banków dwukanałowych, rozwiązania takie należą do rzadkości.

Proces filtracji może być realizowany jako splot w dziedzinie oryginalnej, bądź też jako iloczyn w dziedzinie częstotliwościowej z wykorzy-

staniem dyskretnej transformacji Fouriera. Można także charakteryzować przekształcenia w dziedzinie transformacji z ($h(z) = \sum_{n=-\infty}^{+\infty} h_n z^{-n}$, gdzie $z = e^{i\omega}$, $n \in \mathbb{Z}$), często stosowanej do opisu filtrów cyfrowych.

Schemat dwukanałowej dekompozycji sygnału X przedstawiono na rys. 6.3. Po filtracji $\tilde{h}$ i $\tilde{g}$ uzyskuje się dwukrotne większą liczbę próbek, co jest niekorzystne w niektórych zastosowaniach (m.in. kompresji). Występuje też możliwość zniekształceń nakładania widm (ang. *aliasing*), tj. wzmocnienia pewnych fragmentów sygnału poprzez nałożenie się pasm z obu kanałów (dolno- i górnoprzepustowego), powodowana niemożnością realizacji filtrów o idealnie pasmowych charakterystykach. Rozwiązaniem tych obu problemów jest decymacja $\downarrow 2$ ciągu próbek a i c , czyli wybieranie co drugiej próbki (długość każdego ciągu zmniejsza się o połowę z dokładnością do jednej próbki ze względu na przypadek nieparzystej liczby próbek wejściowych).



Rys. 6.3: Schemat dwukanałowej analizy (z lewej) i syntezy (z prawej) sygnału X za pomocą banku filtrów dolno- i górnoprzepustowych. W ramach analizy, po filtracji dolnoprzepustowej $\tilde{h}$ i decymacji $\downarrow 2$ sygnału X (próbki $a_{0,n}$), uzyskujemy współczynniki skalujące a , a po filtracji górnoprzepustowej $\tilde{g}$ i decymacji - współczynniki falkowe c . Proces odwrotny, czyli synteza, po uzupełnieniu zerami współczynników skalujących i falkowych (ekspander $\uparrow 2$) oraz odpowiedniej filtracji (g i h) i sumowaniu pozwala uzyskać zrekonstruowany sygnał Y wierny sygnałowi wejściowemu pod warunkiem, że użyte filtry spełniają warunek doskonałej rekonstrukcji.

Bank filtrów dwukanałowego schematu analizy i syntezy z rys. 6.3 spełnia warunek doskonałej rekonstrukcji $X = Y$, czyli wiernego (dokładnego) odtworzenia sygnału oryginalnego:

$$h(z)\tilde{h}(z^{-1}) + g(z)\tilde{g}(z^{-1}) = 2 \quad (6.1a)$$


$$h(z)\tilde{h}(-z^{-1}) + g(z)\tilde{g}(-z^{-1}) = 0 \quad (6.1b)$$

Z warunków tych wynika konieczność odwrócenia współczynników filtrów analizy w celu kompensacji opóźnień w poszczególnych filtrach.


Analizując bardziej szczegółowo proces przetwarzania sygnału dla przykładowego filtra dolnoprzepustowego analizy $\tilde{h}$ widać, że najpierw realizowana jest filtracja np. metodą splotu w dziedzinie obrazu (sygnał splatany jest z odpowiedzią impulsową filtra).

Na rys. 6.4a) przedstawiono implementację filtracji dolnoprzepustowej $\tilde{h}$, gdzie decymator eliminuje co drugą próbkę, tworząc ciąg próbek przefiltrowanego sygnału X o dwukrotnie mniejszej liczbie. Przyjmijmy, że mamy parzystą liczbę próbek sygnału (co nie wpływa na ogólność rozważań) i usuwane są próbki o indeksach nieparzystych, co daje na wyjściu parzyste próbki a_e .

a)



b)



Rys. 6.4: Implementacja filtracji z decymacją: a) klasyczna; b) zmodyfikowana, z rozdzieleniem próbek sygnału wejściowego na parzyste i nieparzyste (założono parzyste n).

Aby zmniejszyć złożoność obliczeniową takiej procedury wystarczy ograniczyć filtrację jedynie do próbek parzystych (tj. z indeksem parzystym), co daje sposób filtracji jak na rys. 6.4b). Prześledźmy równania opisujące filtrację za pomocą $\tilde{h}$:

$$\begin{aligned}
 & \vdots \\
 a_0 &= \tilde{h}_0 x_0 + \tilde{h}_1 x_{-1} z^{-1} + \tilde{h}_2 x_{-2} z^{-2} + \dots \\
 a_1 &= \tilde{h}_0 x_1 + \tilde{h}_1 x_0 z^{-1} + \tilde{h}_2 x_{-1} z^{-2} + \dots \\
 a_2 &= \tilde{h}_0 x_2 + \tilde{h}_1 x_1 z^{-1} + \tilde{h}_2 x_0 z^{-2} + \dots \\
 & \vdots
 \end{aligned} \tag{6.2}$$

Usuując nieparzyste próbki podczas decymacji, uzyskujemy jedynie wyrażenia, w których parzyste współczynniki filtra $\tilde{h}_e$ są mnożone przez parzyste próbki sygnału x_e , a nieparzyste współczynniki filtra $\tilde{h}_o$ - przez nieparzyste

próbki x_o . Po filtracji i decymacji otrzymujemy próbki:

$$a_e(z) = \tilde{h}_e(z)x_e(z) + \tilde{h}_o(z)x_o(z)z^{-1} \quad (6.3)$$

gdzie z^{-1} wynika z opóźnienia o jedną próbkę zbioru kolejnych próbek nieparzystych w stosunku do ich parzystych poprzedników.

Analogiczny opis filtracji i decymacji próbek za pomocą górnoprzepustowego filtru analizy prowadzi do następującego równania macierzowego:

$$\begin{bmatrix} a(z) \\ c(z) \end{bmatrix} = \begin{bmatrix} \tilde{h}_e(z) & \tilde{h}_o(z) \\ \tilde{g}_e(z) & \tilde{g}_o(z) \end{bmatrix} \begin{bmatrix} x_e(z) \\ x_o(z)z^{-1} \end{bmatrix} = \tilde{\mathbf{P}}(z) \begin{bmatrix} x_e(z) \\ x_o(z)z^{-1} \end{bmatrix} \quad (6.4)$$

gdzie $\tilde{\mathbf{P}}(z)$ jest macierzą polifazową¹, charakteryzującą dany zestaw filtrów transformacji falkowej. W skrajnym przypadku jednostkowej $\tilde{\mathbf{P}}(z)$ mamy do czynienia jedynie z rozdziałem na dwa zbiory próbek parzystych i nieparzystych, przy czym próbki parzyste stanowią współczynniki niskoczęstotliwościowe, a nieparzyste - wysokoczęstotliwościowe.

W procesie syntezy zagadnienie filtracji wygląda podobnie. Wprowadzenie przez ekspander zer na pozycję co drugiej próbki przed filtracją powoduje niepotrzebny wzrost kosztu obliczeniowego ze względu na konieczność wielokrotnych mnożeń przez zero. Uproszczenia analogiczne jak w analizie prowadzą do następującej postaci rekonstruowanych próbek za pomocą filtru syntezy h (przyjęto nieparzyste indeksy wprowadzanych przez ekspander próbek):

$$y_e(z) = h_e(z)a_e(z) \quad (6.5a)$$

$$y_o(z) = h_o(z)a_e(z)z^{-1} \quad (6.5b)$$

Drugie równanie lepiej jest zapisać w postaci $zy_o(z) = h_o(z)a_e(z)$ ze względu na łączenie po filtracji dwóch sekwencji próbek, przy czym próbki nieparzyste są o jeden opóźnione w stosunku do parzystych.

Macierzowa postać syntezy, analogicznie do (6.4), po uwzględnieniu górnoprzepustowej filtracji syntezy g współczynników falkowych i ich zsumowaniu z próbkami po filtracji h , odpowiednio dla parzystych i nieparzystych y , przedstawia się jak niżej:

$$\begin{bmatrix} y_e(z) \\ zy_o(z) \end{bmatrix} = \mathbf{P}(z) \begin{bmatrix} a_e(z) \\ c_e(z) \end{bmatrix} \quad (6.6)$$

¹Nazwa ang. *polyphase* używana jest w filtracji cyfrowej do opisu techniki rozdziału sekwencji próbek na kilka podzbiorów (fragmentów sygnału przesuniętych w fazie) w celu równoległego ich przetwarzania.

gdzie polifazowa macierz syntezy, zwana dualną, wygląda następująco:

$$\mathbf{P}(z) = \begin{bmatrix} h_e(z) & g_e(z) \\ h_o(z) & g_o(z) \end{bmatrix} \quad (6.7)$$

Dualna macierz polifazowa $\mathbf{P}(z)$ jest transponowaną macierzą pierwotną $\tilde{\mathbf{P}}(z)$ z pominięciem tyldy.

Warunek doskonałej rekonstrukcji można wobec tego napisać jako:

$$\tilde{\mathbf{P}}(z^{-1})\mathbf{P}(z) = \mathbf{I} \quad (6.8)$$

Uwzględnia on wprowadzane w wyniku filtracji opóźnienie. Jeśli założymy odwracalność macierzy $\mathbf{P}(z)$, to:

$$\tilde{\mathbf{P}}(z^{-1}) = \mathbf{P}(z)^{-1} = \frac{1}{h_e(z)g_o(z) - h_o(z)g_e(z)} \begin{bmatrix} g_o(z) & -g_e(z) \\ -h_o(z) & h_e(z) \end{bmatrix} \quad (6.9)$$

Jeżeli wyznacznik macierzy $\mathbf{P}(z)$ jest równy 1, wtedy nie tylko $\mathbf{P}(z)$ będzie odwracalna, ale również bezpośrednio można określić następujące zależności pomiędzy filtrami:

$$\begin{aligned} \tilde{h}_e(z) &= g_o(z^{-1}) \\ \tilde{h}_o(z) &= -g_e(z^{-1}) \\ \tilde{g}_e(z) &= -h_o(z^{-1}) \\ \tilde{g}_o(z) &= h_e(z^{-1}) \end{aligned} \quad (6.10)$$

co po przekształceniu daje następujący warunek na filtry analizy i syntezy:

$$\begin{aligned} \tilde{h}(z) &= -z^{-1}g(-z^{-1}) \\ \tilde{g}(z) &= z^{-1}h(-z^{-1}) \end{aligned} \quad (6.11)$$

Jeśli macierz polifazowa $\mathbf{P}(z)$ ma wyznacznik 1, wtedy para filtrów (h, g) nazywana jest komplementarną. Para filtrów $(\tilde{h}, \tilde{g})$ jest wówczas także komplementarna.

6.1.3 Realizacje za pomocą liftingu

Transformacja zbudowana na schemacie liftingu zawiera iteracyjnie powtarzane kroki predykcji i dookreślenia, które modyfikują próbki nieparzyste wykorzystując liniowy model predykcji z kilku sąsiednich próbek parzystych, a następnie uaktualniają wartości próbek parzystych, aby zachować wartość średnią oryginalnego zbioru próbek. Rezultaty każdego kroku predykcji i dookreślenia są zaokrąglane do najbliższej liczby całkowitej.

Schemat *liftingu* (LS, ang. *lifting scheme*) [70, 71] jest metodą realizacji transformacji falkowej z wykorzystaniem projektowanych baz biortogonalnych falek o skończonym nośniku. Realizacja LS jest szybsza od klasycznej metody splotu i pozwala na zmniejszenie wymagań pamięciowych przy realizacji algorytmu transformacji poprzez implementację „w miejscu”, bez konieczności alokacji dodatkowej pamięci. Schemat LS zapewnia odwracalność transformacji falkowej oraz posiada wystarczająco dużo stopni swobody, aby konstruować przekształcenie zgodnie z przyjętymi założeniami (wymagana regularność, liczba momentów, kształt widma częstotliwościowego falek, lokalizacja w dziedzinie czasu). LS jest używany do konstrukcji transformacji całkowitoliczbowych poprzez zaokrąglanie wyników filtracji w każdym kroku algorytmu (tj. iteracyjnie powtarzanej predykcji i dookreśleniu), przed korektą wyznaczanych wartości próbek odpowiednio nieparzystych i parzystych. LS umożliwia także realizację adaptacyjnej transformacji falkowej. Początkowa postać transformacji może być modyfikowana w kolejnych krokach liftingu jedynie w wybranych obszarach zainteresowań, w zależności od przyjętego kryterium i lokalnych własności sygnału. LS jest więc wygodnym narzędziem do optymalizacji baz falkowych wykorzystywanych w falkowych algorytmach przetwarzania obrazów.

Schemat liftingu rozpoczyna się od etapu rozdzielania (zwanego czasem transformacją leniwej falki - ang. *lazy wavelet*) zbioru próbek na dwa podzbiory: próbek parzystych i nieparzystych, tj. $a_n^{(0)} \doteq x_{2n}$ i $c_n^{(0)} \doteq x_{2n+1}$, w celu sformułowania początkowej postaci podpasm dolno- i górnoczęstotliwościowego sygnału wejściowego x . Następnie są one modyfikowane w kolejnych (według indeksu k) krokach LS, realizujących transformację prostą zgodnie z zależnością:

$$c_n^{(k)} = c_n^{(k-1)} + \sum_i \tilde{\mathbf{p}}_i^{(k)} a_{n-i}^{(k-1)} \quad (6.12a)$$

$$a_n^{(k)} = a_n^{(k-1)} + \sum_i \tilde{\mathbf{u}}_i^{(k)} c_{n-i}^{(k)} \quad (6.12b)$$

lub całkowitoliczbowo:

$$c_n^{(k)} = c_n^{(k-1)} + \left\lfloor \sum_i \tilde{\mathbf{p}}_i^{(k)} a_{n-i}^{(k-1)} + \frac{1}{2} \right\rfloor \quad (6.12c)$$

$$a_n^{(k)} = a_n^{(k-1)} + \left\lfloor \sum_i \tilde{\mathbf{u}}_i^{(k)} c_{n-i}^{(k)} + \frac{1}{2} \right\rfloor \quad (6.12d)$$

gdzie współczynniki filtrów predykcji $\tilde{\mathbf{p}}^{(k)}$ i dookreślenia (ang. *update*) $\tilde{\mathbf{u}}^{(k)}$ są obliczane poprzez faktoryzację macierzy polifazowej $\tilde{\mathbf{P}}(z)$ dowolnego banku filtrów doskonałej rekonstrukcji. Faktoryzacja jest procesem odwrot-

nym do liftingu, tj. zastąpieniem nawet bardzo złożonych banków filtrów, definiowanych najczęściej z wykorzystaniem zestawu współczynników odpowiedzi impulsowej, szeregiem prostych filtrów określających kolejne kroki liftingu [72].

Dla pary filtrów komplementarnych $(\tilde{h}, \tilde{g})$ zawsze można wydzielić pewną liczbę kroków liftingu, dochodząc ostatecznie w procesie faktoryzacji macierzy polifazowej $\tilde{\mathbf{P}}(z)$ tej pary filtrów do postaci macierzy jednostkowej lub też macierzy diagonalnej z dwoma niezerowymi wartościami stałymi na przekątnej macierzy. $\tilde{\mathbf{P}}(z)$ może być więc rozłożona na czynniki w sposób następujący:

$$\tilde{\mathbf{P}}(z) = \begin{bmatrix} K_1 & 0 \\ 0 & K_2 \end{bmatrix} \prod_{i=1}^m \left\{ \begin{bmatrix} 1 & \tilde{u}_i(z) \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ \tilde{\mathbf{p}}_i(z) & 1 \end{bmatrix} \right\} \quad (6.13)$$

gdzie: K_1 i K_2 są to różne od zera stałe skalujące, a m - liczba kroków (etapów) schematu liftingu.

Zasadnicze problemy związane z faktoryzacją to:


- faktoryzacja na kroki liftingu jest dalece niejednoznaczna; nie wiadomo dokładnie jak wiele zasadniczo różnych faktoryzacji jest możliwych, jak bardzo się one różnią i w jaki sposób wybrać tę najlepszą;
- nie ma pewności, że filtry ze współczynnikami w notacji binarnej można zastąpić w wyniku faktoryzacji etapami liftingu z filtrami o współczynnikach tejże notacji; mogą bowiem pojawić się liczby zespolone, funkcje wymierne, ciała skończone itp.

Realizację transformacji falkowej metodą liftingu pokazano na rys. 6.5. Ustalając $\mathbf{p}$ i $\mathbf{u}$ można uzyskać różne postacie transformacji rzeczywistoliczbowych lub ich wersji całkowitoliczbowych, jak w tabeli 6.1.

Powyższe określenia przekształcenia falkowego dotyczą transformacji jednowymiarowych sygnałów. Dwuwymiarową postać transformacji falkowej obrazów można realizować z wykorzystaniem tzw. jądra separowalnego, tj. jądra jednowymiarowego zastosowanego niezależnie do obu wymiarów. Konstruowane są także jądra dwuwymiarowe, uwzględniające charakterystykę obrazów i umożliwiające dokładniejszą analizę obiektów o nieregularnym kształcie (np. mikrozwapnień). Testowana postać przekształcenia wykorzystuje falkowe jądro heksagonalne.

6.2 Transformacja heksagonalna

Transformacja heksagonalna jest przekształceniem z dwuwymiarowym jądrem. Można wyróżnić 7 faz filtracji klasycznych danych dwuwymiarowych



Rys. 6.5: Transformacja falkowa prosta realizowana z wykorzystaniem metody lifting, zawierającej kolejne etapy predykcji P i dookreślenia U. Przy transformacjach całkowitoliczbowych operacje P i U są zaokrąglane do liczby całkowitej. Liczba kroków predykcji i dookreślenia nie musi być równa. Transformacja odwrotna ma postać zbliżoną: te same kroki liftingu wykonywane są w odwrotnej kolejności (od tyłu schematu do przodu), przy czym operacje sumowania są zastąpione odejmowaniem. Z^{-1} oznacza przesunięcie w czasie sygnału o jedną próbkę.


Tabela 6.1: Definicje transformacji metodą lifting, całkowitoliczbowe i rzeczywistoliczbowe (bez widocznych we wzorach zaokrągleń); a , c jak w równaniach (6.12).

Nazwa	Definicja transformacji
5/3	$c_n = c_n^{(0)} + \left\lfloor \frac{1}{2}(-a_n^{(0)} - a_{n+1}^{(0)}) \right\rfloor$ $a_n = a_n^{(0)} + \left\lfloor \frac{1}{4}(c_{n-1} + c_n) + \frac{1}{2} \right\rfloor$
9/7	$c_n = c_n^{(0)} + \left\lfloor \frac{1}{16}(a_{n-1}^{(0)} + a_{n+2}^{(0)} - 9(a_n^{(0)} + a_{n+1}^{(0)})) + \frac{1}{2} \right\rfloor$ $a_n = a_n^{(0)} + \left\lfloor \frac{1}{4}(c_{n-1} + c_n) + \frac{1}{2} \right\rfloor$
17/11	$c_n = c_n^{(0)} + \left\lfloor \frac{1}{256}(-3(a_{n-2}^{(0)} + a_{n+3}^{(0)}) + 25(a_{n-1}^{(0)} + a_{n+2}^{(0)}) - 150(a_n^{(0)} + a_{n+1}^{(0)})) + \frac{1}{2} \right\rfloor$ $a_n = a_n^{(0)} + \left\lfloor \frac{1}{16}(-c_{n-2} - c_{n+1} + 5(c_{n-1} + c_n)) + \frac{1}{2} \right\rfloor$
SPB	$c_n^{(1)} = c_n^{(0)} - a_n^{(0)}; \quad a_n = a_n^{(0)} + \left\lfloor \frac{1}{2}c_n^{(1)} \right\rfloor$ $c_n = c_n^{(1)} + \left\lfloor \frac{1}{8}(2a_{n-1} + a_n - 3a_{n+1} + 2c_{n+1}^{(1)}) + \frac{1}{2} \right\rfloor$
5/11	$c_n^{(1)} = c_n^{(0)} - \left\lfloor \frac{1}{2}(a_n^{(0)} + a_{n+1}^{(0)}) \right\rfloor; \quad a_n = a_n^{(0)} + \left\lfloor \frac{1}{4}(c_{n-1}^{(1)} + c_n^{(1)}) + \frac{1}{2} \right\rfloor$ $c_n = c_n^{(1)} + \left\lfloor \frac{1}{16}(a_{n-1} - a_n - a_{n+1} + a_{n+2}) + \frac{1}{2} \right\rfloor$

(obrazów) przy użyciu transformacji heksagonalnej:

1. transformacja obrazu do postaci heksagonalnej,
2. podział na 4 podpasma,
3. predykcja w trzech podpasmach (ang. prediction),

4. dookreślanie pasma niskoczęstotliwościowego (ang. update),
5. modyfikacja współczynników transformaty,
6. odtworzenie sygnału do postaci heksagonalnej,
7. transformacja z postaci heksagonalnej do obrazu wynikowego.



Rys. 6.6: Schemat liftingu w transformacie heksagonalnej [P krok predykcji (ang. prediction); U krok dookreślania (ang. update)].


Faza 1 i podobnie faza 7 są względem siebie operacjami komplementarnymi. Transformacja obrazu do postaci heksagonalnej może być zrealizowana w taki sposób, że co drugi rząd jest niejako przesuwany o 1 piksel, a nowe piksele są obliczane na podstawie punktów, które znajdowały się w najbliższym sąsiedztwie obliczanego punktu w danej linii (średnia arytmetyczna punktów przed- i za- obliczanym punktem). Faza 7 realizowana jest w podobny sposób w co drugim rzędzie punkty przesuwane są na swoje miejsca i ponownie obliczane na podstawie wartości punktów sąsiednich. Przekształcenie to nie jest oczywiście w 100% odwracalne i powoduje wygładzenie obrazu (filtrację dolnoprzepustową), jednak korzyści płynące z lepszego dopasowania jądra przekształcenia w dalszym procesie filtracji (w stosunku do tradycyjnej transformaty falkowej) rekompensują tę niedogodność. Faza 2 polega na podziale punktów obrazu na 4 grupy, które po fazie predykcji i dookreślania zostaną przekształcone w 4 podpasma (patrz rys. 6.6):

- niskoczęstotliwościowe (a)
- wysokoczęstotliwościowe zorientowane na zmiany występujące w obrazie na osi pochyłonej o kąt 0 stopni (c0)

- wysokoczęstotliwościowe zorientowane na zmiany występujące w obrazie na osi pochylonej o kąt 60 stopni (c60)
- wysokoczęstotliwościowe zorientowane na zmiany występujące w obrazie na osi pochylonej o kąt 120 stopni (c120)

Proces predykcji (faza 3) realizowany jest w taki sposób, że na podstawie wybranych punktów z pasma bazowego przewidywane są odpowiednie punkty pozostałych pasm, a następnie przewidziane wartości są odejmowane od wartości oryginalnych. Filtr predykcji powinien być dobrze dopasowany do charakterystyki istotnych diagnostycznie obiektów w obrazie (np. mikrozwapnień). Przyjmuje się, że znajdując się w centralnym punkcie mikrozwapnienia o charakterystyce zbliżonej do dwuwymiarowej funkcji Gaussa próbujemy przewidzieć ten punkt na podstawie najbliższego sąsiedztwa z pasma bazowego. Mając dobrze dopasowane jądro przekształcenia w wyniku filtracji uzyskamy największe wartości współczynników w obszarach najlepiej dopasowanych do charakterystyki filtru, czyli przyjętego modelu obiektów użytecznych. Daje to informacje w pasmach wysokoczęstotliwościowych o szczegółach i wskazuje na potencjalne miejsca występowania wzorców istotnych diagnostycznie. Dane o szczegółach są następnie użyte do modyfikacji wartości w paśmie niskoczęstotliwościowym (chodzi o zachowanie składowej stałej) w wyniku operacji dookreślenia.


Przykładową realizację transformacji heksagonalnej na etapie kierunkowej predykcji przedstawiono na rys. 6.7. Zastosowano trzy bloki predykccyjne dla poszczególnych kanałów wysokoczęstotliwościowych (c0, c60 i c120). Współczynniki predykcji wynosiły odpowiednio $\frac{1}{2}$, $\frac{1}{8}$ i $-\frac{1}{16}$. W procesie dookreślenia współczynniki równe były $\frac{1}{8}$.



Rys. 6.7: Rozkład współczynników predykcji dla kanałów: c0, c60 i c120.

6.3 Transformacja *contourlet*


Transformacja *contourlet* jest uogólnieniem transformacji falkowej. Rozszerzenie przestrzeni dekompozycji o wymiar kąta analizy dało możliwość pełniejszego opisu obiektów w transformowanym obrazie. W klasycznej dwuwymiarowej transformacji falkowej przestrzeń kątowna analizy obrazu jest ograniczona do trzech kierunków (pionowy, poziomy i ukośny). *Contourlet* pozwala na taką parametryzację transformacji, aby na danym poziomie dekompozycji (w danej skali) rozszerzyć rozdzielczość kątową do 2^n liczby kierunków analizy.




Rys. 6.8: Różnice pomiędzy transformacją falkową a) c) i *contourlet* b) d).

Transformacja *contourlet* zbudowana jest na bazie piramidy Laplacea. Dekompozycja ta polega na podziale sygnału wejściowego (obrazu) na jego składową niskoczęstotliwościową oraz na różnicę pomiędzy sygnałem wejściowym a jego reprezentacją po fazie predykcji z sygnału niskoczęstotliwościowego. W taki sposób powstaje składowa wysokoczęstotliwościowa, która stanowi współczynniki transformacji na danym poziomie dekompozycji.

Opracowano dwuwymiarowe banki filtrów kierunkowych w celu zapewnienia kierunkowych właściwości transformacji. Ideą tego rozwiązania był podział przestrzeni na określoną liczbę części w taki sposób, aby linie podziału znajdowały się w centralnym punkcie i wyznaczały kierunki. Dało to możliwość dyskretyzacji kąta linii podziału i tym samym zaadresowania danego kierunku na płaszczyźnie obrazu.




Rys. 6.9: Piramida Laplace'a



Rys. 6.10: Bank filtrów kierunkowych


Transformacja *contourlet* jest złożeniem analizy wielorozdzielczej przy użyciu piramidy Laplace'a z podziałem na każdym poziomie dekompozycji na poszczególne kierunki analizy z zastosowaniem filtrów kierunkowych. Tego typu złożenie umożliwia zbudowanie dekompozycji wrażliwej na kierunkowe zmiany wartości pikseli w obrazie ze z góry zdefiniowaną rozdzielczością kątową oraz z możliwością analizy obrazu w określonej skali.



Rys. 6.11: Wielorozdzielcza dekompozycja obrazu

Rysunek 6.12 przedstawia przykładowy obraz zdekomponowany do dziesiątych wartości współczynników transformacji *contourlet* - widać, że na

pierwszym poziomie dekompozycji dokonano analizy obrazu dla 2^3 różnych kierunków.



Rys. 6.12: Przykładowy obraz (Barbara) w dziedzinie współczynników transformacji *contourlet*.

Rozdział 7

Metody poprawy percepcji informacji obrazowej

W radiologicznych badaniach obrazowych wykorzystuje się dane różnorodnych modalności: USG, MRI w różnych wersjach (m.in. badania funkcjonalne), CT - w tym badania kontrastowe, radiografii analogowej (klisze) i cyfrowej ze szczególnym uwzględnieniem mammografii rentgenowskiej, tomografii nuklearnych SPECT i PET, scyntygrafii, a ponadto w coraz większym stopniu obrazowania optycznego, terahercowego, prób z tomografią impedancyjną itp.

Odbiorcą jest specjalista radiolog i/lub system CAD, który umożliwia automatyczną lub pół-automatyczną detekcję szukanych patologii. Postrzeganie wzrokowe przez człowieka - polega na rozpoznawaniu różnic w jasności (kolorów) poszczególnych fragmentów obrazu. Zwiększenie różnicy jasności w sąsiednich obszarach skutkuje pewniejszą decyzją. Świadczy to o konieczności zwiększania lokalnego kontrastu w obszarach szczególnie istotnych diagnostycznie czyli w miejscach występowania patologii.

Poprawa percepcji oznacza taką zmianę parametrów w torze transmisji informacji pomiędzy źródłem a odbiorcą, która skutkuje bardziej trafną diagnozą.

W torze wydobywania, przekazywania i przetwarzania informacji obrazowej znajdują się:

- badany obiekt (pacjent),
- obrazujące urządzenie radiologiczne (cyfrowe),
- układy rekonstrukcji i przetwarzania obrazu (składanie i korekta danych z akwizycji, poprawa jakości i percepcji),

- profesjonalne metody wizualizacji wyników badania,
- specjalista radiolog (wspomagany np. systemem CAD).

Jak widać na diagnozę ma wpływ wiele czynników. Tak więc aby poprawiać percepcję należało by zadbać o jak najlepsze zobrazowanie, interesujących z punktu widzenia diagnozy, fragmentów badanego obiektu. Zwykle urządzenie radiologiczne dostarcza danych obrazowych o znacznie większej liczbie poziomów szarości niż jest w stanie rozróżnić oko ludzkie. Celem układów przetwarzania obrazu jest wytłumienie sygnałów nieistotnych z punktu widzenia diagnozy (detekcji) oraz uwydatnienia obszarów które specjalista powinien dokładnie obejrzeć. Stosuje się różnego rodzaju algorytmy przetwarzania obrazu. Budowane są predefiniowane filtry do konkretnych rodzajów badań lub stosuje się progowanie (okienkowanie) wartości pikseli w obrazie ze zmiennymi wartościami progów. Współczynniki te modyfikowane są ręcznie podczas oglądania obrazu. Taki sposób przedstawienia danych pomaga w rozróżnianiu niejednorodności w strukturze tkanki. Wadą tego typu rozwiązania jest konieczność indywidualnego dobierania parametrów wyświetlania do każdego analizowanego obrazu. Prowadzone są prace nad adaptacyjnymi metodami doboru współczynników oraz wyrównania histogramu. Znane są takie metody jak CLAHE (contrast-limited adaptive histogram equalization), MUSICA (multiscale image contrast amplification), HIW (histogram-based intensity windowing), MIW (manual intensity windowing) czy MMIW (mixture model intensity windowing), które w większy lub mniejszy sposób angażują odbiorcę w modyfikację parametrów wyświetlania. Inną grupą metod poprawy percepcji jest analiza i modyfikacja obrazu w dziedzinie transformacji wielorozdzielczej. Aby określić miejsce wymagające zwiększenia kontrastu trzeba znać "wygląd" szukanej patologii. Jak wiadomo, każda patologia jest inna tak więc klasyfikuje się je i tworzy modele. Stosowane są przekształcenia falkowe i inne (Leplacé'a) i buduje się modele szukanych patologii (lub zakłóceń) uwzględniając ich wystąpienie we współczynnikach zastosowanej transformacji na różnych poziomach dekompozycji (w różnych skalach). Transformacja powinna być tak dobrana aby umożliwiała opis szukanych obiektów w stosunkowo niewielkiej liczbie współczynników (tak aby współczynniki dobrze (możliwie jednoznacznie) charakteryzowały dany rozkład współczynników jasności w obrazie). Pozwala to na identyfikację konkretnych obiektów w obrazie oraz na wzmacnianie/osłabianie współczynników opisujących wybrany obiekt i co za tym idzie - uwydatnianie/tłumienie go w obrazie. Powoduje to zwiększenie dynamiki użytecznego sygnału.

7.1 Poprawa percepcji z użyciem przekształceń wielorozdzielczych


Transformacja falkowa stanowi bardzo dobrą bazę do budowania algorytmów uwydatniania subtelnych różnic w obrazie. Wykorzystano tą cechę w metodzie poprawy percepcji niedokrwiennego udaru mózgu. Przetwarzanie obrazu zrealizowano według następującego algorytmu:

1. Segmentacja regionu zainteresowań na poszczególnych warstwach
 - oddzielenie tkanki kostnej oraz obiektów o wartościach współczynnika pochłaniania promieniowania rentgenowskiego większych niż tkanka kostna (wybór obszarów o wartościach $-5 - 50$ HU)
 - wybór obszarów w których istnieje pewne prawdopodobieństwo wystąpienia udaru mózgu: szacowane na podstawie wartości średniej $+10$ HU w wybranych wcześniej obszarach oraz przyjęto szerokość okna równą 10 HU.
2. Transformacja falkowa z 6 poziomami dekompozycji: wybrano jądro przekształcenia o następujących filtrach: $g_0 = [-1/8, 2/8, 6/8, 2/8, -1/8]$, $h_0 = [1/4, 2/4, 1/4]$.
 - zastosowano metodę redukcji szumów poprzez modyfikację wartości współczynników transformacji według zależności: $c_{nowa} = c|c|^p$, gdzie c są to wartości współczynników falkowych znormalizowane w danej skali; parametr p ustawiano na 0.7 , c_{nowa} - nowa wartość współczynnika falkowego.
 - zwiększenie kontrastu zrealizowano poprzez modyfikację wartości współczynników według zależności:

$$y(x) = \begin{cases} x(\frac{m}{c})^p & \text{dla } |x| < c \\ x(\frac{m}{|x|})^p & \text{dla } c \leq |x| < m \\ x & \text{dla } |x| > m \end{cases}$$

gdzie p jest współczynnikiem nieliniowości (musi przyjmować wartości z przedziału $[0, 1]$); parametr c - zależy od poziomu szumów; wartości współczynników falkowych przekraczających m nie są modyfikowane.

3. W końcowej wizualizacji wyrównywany jest histogram odtworzonego obrazu oraz przeprowadzana normalizacja do obrazu 8 bitowego (256 poziomów szarości) z pikselami wewnątrz czaszki nie poddawany przekształceniom ustawionymi na wartość 255 .



Rys. 7.1: Wynik działania "monitora udaru": badanie wczesne a), badanie wczesne po filtracji b), badanie późne c).

7.2 Transformacja heksagonalna


Aby poprawić percepcję zmian patologicznych w obrazach mammograficznych zastosowano filtrację falkową z dwuwymiarowym jądrem przekształcenia [115][116].

Użyto adaptacyjnej metody modyfikacji wartości współczynników transformaty. Na podstawie otoczenie badanego punktu (w kanałach wysokoczęstotliwościowych) oraz jego wartości wyznaczano nową wartość tego punktu. Jeżeli średnia z wartości bezwzględnych otoczenia była mniejsza od wartości bezwzględnej badanego punktu, to wartość tego punktu jest zwiększana o 30% ($A=1.3$), dla pozostałych przypadków wartość nie jest zmieniana (dla $B=1$) zgodnie ze wzorem:

$$y' = \begin{cases} Ay, & \text{jeżeli } |y| > \alpha \sum_{x_i \in C} |x_i| \\ \frac{y}{B}, & \text{dla pozostałych} \end{cases} \quad (7.1)$$


gdzie y współczynnik falkowy, C kontekst jak na rys. 7.2, x_i współczynniki kontekstu, A - dobierana waga wzmocnienia, B - dobierana waga tłumienia, α - zależne od skali i położenia uwydatnienia obiektu.

Po odtworzeniu obrazów z tak przygotowanych wartości współczynników transformacji przeprowadzono wstępne testy subiektywne oceny jakości. Testom poddawane były mammogramy bez i z filtracją wstępną z wykorzystaniem heksagonalnych przekształceń falkowych. W ocenie obrazów brali udział inżynierowie, specjaliści od przetwarzania obrazów oraz specjaliści z dziedziny radiologii. Stwierdzono zauważalną poprawę jakości mammogramów.



Rys. 7.2: Sąsiedztwo modyfikowanego współczynnika transformaty, określone jako C we wzorze.


Rysunki 7.3 a) i b) przedstawiają zaznaczony obszar z wykrytymi mikrozwapnieniami przed i po zastosowaniu filtracji heksagonalnej. Dostrzegalne są różnice w lokalnym kontraście w okolicach mikrozwapnień.



Rys. 7.3: Obrazy mammograficzne: a) bez filtracji, b) po filtracji.

Efekt poprawy percepcji fragmentu mammogramu zawierającego mikrozwapnienie przedstawiono na rys. 7.4.

Dodatkowo, przeprowadzono testy z wykorzystaniem opisanej metody jako pre-filtracji w systemie CAD. Wstępne wyniki pokazują, że zastosowanie transformaty heksagonalnej z adaptacyjną metodą modyfikacji współczynników może być użyteczne. Tabela 7.1 zawiera wyniki czułości i współczynnika PVP:



Rys. 7.4: Interpolowany obraz mikrozwapnienia przed a) i po b) zastosowaniu filtracji heksagonalnej.

Tabela 7.1: . Poprawa jakości mammogramów.

Subtelność	1	2	3	4	5
<i>Czułość</i> [%]	31	60	75	83	100
<i>PVP</i> [%]	8	7	14	14	33
<i>Czułość</i> [%] po filtracji	69	85	95	92	100
<i>PVP</i> [%] po filtracji	15	34	33	18	30

gdzie *Czułość* i *PVP* obliczane są według zależności:

$$Czułość = \frac{TP}{TP + FN} \quad (7.2)$$

$$PVP = \frac{TP}{TP + FP} \quad (7.3)$$

Widać, że znacznie polepszają się parametry detekcji dla obrazów o dużym stopniu trudności rozpoznawania (*Subtelność* = 1, 2 i 3). Niewielka wartość *PVP* jest wynikiem zastosowania nowego algorytmu wyznaczania klastrów mikrozwapnień, który jest jeszcze w fazie projektowania.

Podsumowując można stwierdzić, że stosowanie filtracji przy użyciu przekształceń falkowych jest jak najbardziej uzasadnione do przetwarzania obrazów mammograficznych. Szczególnie istotna jest tu możliwość ingerencji w wybrane obszary obrazu, jak również analiza wielorozdzielcza, która ułatwia detekcję obiektów użytecznych o zróżnicowanym rozmiarze, a także uniezależnia możliwość wykrycia obszaru patologicznego od rozdzielczości analizowanego obrazu czyniąc metodę bardziej uniwersalną.

7.3 Transformacja *contourlet*


Ze względu na kierunkowy charakter transformacji *contourlet* zrodził się pomysł zastosowania w/w przekształcenia do analizy i modyfikacji w celu polepszenia jakości obrazów mammograficznych. Poddano próbie i przebadano oparte na analizie wielorozdzielczej metody poprawy percepcji mikrozwapnień oraz guzków spikularnych.

Na zdjęciach mammograficznych guzki spikularne (gwiazdziste) widoczne są jako nieregularne jasne powierzchnie z poszarpanymi krawędziami, które wrastają w zdrową tkankę. Poszukiwanie w/w obiektów w obrazach jest szczególnie istotne w początkowej fazie rozwoju guza gdyż nie można go zidentyfikować prostszymi metodami (palpacyjnie, innymi metodami obrazowania). Jak wiadomo, guzy spikularne mają dość skomplikowany kształt co stanowi znaczny problem przy automatycznym rozpoznawaniu obrazu. Do rozwiązania tego zadania zastosowano transformację *contourlet*. Testowano kilka rodzajów przekształceń falkowych. Obiecujące wyniki dała transformacja *contourlet*, która jak wspomniano wcześniej, szczególnie dobrze charakteryzuje kierunkowość analizowanego sygnału, czyli przestrzennych (2W) struktur zmian w mammogramach. Przy zastosowaniu kierunkowej analizy falkowej możliwe jest bardziej dokładne określenie położenia centralnej części guza, co umożliwia jego lokalizację oraz identyfikację. W kolejnej fazie zastosowano wzmocnienie wartości pikseli zidentyfikowanych jako należące do poszukiwanej patologii. Efektem zmiany rozkładu wartości współczynników transformaty było zwiększenie lokalnego kontrastu.


Porównano wyniki klasycznej transformacji falkowej (wavelet) z transformacją *contourlet* i okazało się, że w dziedzinie współczynników transformacji *contourlet* można z lepszym przybliżeniem definiować modele dużych obiektów w obrazie. Klasyczna transformacja falkowa nadaje się raczej do analizy niewielkich obiektów o regularnych kształtach, np. mikrozwapnień (lepiej opisuje punktową nieosobliwość, nieciągłość, podczas gdy *contourlets* dobrze charakteryzują nieciągłości liniowe, czyli kontury np. guzków)

Zaproponowany algorytm poprawy percepcji bazuje na wielorozdzielczej analizie obrazu. W pierwszej fazie podejmowana jest próba rozpoznania i lokalizacji obiektów patologicznych oraz odseparowanie ich od obrazu zdrowej tkanki (naczyń itp.) a następnie lokalną modyfikację kontrastu.

Jak wcześniej wspomniano, algorytm opiera się na przekształceniu *contourlet*. W dziedzinie transformacji obiekt o zbliżonych cechach do guza spikularnego charakteryzuje się zmniejszeniem lokalnej wariancji współczynników. W obszarach gdzie nie występuje poszukiwany obiekt lokalna wariancja osiąga wartości przekraczające 20 000. Dobór wielkości otoczenia też nie jest bez znaczenia. Eksperymentalnie dobrano sąsiedztwo 10x10 pik-



Rys. 7.5: Wartości współczynników transformacji *contourlet* na poziomie 3 kierunek 1 z przedziału $< 0, 2^3 >$ (na obszarze o współrzędnych (140, 60) widoczne zmniejszenie lokalnej wariancji).



Rys. 7.6: Mapa obszarów podejrzanych o występowanie patologii (guza spikularnego).


seli dla których wartość lokalnej wariancji w miejscu występowania obiektu patologicznego wynosiła 3000. Na podstawie rozkładu wartości wariancji utworzono mapę obszarów podejrzanych o występowanie patologii. Obszary te poddawane były operacji zwiększenia kontrastu poprzez zwiększenie wartości współczynników. Do zwiększania kontrastu zastosowano zmodyfikowany algorytm MUSICA (Multi Scale Image Contrast Amplification).

Wartości współczynników transformacji modyfikowano na podstawie wzoru:

$$y(x) = a \frac{x}{|x|} |x|^p \quad (7.4)$$


gdzie: p - parametr z przedziału $(0, 1)$ określający stopień zniekształceń (im bliższy wartości 1 tym mniejsze zniekształcenia); x - znormalizowane wartości współczynników transformacji do przedziału $[-1, 1]$; y - zmodyfikowane znormalizowane wartości współczynników transformacji, a - współczynnik normalizujący.

Ustalono eksperymentalnie wartość parametru p w przedziale $< 0.7, 0.85 >$ (podobnie jak w pracy [114] dla klasycznej piramidy Laplace'a). Powyżej wartości 0.85 modyfikacja współczynników transformacji ma niezauważalne znaczenie, natomiast poniżej 0.7 - powoduje znaczne zwiększenie poziomu szumów w przetwarzanym obrazie.



Rys. 7.7: Przykładowy obraz guza spikularnego.


Na Rys. 7.7, 7.8 oraz 7.9 przedstawiono obrazy mammograficzne guza spikularnego powstałe w wyniku transformacji falkowej oraz *contourlet* z modyfikacją współczynników wg wzoru 7.4. Widać, że na obrazie 7.9 struktura guza jest najlepiej widoczna gdyż bardziej są wytłumione struktury



Rys. 7.8: Obraz guza spikularnego po przetwarzaniu z użyciem transformacji falkowej ($p = 0.75$).

sutka gęstego w okolicy patologii niż na obrazach 7.7 i 7.8.

Wyniki eksperymentów potwierdziły użyteczność transformacji *contourlet* w poprawie percepcji guzów. Przetestowano ok. 30 zdiagnozowanych obrazów pochodzących z bazy danych DDSM i eksperymentalnie dobrano następujące parametry algorytmu: filtry transformacji *contourlet*: '9-7' oraz '5-3'; liczba poziomów dekompozycji: 3; liczba rozpoznawanych kierunków na poszczególnych poziomach dekompozycji: 4, 8, 8; wartość parametru p : 0.75. We wszystkich testowanych obrazach widoczna była poprawa widoczności struktury guza na tle sutka gęstego. Transformacja *contourlet* lepiej charakteryzuje duże obiekty o ostrych krawędziach niż klasyczna transformacja falkowa. Przekształcenie *contourlet* podobnie jak falkowe jest transformacją wielorozdzielczą. Daje to możliwość analizy obrazu w różnych skalach, co jest niezwykle istotne przy wyszukiwaniu cech charakteryzujących szukany obiekt. Transformacja *contourlet* zorientowana jest na analizę krawędzi występujących w obrazie i przybliżaniu ich z regulowaną dokładnością za pomocą prostych w różnych skalach (na różnych poziomach dekompozycji). Taki sposób analizy ułatwia wyszukiwanie granicy obszarów różniących



Rys. 7.9: Obraz guza spikularnego po przetwarzaniu z użyciem transformacji *contourlet* ($p = 0.75$).

się poziomem jasności, czyli w opisywanym przypadku obszarami wewnątrz i na zewnątrz guza. Dodatkowo dostajemy informację w postaci dużej wartości współczynnika transformacji - jakiej długości jest znaleziona krawędź (wnioskujemy to z poziomu dekompozycji) oraz pod jakim kątem przebiega. Złożenie informacji pochodzącej z różnych skal o krawędziach daje możliwość poprawy ich percepcji poprzez lokalne ich wyostrenie i redukcję tła w celu lepszej identyfikacji poszczególnych struktur.

Rozdział 8

Charakterystyka systemów wspomagania diagnostyki w mammografii


8.1 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 (20 keV) do wykonania zdjęcia piersi. Można tu zobaczyć nawet bardzo małe zmiany (np. 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% [1]. 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 w piersi stwierdzonych wcześniej badaniem klinicznym. Podstawowe badanie mammograficzne zawiera zdjęcia w dwóch projekcjach - skośnej i kranio-kaudalnej (rys. 8.1).

Projekcja skośna (MLO, boczna) wykonana jest pod kątem 40-60° do pionu, a kranio-kaudalna (CC) to projekcja pozioma (rys. 8.2). 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 uzupełnia-

jące przy stwierdzonej w mammografii zmianie dają badanie kliniczne i wywiad oraz często badanie USG. Natomiast ostateczną odpowiedź zapewnia biopsja aspiracyjna cienkoigłowa i badanie histopatologiczne [4].




Rys. 8.1: Typowe badanie mammograficzne w dwóch projekcjach.

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,



Rys. 8.2: Sposób wykonania badania mammograficznego: (a) projekcja MLO; (b) projekcja CC. (Rysunek zaczerpnięty z pracy [2].)

- innych zewnętrznych w stosunku do medycyny i techniki obrazowania 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: anatomię piersi oraz zmienność osobniczą jej budowy, właściwości fizyczne tkanek piersi. Jeśli dodamy splot tych czynników stanowi to trudne do pokonania ograniczenie interpretacji badań mammograficznych.

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. Zręb podtrzymuje naczynia krwionośne, limfatyczne, nerwy i stabilizuje wszystkie struktury sutka. Rysunek 8.3 przedstawia schematycznie anatomię piersi.

Tkanka gruczołowa piersi zgrupowana jest w ok. 15-20 stożkowatych płatów skierowanych wierzchołkiem ku brodawce. W obrębie płata tkanka gruczołowa podzielona jest 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 ułożone są kolistnie wokół brodawki, to rozkład tkanki gruczołowej nie jest jednorodny. Najwięcej jest jej w obszarze centralnym i górnobocznym piersi. Zmiany nowotworowe w piersi powstają z tkanki gruczołowej i nabłonka gruczołowego wyściełającego przewody mleczne.



Rys. 8.3: Anatomia piersi podstawowe struktury. Dla jasności rysunku nie uwzględniono naczyń krwionośnych, limfatycznych i całości przegród łącznotkankowych. (Rysunek na podstawie [11].)

Zmienność obrazu piersi

Pierś rozwija się gwałtownie w okresie dojrzewania w odpowiedzi na hormony produkowane przez jajniki (estrogen i progesteron). W ciągu życia kobiety organ ten jest w stanie periodycznych zmian pod wpływem stymulacji hormonalnej, aż do okresu menopauzy. Znaczne zmiany zachodzą w piersi w okresie ciąży i laktacji. Dopiero w okresie menopauzy obraz piersi stabilizuje się. Sutki są organami 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 drugiego

sutka, a przy kolejnych badaniach – porównanie ze zdjęciami poprzednimi (ocena względna, porównawcza) [4].

Budowę piersi cechuje również duża zmienność osobnicza. Normą jest występowanie w populacji różnych typów budowy piersi dla tych samych przedziałów wiekowych. 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.

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 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.

Podsumowując, piers jest organem złożonym zarówno anatomicznie jak i funkcjonalnie. Z tego względu jak również ze względu na dużą zmienność osobniczą nie ma jak dotąd (i zapewne nie będzie, nawet dla wyróżnionych przedziałów wiekowych) "wzorca prawidłowej piersi". Wszystko to sprawia, że interpretacja mammogramu jest zadaniem złożonym.

Ograniczenia wynikające z innych zewnętrznych w stosunku do medycyny i techniki obrazowania uwarunkowań

Do czynników obniżających trafność diagnozy należy również zaliczyć znaczący wpływ uwarunkowań technicznych 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.

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% różnice w czułości diagnozy: w skrajnych przypadkach procent pacjentek skierowanych na biopsję wynosił 100% i 47% [5].

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 [53].

Prace badawcze dążą do osiągnięcia zmniejszenia subiektywizmu diagnozy. Konsultacje kilku lekarzy (druga ocena, kontr-ocena) dotyczące tego samego przypadku zwiększają efektywność mammografii o około 15% [6], ale jednocześnie zmniejszają wydajność ich pracy i podnoszą cenę badania.

8.1.1 Podstawowe patologie istotne w CAD – charakterystyka

Standaryzacja opisu medycznego jest ważnym tematem badawczym w Informatyce Medycznej [104]. W dziedzinie terminologii mammograficznej za standard uważany jest obecnie BI-RADS [3][2] (*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 [3]:

- 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) [1]. Prawidłowa ocena mikrozwapnień ma zasadnicze znaczenie ponieważ jest to jeden z ważnych objawów umożliwiających wykrycie małych niepalpacyjnych nowotworów piersi.

W [1] podaje się, że około połowa raków niepalpacyjnych uwidocznia się jako mikrozwapnienia. Zmiany łagodne również zawierają zwapnienia (zarówno makro jak i mikro), więc weryfikacja histopatologiczna każdego przypadku nie jest uzasadniona ani merytorycznie, ani ekonomicznie. Ważna natomiast jest analiza cech mikrozwapnień i ocena na tej podstawie prawdopodobieństwa ich złośliwości. Dlatego w dalszej części skryptu poświęconej charakterystyce zmian mammograficznych opisane będą guzy i mikrozwapnienia.

8.1.2 Guzy

Guz to patologia pokrywająca pewien obszar, widoczna w dwóch projekcjach [53]. 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. 8.4):

- Okrągły (*'round'*) – kształt sferyczny, 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. 8.4):


- Dobrze odgraniczony (*'circumscribed'*) - Brzegi są ostro odgraniczone z nagłym przeskokiem pomiędzy patologią a otaczającą tkanką. Nie ma nic, co sugerowałoby naciekanie sąsiadujących tkanek.
- Mikropolicykliczny (syn. ząbkowany) (*'microlobulated'*) - Brzegi faliście 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 normalnych tkanek piersi.
- Spikularny (*'spiculated'*) - Patologia jest scharakteryzowana przez linie promieniujące gwiazdźście od brzegu zmiany (naciekanie).

Guzy łagodne zwykle mają regularny kształt (kolisty lub owalny), gładkie zarysy, jednolitą teksturę. Są dobrze odgraniczone od tkanki otaczającej (rys. 8.6). Guzy o nieregularnym kształcie z nieostrych zarysami lub spikulami wrastające w otaczającą tkankę mają większe prawdopodobieństwo złośliwości (rys. 8.5, 8.7). 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. 8.5).


8.1.3 Mikrozwapnienia

Mikrozwapnienia są jednym z ważniejszych objawów umożliwiającym wczesne wykrycie raka sutka. W 30-50% wczesnie wykrytych w mammografii raków widoczne są klastry mikrozwapnień, a w 60-80% raków piersi schorzenie ujawnia się jako mikrozwapnienia podczas badania histologicznego [10]. Mammografia jest podstawowym badaniem w ich ocenie ilościowej i jakościowej [4].


Mikrozwapnienia to małe złogi 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 wapnienia pozostałości wewnątrzprzewodowych, które nie mogły zostać wchłonięte lub wydzielone [1].




Rys. 8.4: Schematycznie przedstawione rodzaje kształtów i zarysów oraz odpowiadająca im terminologia używana do opisu guzów. (Rysunek zaczerpnięty z pracy [2].)



Rys. 8.5: Złośliwe guzy. (a) Zarysy odcinkowo nieostre, źle określone. (b) Mocno wysycony guz o przypadkowej orientacji. (Rysunek zaczerpnięty z pracy [7].)



Rys. 8.6: Łagodne guzy dobrze odgraniczone. (a) Halo: wąska półprzezroczysta obręczka naokoło guza. (b) Tłuszczak - niskie wysycenie. (c) Cysta o gładkich zarysach i orientacji w kierunku brodawki. (Rysunek zaczerpnięty z pracy [7].)



Rys. 8.7: Złośliwe patologie gwiaździste. (a) Wyraźny centralny guz z gęstymi kolcami promieniującymi we wszystkich kierunkach. (b) Bardzo mały guz, nie wyczuwalny w dotyku - w mammografii widoczne zaburzenie architektury. (Rysunek zaczerpnięty z pracy [7].)

Na zdjęciach rentgenowskich mikrozwapnienia wyglądają jak drobne jasne plamki różnych rozmiarów i kształtów. Ważną charakterystyką zwapnień są ich rozmiar, kształt lub morfologia, liczba lub rozłożenie (*'distribution'*). Generalnie są bardzo małe, o wymiarach od 0.05 do 1 mm (średnio 0.3 mm).


Typowo łagodne zwapnienia (rys. 8.8) są:

- obrączkowate, skórne (*'luculent ceter'*) - makrozwapnienia sferyczne, duże, gładka powierzchnia, przeźroczyste centrum (rys. 8.10b.),
- naczyniowe (*'vascular'*) - makrozwapnienia o kształcie liniowym, zlokalizowane w przebiegu naczyń krwionośnych,
- zgrubne, kleksowate (*'coarse'*) – makrozwapnienia charakterystyczne dla degenerującego gruczolakowłókniaka (rys. 8.10c.),
- pałeczkowate (*'rod-like'*) – łagodne zwapnienia (najczęściej makrozwapnienia) w przewodach mlecznych,
- punkcikowate (*'punctate'*) – mikrozwapnienia okrągłe lub owalne, mniejsze niż 0.5 mm z wyraźnie określonym zarysem (rys. 8.10a.),
- jak skorupka jajka (*'egg-shell'*) – mikro- lub makrozwapnienia,
- mleczko wapnia (*'milk of calcium'*) – mikro- lub makrozwapnienia.

Zwapnienia o interpretacji niepewnejpośredniej (*'amorphous, indistinct'*) są małe, niewyraźne, o trudnym do dokładnego określenia kształcie, czasami opisując je stosuje się terminy bezpostaciowe lub amorficzne.

Mikrozwapnienia o zwiększonym prawdopodobieństwie złośliwości zwykle są mniejsze niż 0.5 mm i mogą być:

- niejednorodne, polimorficzne, nieregularne, różnokształtne (*'pleomorphic, heterogeneous'*) (rys. 8.9a.),
- cienkie, linearne, ale nieciągłe, rozgałęziające się (*'fine, linear, branching'*) (rys. 8.9b.).




Rys. 8.8: Terminologia używana do opisu mikrozwapnień. (Rysunek zaczerpnięty z pracy [2].)

Rozłożenie w tkance zwapnień może być opisane jako:

- skupisko (*'clustered'*) - grupa więcej niż pięciu w małej objętości tkanki (poniżej 2 cm³) (rys. 8.9a.),
- liniowe (*'linear'*) - ułożone w linię, która może się rozgałęziać (bardziej prawdopodobna złośliwość) (rys. 8.9b.),

- segmentarne lub przewodowe (*'segmental'*) - 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 po całej powierzchni piersi (*'diffuse, scattered'*) - są prawie zawsze łagodne (rys. 8.10b.).




Rys. 8.9: Złośliwe mikrozwapnienia. (a) Punkcikowate kropki lub o wydłużonym kształcie, niezliczone w skupisku. (b) Robaczkowate, linijne, rozgałęziające się. (Rysunek zaczerpnięty z pracy [7].)


8.1.4 Wczesne oznaki złośliwości

Inne delikatne objawy sugerujące wczesną postać raka to:

- nowe zagęszczenie tkanki w porównaniu z poprzednimi badaniami,
- zaburzenie architektury tkanki bez masy guza (rys. 8.5b., 8.11),
- asymetria gęstości tkanki w obydwu piersiach.



Rys. 8.10: Łagodne mikrozwapnienia. (a) Jednorodne, lite, ostro odgraniczone, bardzo drobne i gęste. (b) Obrączkowate, środek przezroczysty. (c) Gruboziarniste, nieregularne i bardzo gęste. (Rysunek zaczerpnięty z pracy [7].)



Rys. 8.11: Delikatne zaburzenie architektury - zmiana złośliwa. (Rysunek zaczerpnięty z pracy [2].)

8.1.5 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. 8.12): 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. 8.1)


Kategoria	Ocena	Opis
0	Ocena niekompletna	Dodatkowe badanie obrazowe
1	Negatywna	Bez komentarza
2	Zmiana łagodna	Zmiana zdecydowanie łagodna
3	Zmiana prawdopodobnie łagodna	Bardzo wysokie prawdopodobieństwo zmiany łagodnej; krótkoczasowa obserwacja w celu uzyskania pewności diagnozy
4	Podjęzrzenie patologii złośliwej	Zmiana nietypowa, złośliwa ze znaczącym prawdopodobieństwem; należy rozważyć biopsję
5	Silne przekonanie o złośliwej patologii	Wysokie prawdopodobieństwo zmiany złośliwej; należy podjąć odpowiednie działania

Tabela 8.1: Kategorie oceny końcowej badania mammograficznego.

8.2 Charakterystyka stosowanych metod CAD

8.2.1 Cel komputerowego wspomaganie diagnozy

Skutecznym rozwiązaniem problemu kontr-oceny innego radiologa może być komputerowe wspomaganie diagnozy (*computer-aided diagnosis* - CAD),



Rys. 8.12: 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 drobnotuzzkowa, (d) gęste utkanie gruczołowe. Widać wyraźnie, że ostatni typ budowy piersi znacznie ogranicza czułość mammografii jeśli chodzi o małe zmiany. (Na podstawie [13].)

czyli włączenie technologii komputerowej w proces interpretacji badań mammograficznych. Komputerowo wspomagana diagnoza to wspieranie decyzji diagnostycznej radiologa metodami przetwarzania, analizy i rozpoznawania. Jednakże ostateczną decyzję podejmuje lekarz, a wskazania CAD mają jedynie charakter sugestii. Celem CAD jest pomoc lekarzowi w wydaniu prawidłowej diagnozy (zwiększenie dokładności diagnostycznej) poprzez zwiększenie możliwości detekcji i właściwej oceny zmian. Ponadto pozwala ono w większym stopniu zobiektywizować interpretację zdjęć mammograficznych (zmniejszyć różnice w diagnozach wydawanych przez różnych radiologów lub też przez jednego, ale w różnym czasie) oraz zmniejszyć nakłady pracy lekarzy.

8.2.2 Zastosowania CAD

Komputerowa analiza i przetwarzanie cyfrowych obrazów mammograficznych wykorzystywana jest do poprawy jakości obrazu, lepszej prezentacji zawartej w nich informacji diagnostycznej - poprawy percepcji (poprawa kontrastu, wykrycie krawędzi, podkreślenie zmian patologicznych, uwypuklenie ich cech charakterystycznych, usunięcie szumów) oraz detekcji (metody modelowania i rozpoznawania wzorców) i klasyfikacji (oszacowania złośliwości) podejrzanych zmian w tkance.

Wynikiem takiego wspomagania może być przetworzony obraz, symbol oznaczający podejrzane miejsce (np. gwiazdka, strzałka) lub wartość nu-

meryczna (np. prawdopodobieństwo złośliwości). Radiolog podejmuje decyzję diagnostyczną na podstawie wcześniejszej samodzielnej analizy obrazów medycznych oraz wyniku wspomagania. CAD ma przyciągnąć uwagę radiologa do podejrzanych zmian ocenionych przez komputer jako mających cechy raka. W tym kontekście CAD służy jako "druga para oczu" (*'second pair of eyes', 'second opinion'*).

8.2.3 Przydatność CAD w procesie diagnozy


Mimo wszystko, diagnoza jednego lekarza przy wspomaganiu komputerowym zawsze będzie mniej skuteczna niż konsultacje dwóch lub więcej radiologów dotyczące jednego badania. Głównie z powodu faktu, że zaznaczenie podejrzanego regionu przez system CAD nie gwarantuje uwzględnienia tej podpowiedzi przez radiologa. Jednak nawet w przypadku współdziałania kilku lekarzy CAD może wskazać zmiany, które zostały niezauważone i zwiększyć skuteczność detekcji. Testy przeprowadzone ostatnio w USA wykazały wzrost liczby wykrytych raków o 7%, nawet w przypadku analizowania badań przez dwóch lekarzy z pomocą systemu CAD [8]. Przydatność systemu komputerowego nie oznacza, że jest on "lepszy" - skuteczniejszy niż radiolog, ale jest w stanie wykryć niektóre zmiany, które mogą zostać niezauważone przez lekarza. Wspomaganie detekcji może być użyteczne nawet w mammografii diagnostycznej, gdzie rak może znajdować się także w innym obszarze niż wskazanie z badania klinicznego, tzw. detekcja kliniczne niepodejrzanych raków [9].

8.2.4 Schemat przetwarzania informacji w CAD

Danymi wejściowymi dla systemu CAD są cyfrowe obrazy mammograficzne. W celu oszczędności czasu przetwarzania, dokonuje się segmentacji granicy tkanki piersiowej odrzucając zaszumione tło obrazu. Algorytmy detekcji patologii na ogół składają się z dwóch etapów (rys. 8.13):

1. detekcja podejrzanego regionu na obrazie mammograficznym - zastosowanie m.in. technik segmentacji i rozrostu regionu (cel - uzyskanie jak najwyższej czułości, dopuszczając dużą liczbę fałszywych wskazań)
2. klasyfikacja tego obszaru jako guza lub normalnej (zdrowej) tkanki (cel - redukcja liczby fałszywych wskazań, nie zmniejszając drastycznie czułości)

W niektórych metodach poszczególne kroki (rys. 8.13b.) wykorzystują bardzo zaawansowane algorytmy, niektóre zostają zredukowane do bardzo



Rys. 8.13: (a) Ogólny schemat funkcjonalny systemu CAD. (b) Poszczególne kroki włączone w projektowanie metod na etapie 1. i 2. detekcji oraz diagnozy.

prostyh technik, a niektóre są całkowicie pominięte. Na przykład na pierwszym etapie detekcji często klasyfikacja zostaje zredukowana do prostego progowania lub usuwania regionów o powierzchni mniejszej od zadanej wartości.

Ogólnie wstępne przetwarzanie służy do: usunięcia lub redukcji szumu i artefaktów (małe - o powierzchni kilku pikseli - obiekty, np. rysa, pyłek, który osiadł na zdjęciu rentgenowskim podczas skanowania itp.), usunięcia informacji diagnostycznie nieistotnej (struktur zdrowej tkanki), uwypuklenia cech istotnych dla diagnozy, wzmocnienia lokalnego kontrastu, selekcji regionu zainteresowania (ROI), w którym występowanie raka jest bardziej prawdopodobne. Następnie (zwykle w drugim etapie detekcji lub w diagnozie) dla każdej patologii obliczane są cechy - deskryptory matematyczne. Dla mikrozwapnień mogą to być: rozmiar, kontrast, cechy kształtu, cechy całych klastrów, dla guzów: obecność i rozmiary spikul, asymetria, gęstość, kształt. Ze zbioru cech należy wybrać te najlepiej rozróżniające poszczególne klasy patologii (selekcja cech), np. dzielące patologie na prawdziwe i fałszywe lub na łagodne i złośliwe w zależności od rodzaju wyniku wspomagania. Do zbioru powyższych deskryptorów matematycznych można dodać też dane kliniczne (wiek pacjentki, wywiad rodzinny itp.) oraz wyniki innych badań (USG, MRI). Metody klasyfikacji to analiza dyskryminacyjna, sieci neuronowe lub inne hybrydowe klasyfikatory. Wynikiem detekcji jest lokalizacja zmiany lub oznaczenie regionu zmiany z dokładnymi granicami albo w przypadku diagnozy oszacowane prawdopodobieństwo złośliwości lub też zalecenia dalszego postępowania (BI-RADS).

8.2.5 Przegląd rozwiązań komercyjnych

Komputerowe wspomaganie diagnostyki oraz komputerowa detekcja różnych radiologicznych anomalii są dziedzinami, które rozwijają się intensywnie w ostatnich latach. Powstało już kilka zaawansowanych technologicznie komercyjnych systemów detekcji zmian patologicznych w mammografii, m.in. *ImageChecker* firmy *R2 Technology* (technologia wspomagania detekcji anormalności CAD na filmach oraz cyfrowych obrazach mammograficznych zaaprobowana przez *U.S. Food and Drug Administration* w 1998) [14], *SecondLook* firmy *iCAD* (FDA - 2002) [15], *MammoReader* firmy *CADx* (FDA - 2002; w 2003 połączony z firmą *iCAD*), *Mammex MammoCAD* firmy *Scanis* [16], *Kodak Mammography CAD System* firmy *Eastman Kodak*, *M-Vu Mammography CAD System* firmy *VuCOMP* [17].

Dotychczas najlepiej przetestowanymi oraz rozpowszechnionymi są systemy *ImageChecker* i *SecondLook*. Czułość ich jest podobna, ale różnią się liczbą fałszywych wskazań na obraz. Ogólnie systemy te różnią się głównie

rodzajem wyświetlacza - sposobem prezentacji obrazu, integracją z systemami cyfrowej mammografii (*FFDM - Full Field Digital Mammography*), integracją z PACS oraz zajmowaną powierzchnią.

8.2.6 Kryteria oceny systemów CAD

Ocena systemów CAD (wspomagania detekcji) polega na oszacowaniu wydajności samej komputerowej metody detekcji ze względu na czułość i liczbę fałszywych wskazań (*FP - 'false positives'*) na obraz - analizie wykresów czułości w zależności od liczby FP na obraz (krzywe *FROC - 'Free-Response Receiver Operating Characteristic'*)[53]. Jednak ostatecznym testem jest badanie jakości diagnozy radiologów, którzy używają danego systemu wspomaganie komputerowego, tj. testy obserwacyjne, które mierzą wydajność radiologa pracującego samodzielnie, a także pracującego ze wsparciem systemu CAD oraz studia kliniczne.

8.2.7 Szczegółowa ocena wybranych systemów

Testy systemu *R2 ImageChecker* przeprowadzone na dużej bazie badań skriningowych wykazały, że jego czułość całkowita to ok. 90%, liczba fałszywych wskazań na obraz to 0.5 (tab. 8.2) [18]. System ten zwiększa czułość radiologa o ok. 19.5% (od 3.2 do 3.8 schorzeń / 1000 badań), a liczba pacjentek wysyłanych na biopsję (*'recall rate'*) wzrasta o ok. 18.5% (od 6.5% do 7.7%) [19].

Czułość detekcji - mikrozwapnienia	98.3%
Czułość detekcji - guzy	85.7%
Czułość całkowita	90.4%
FP / normalny przypadek (złożony z 4 obrazów)	2.0 (0.5 FP/obraz)

Tabela 8.2: Skuteczność systemu R2 ImageChecker [18][19].

Czułość systemu *iCAD SecondLook* to 92-96%, a liczba FP na normalny przypadek to 1.6 do 2.8 w zależności od opcji oprogramowania [15]. Zwiększa czułość radiologa o ok. 21.2% [20][21][22][23][24].

Porównanie skuteczności najbardziej rozpowszechnionych komercyjnych systemów CAD w detekcji złośliwych zaburzeń architektury wypada zdecydowanie na korzyść systemu *R2 ImageChecker* - wyższa czułość i niższa liczba fałszywych wskazań (tab. 8.3) [25].

	Liczba	<i>R2 ImageChecker</i>	<i>iCAD SecondLook</i>
Przypadki (wykrywanie na jednym z dwóch obrazów)	27	48%	19%
Obrazy	51	31%	10%
FP/obraz	–	0.7	1.27

Tabela 8.3: Porównanie czułości komercyjnych systemów *R2 ImageChecker* i *iCAD SecondLook* w detekcji złośliwych zaburzeń architektury [25].

8.2.8 Systemy CAD w praktyce klinicznej

W USA praktyka diagnozy ze wspomaganie komputerowym jest już szeroko rozpowszechniona. W 2003 w USA działało ok. 1200 stacji wspomaganie detekcji. Około 25-30% (8 mln) badań przesiewowych było diagnozowanych przy pomocy systemów CAD.

W 2004 powstały pierwsze systemy wspomaganie diagnozy badań MRI (*3TP ImagingSciences*, *CADimas breast MRI CAD*, *CADstream MRI Con-firma*) oraz USG (*Cedara B-CAD*) [17].

8.2.9 Systemy wspomaganie detekcji - wyzwania światowe

Rozwój systemów wspomaganie detekcji ciągle trwa. Przede wszystkim potrzeba jeszcze wielu testów klinicznych zebranie dużej bazy przypadków (liczba raków w populacji przesiewowej jest mała) z różnych populacji pacjentek oraz staranne przygotowanie testów i procedur ich oceny (m.in. wybór reprezentatywnej grupy radiologów oceniających wyniki CAD).

Inne możliwe udoskonalenia oraz problemy do oszacowania to:

- Poprawa algorytmów detekcji guzów w celu zwiększenia czułości detekcji przy zachowaniu wskaźnika FP/obraz. (W obecnym stanie zaawansowania systemów CAD niektórzy radiolodzy mogą ignorować wyjście detekcji guzów jako mało skuteczne [26].)
- Włączenie i poprawa detekcji innych radiograficznych oznak raka, np. zaburzeń architektury.
- Rozwój i ocena CAD na innych modalnościach (używanych szczególnie w skryningu pacjentek wysokiego ryzyka, np. USG, MRI); Analiza

łączona mammografii i innych modalności.

- Ocena komputerowej detekcji mikrozwapnień jako podstawowego wskaźnika diagnostycznego (*'primary reader'*).
- Ocena potencjalnej roli CAD jako detekcji przypadków normalnych (bez potrzeby weryfikacji przez radiologa) – *'prescreener'*.

Rozdział 9

Wybrane metody i narzędzia CADD

9.1 Metody detekcji guzów w mammografii

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.

Detekcję guzów można podzielić na dwa etapy:

- detekcja podejrzanych regionów na mammogramie
- klasyfikacja podejrzanych regionów na guzy i normalną (zdrową) tkankę

Ogólny schemat metod detekcji guzów przedstawiony jest na rysunku 8.13. Pierwszy etap zwykle jest zaprojektowany tak, aby mieć bardzo wysoką czułość przy dopuszczalnej dużej liczbie fałszywych wskazań. Większość fałszywych wskazań powinna być usunięta w fazie drugiej algorytmów.

9.1.1 Metody uwydatniania


Wzmacnianie kontrastu podejrzanych regionów:

- adaptacyjne lokalne progowanie (próg zależny od lokalnych statystyk z okna sąsiedztwa wokół analizowanego punktu: średniej i odchylenia standardowego). Wartości progu powyżej wartości średniej pomnożonej przez wybraną wielokrotność odchylenia standardowego pozostają na obrazie, a pozostałe ustawiane są na wartość minimalną.

- globalne progowanie – pozostaje wybrany procent najwyższych wartości pikseli w histogramie poziomów jasności
- Wyostrzanie ekstremum (*'extremum sharpening'*) – Wartością operatora ekstremum jest minimum albo maximum z okna sąsiedztwa o środku w analizowanym punkcie w zależności od tego które z nich jest bliższe wartości funkcji jasności w tym punkcie. Jeśli wartość funkcji w punkcie jest dokładnie w połowie pomiędzy wartościami ekstremów, wartość pozostaje nie zmieniona. Rozmiar okna sąsiedztwa zależy od szerokości krawędzi w obrazie (rys. 9.1). Standardowa procedura analizy filtrem to: filtr medianowy 9x9 (usuwanie szumu), wyostrzanie ekstremum 3x3, filtr medianowy 5x5.

Usuwanie szumu – tła:

- schematy selektywnego uśredniania (schematy uśredniania unikające uśredniania w poprzek krawędzi)
 - wygładzanie zachowujące krawędzie [27] – Metoda poszukująca jednorodnego sąsiedztwa (wariancja jest miarą jednorodności, niższa wariancja oznacza bardziej jednorodny obszar) w różnych kierunkach analizowanego piksela i uśredniającą tylko w tym sąsiedztwie.
 - metoda połowy sąsiedztwa (*'half neighbourhood'*) [27] – Dla pikseli leżących na krawędziach sąsiedztwo dzielone jest w różny sposób i do uśredniania wybierane jest to, którego poziom uśrednienia różni się najbardziej od pozostałej części. Metoda zakłada, że krawędzie są proste i złożone są z kolejnych połączonych punktów.
 - metoda k-najbliższych sąsiadów – Średnia z k najbliższych sąsiadów w oknie sąsiedztwa, których poziomy jasności są najbliższe analizowanemu punktowi
- filtracja medianowa (usuwa szum bez rozmywania krawędzi)
- selektywna filtracja medianowa (filtracja medianowa "najbliższego sąsiada") [27] – w obliczeniu mediany dla wybranego okna - zbiór pikseli ograniczony jest do tych, których różnica poziomów jasności z pikselem w centrum okna jest nie większa niż zadany próg T. Parametr T kontroluje jakość rozmycia krawędzi: jeśli T jest mały, to zachowuje krawędzie, ale efekt wygładzający też mały.



Rys. 9.1: Poprawa percepcji guza spikularnego. Po prawej – oryginał, po lewej – obraz po filtracji wyodrządzającej ekstrema.

9.1.2 Lokalizacja i segmentacja

Algorytm detekcji podejrzanego regionu (etap pierwszy) można podzielić na dwa rodzaje:

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

Detekcja oparta na analizie pojedynczych pikseli

Detekcja guzów spikularnych i zaburzeń architektury

Normalna 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) oraz cechy tekstury Law; klasyfikacja każdego piksela - binarne drzewo decyzyjne [54],

- statystyczna analiza map orientacji pikseli (orientacje pikseli policzone są na podstawie filtrów pochodnych kierunkowych Gaussa) [55],
- wielorozdzielcza dekompozycja falkowa w celu wychwycenia guzów różnych rozmiarów; detekcja przeprowadzana jest od skali zgrubnej (większe guzy) do coraz bardziej dokładnej (mniejsze zmiany); na każdym poziomie rozdzielczości zastosowano statystyczną analizę ALOE (j.w.) [56].

Detekcja wszystkich rodzajów guzów

- wstępna segmentacja podejrzanych regionów - adaptacyjne progowanie; iteracyjna poprawa segmentacji przy użyciu wielorozdzielczego pola losowego Markova (*Markov random field*); [57],
- podział mammogramów na kategorie w zależności od rodzaju utkania tkanki piersi (progowanie adaptacyjne); podejrzane regiony segmentowane są na podstawie różnych wartości progów w zależności od rodzaju tkanki; [58],
- uwydatnianie morfologiczne i segmentacja oparta na modelu stochastycznym; model histogramu obrazu mammograficznego - zgeneralizowany rozkład gaussowski; segmentacja poprzez klasyfikację pikseli za pomocą '*Bayesian relaxation labeling*' [59].
- przybliżenie lokalnego histogramu splajnami Beziera, próg to najmniejsze minimum histogramu lub skrajne prawe przegięcie histogramu [68]

Zalety i wady metod opartych na analizie pikseli:

- duża liczba próbek do nauki klasyfikatora
- inna charakterystyka pikseli wewnątrz zmiany i na obrzeżach – w rzeczywistości wymaga różnego rodzaju 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 rozróżniający guzy od normalnej tkanki)
- duża złożoność obliczeniowa

Detekcja oparta 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.

- Filtr *Iris* – model guza: okrągły wypukły region – zastosowany do mapy gradientów obrazu (operator Prewitta); Wyjście filtru niezależne od kontrastu między patologią a tłem. [60],
- Filtry wykrywające krawędzie: *Laplacian of Gaussian*, *Difference of Gaussian* [61][62]
- piramida gaussowska [63]
- transformata Hougha dla okręgów zastosowana na obrazie krawędzi (operator Canny) [65]
- wielorodzielcza i wielokierunkowa transformata falkowa [64]
- lokalna analiza tekstury oraz momentów lokalnych histogramów poziomów jasności [66]

Kształty wykrytych obiektów mogą być poprawiane z zastosowaniem technik rozrostu regionu [62].

Zalety i wady metod opartych na analizie regionów:

- analiza przestrzennego rozłożenia pikseli
- cechy mają bezpośrednie odniesienie do ważnych informacji diagnostycznych, np. kształt i zarysy wykrytych regionów
- mniejsza złożoność obliczeniowa niż metod opartych 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.)

9.1.3 Ekstrakcja cech

Do eliminacji fałszywych regionów (klasyfikacja patologia-norma) zastosowano cechy:

- deskryptory kształtu, m.in. zwartość [57][58],

- rozmiary regionu i powierzchnia [57],
- kontrast [57],
- statystyki poziomów jasności [58],
- cechy tekstury Law [62][63],
- deskryptory krawędziowe [62][63],
- wielorozdzielcze cechy tekstury z macierzy SGLD,
- położenie.

9.1.4 Klasyfikacja regionów (weryfikacja detekcji i diagnoza)


Metody klasyfikacji regionów na guzy i normalną tkankę:

- rozmyte binarne drzewo decyzyjne [57],
- sieci neuronowe, m.in. sieci o radialnej funkcji bazowej [66],
- analiza dyskryminacyjna

9.2 Metody detekcji mikrozwapnień w mammo- grafii

Ogólny schemat systemów detekcji i klasyfikacji mikrozwapnień znajduje się na rysunku 9.2. Danymi wejściowymi komputerowej detekcji mikrozwapnień jest obraz mammograficzny z odpowiednio dobranymi parametrami akwizycji (odpowiednia rozdzielczość obrazu itp.). We wstępnej fazie obróbki obrazu następuje uwypuklenie cech charakterystycznych dla mikrozwapnień, zmniejszenie widoczności cech obrazu odnoszących się do zdrowych struktur tkanki i szumu. Następnie lokalizowane są potencjalne regiony zawierające mikrozwapnienia. Segmentacja mikrozwapnień to odseparowanie ich z tła (zdrowej tkanki). Kolejną fazą jest ekstrakcja różnorodnych cech charakteryzujących pojedyncze mikrozwapnienia oraz ich skupiska. Detekcja klastrow to grupowanie pojedynczych obiektów w większe skupiska wg ustalonej definicji grupy, np. 5 obiektów na obszarze o wymiarach 1x1 cm. Selekcja polega na wybraniu tych cech, które najlepiej charakteryzują poszczególne grupy klastrow mikrozwapnień. Mikrozwapnienia mogą być klasyfikowane na trzy grupy: łagodne, złośliwe i normalne (fałszywie pozytywne). Klasyfikacja może także służyć jako ostateczna weryfikacja detekcji,

np. podział na dwie grupy: prawdziwie pozytywne i fałszywie pozytywne [10].



Rys. 9.2: Ogólny schemat metod detekcji i klasyfikacji mikrozwapnień.

W stworzonym systemie MammoViewer analizujemy i testujemy algorytmy dotyczące poszczególnych faz detekcji i klasyfikacji mikrozwapnień (rys. 9.2), sposoby połączenia rezultatów poszczególnych bloków funkcjonalnych oraz szukamy metod uproszczenia i przyspieszenia ogólnego schematu [43][44][45].

9.2.1 Metody uwydatniania mikrozwapnień

Metody uwydatniania mikrozwapnień są następujące:

- Eliminacja tła poprzez odejmowanie obrazu wygładzonego od oryginalnego (lub wzmocnionego), np. *'round high-emphasis'* (średnia otwarcia i zamknięcia morfologicznego) - filtr górnoprzepustowy zachowujący koliste krawędzie i "esencję" tekstury [10][28];
- Modelowanie zdrowej tkanki poprzez techniki fraktalne, wykorzystujące lokalne samopodobieństwo struktur zdrowej tkanki (inaczej niż mikrozwapnienia) [37];
- Falkowe metody usuwania szumu
 - Usuwanie niskoczęstotliwościowych informacji (zdrowe struktury tkanki) - całkowite usuwanie współczynników z podpasem niskoczęstotliwościowych [34];

- Progowanie podpasm zawierających wysokoczęstotliwościowe współczynniki falkowe (HH,HL,LH), aby oddzielić szum od mikrozwapnień; następnie rekonstrukcja obrazu [33];
- Morfologia - 'white top-hat', który uwypukla szczegóły obrazu [28][29][30][31][32];
- Wzmacnianie oparte na sąsiedztwie – zasięg i kształt regionu dostosowuje się do lokalnej zmienności funkcji jasności; definicja zasięgu regionu jest krytyczna [10].
- Filtracja 'box-rim': 9x9 wzorec z centralnym blokiem 3x3 odpowiadający mikrozwapnieniu z zewnętrzną otoczką o szerokości 2 pikseli odpowiadającą otaczającemu tłu

9.2.2 Lokalizacja i segmentacja mikrozwapnień

Metody lokalizacji regionów zawierających skupiska mikrozwapnień to analiza macierzy *Surrounding region-dependance* [39] lub też obliczanie wymiaru fraktalnego [38] (określającego "chropowatość" (obszaru) dla ustalonego podobrazu.

Lokalizacja pojedynczych obiektów potencjalnych mikrozwapnień:

- realizowana jest przez skalowalne filtry LoG (*Laplacian-of-Gaussian*) [40] – poszukiwanie lokalnych maksimów na obrazach po filtracji LoG w różnych skalach;
- poszukiwanie lokalnych maksimów na obrazie oryginalnym [67] lub na wybranych podpasmach zawierających wysokoczęstotliwościowe współczynniki falkowe [42].

Metody segmentacji mikrozwapnień z tła można podzielić na lokalne progowanie oraz metody rozrostu regionu (*region growing*). W algorytmie lokalnego progowania parametrami krytycznymi są rozmiar okna – sąsiedztwo zlokalizowanego obiektu i próg, np. próg adaptacyjny zależny od statystyk z okna. Metody rozrostu regionu polegają na grupowaniu pikseli o właściwościach podobnych do startowego (ziarna) - *seed* (parametry: rozmiar okna, moduł różnicy jasności pomiędzy przetwarzanym pikselem a startowym) [10].

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 [67], gdzie spadek można zdefiniować jako:

$$s(x, y) = (f(x_0, y_0) - f(x, y)) / d(x_0, y_0, x, y) \quad (9.1)$$

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) .

9.2.3 Ekstrakcja cech

Cechy charakteryzujące mikrozwapnienia można podzielić na cztery grupy:

- Cechy pojedynczych mikrozwapnień: cechy kształtu (powierzchnia, zwartość, momenty kształtu, momenty geometryczne), cechy oparte na analizie statystycznej histogramu rozkładu jasności (średni poziom jasności, odchylenie standardowe rozkładu jasności), wyrazistość krawędzi, lokalny kontrast [31][42];
- Statystyczne cechy tekstury oparte na analizie macierzy powinowactwa (zdarzeń), *'Gray-level run-length'*, *'Surrounding region dependence'*, *'Gray-level difference'* [38];
- Wielorozdzielcze cechy tekstury: cechy falkowe, filtry Gabora [42];
- Cechy klastrów mikrozwapnień: powierzchnia, liczba mikrozwapnień, średni poziom jasności mikrozwapnień w klastrze [29][31][41].

9.2.4 Klasteryzacja i segmentacja mikrozwapnień w MammoViewer

Metoda detekcji mikrozwapnień

Celem pracy była optymalizacja metody detekcji i analizy mikrozwapnień w mammografii. Zaproponowano metodę lokalizacji, klasteryzacji i segmentacji nadmiarowego zbioru obiektów zainteresowania – potencjalnych mikrozwapnień.

Celem szczegółowym opracowanego narzędzia wspomagania detekcji jest wskazanie regionów zawierających klastry mikrozwapnień. Wykorzystano elementy analizy wielorozdzielczej obrazów, metody grupowania i morfologii matematycznej zwracając szczególną uwagę na jakość wykrywanych klastrów. Prezentowana metoda została zweryfikowana w testach klinicznych

korzystając ze zdiagnozowanych baz danych (DDSM dostępnej w Internecie [48] oraz zestawu zdjęć mammograficznych zawierających interesujące przypadki zmian wybranych przez radiologów z Zakładu Diagnostyki Obrazowej Szpitala Wolskiego i Centrum Onkologii w Warszawie).

Zaproponowana technika jest kombinacją a) falkowych metod poprawy percepcji mikrozwapnień, b) filtracji przy użyciu filtrów LoG w różnych skalach w celu lokalizacji jasnych plamek - potencjalnych mikrozwapnień, c) algorytmu grupowania sygnałów DBSCAN (*Density Based Spatial Clustering of Applications with Noise*) oraz d) metod morfologicznych i rozrostu regionu do rekonstrukcji kształtów. Naszym założeniem była wstępna detekcja nadmiarowego zbioru kandydatów, redukowanego w znacznym stopniu w procesie klasteryzacji i rekonstrukcji kształtu.

Zaproponowana metoda oparta jest na następujących etapach:

- Wstępne przetwarzanie – techniki falkowe:
 - wygładzanie obrazu: podpasma niskoczęstotliwościowe transformaty bez decymacji; w celu usunięcia wysokoczęstotliwościowych informacji - drobnych artefaktów, załamania krawędzi, granulacji tekstury
 - uwypuklanie mikrozwapnień: adaptacyjne progowanie współczynników transformaty heksagonalnej na wielu poziomach dekompozycji [49];
- Lokalizacja pojedynczych obiektów - jasnych plamek (większych artefaktów, przecięć włókien oraz mikrozwapnień): skalowalne filtry LoG (Laplacian-of-Gaussian) (podobnie jak w [40]).
- Grupowanie w klastry oparte na przestrzennym rozmieszczeniu i gęstości obiektów (DBSCAN) [50];
- Segmentacja mikrozwapnień w klastrach przy użyciu operatorów morfologicznych z adaptacyjnym progowaniem lokalnym;
- Wygładzanie kształtów mikrozwapnień technikami rozrostu regionów;
- Opis kształtu klastrów - otoczki wypukłej zlokalizowanych grup.

Lokalizacja pojedynczych obiektów potencjalnych mikrozwapnień

Lokalizacja pojedynczych obiektów potencjalnych mikrozwapnień realizowana jest przez skalowalne filtry LoG (*'Laplacian-of-Gaussian'*) [40] – poszukiwanie największych lokalnych maksimów na ścieżkach utworzonych na podstawie obrazów po filtracji LoG w różnych skalach.

Znajdowane artefakty to bardzo wysokie (duży gradient) piki o małej powierzchni oraz większe fragmenty włókien (zdrowej) struktury piersi – większa powierzchnia i niski gradient. Mikrozwapnienia są pośrednie.

Segmentacja obiektów potencjalnych mikrozwapnień

Znajdowanie krawędzi zlokalizowanego obiektu w kilku kierunkach od punktu ziarna, a następnie rozwinięcie ich do pełnego konturu obiektu – *'hill climbing'* – metoda polegająca na znajdowaniu największego spadku w 16 kierunkach wokół punktu ziarna [67], gdzie spadek można zdefiniować jako:

$$s(x, y) = (f(x_0, y_0) - f(x, y)) / d(x_0, y_0, x, y) \quad (9.2)$$

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) .

Klasteryzacja oparta na algorytmie DBSCAN

Proste (standardowe) algorytmy klasteryzacji polegają na przesuwaniu po obrazie okno o wymiarach 1x1 cm w poszukiwaniu 3 lub 5 obiektów znajdujących się wewnątrz okna [51].

W algorytmie DBSCAN (*Density Based Spatial Clustering of Applications with Noise*) definicja klastra zostaje nieco zmieniona. Tutaj są to grupy obiektów połączonych zadaną gęstością.

Do definicji potrzebna są dwa parametry:

- *Eps* - promień sąsiedztwa punktu określonego wg 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.)

W implementacji przyjęto $Eps=0.5$ cm i $MinPts=3$ z możliwością zmiany w celu poszukiwania bardziej gęstych klastrow.

Definicja klastra oparta jest 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, w którym w sumie znajduje się co najmniej *MinPts* takich 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 leżących wewnątrz klastra także należą do klastra (maksymalność). Dla punktu należącego do klastra najpierw rozwijany jest cały klasteryzacji. Później algorytm przechodzi do analizy kolejnych punktów nie należących do żadnego klastra. Dokładny opis algorytmu można znaleźć w [50].


Algorytm DBSCAN okazał się szybszy i bardziej efektywny niż standardowa klasteryzacja. Jego złożoność obliczeniowa to ok. $k \cdot$ złożoność znalezienia Eps -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 $O(n \cdot m)$, gdzie n i m to wymiary obrazu. Zwykle $k^2 \ll n \cdot m$, ponieważ nawet przy niskim progu detekcji rząd wielkości k osiąga około 500, a wielkość macierzy obrazu to około 6000 x 4000 pikseli. W standardowych algorytmach czasem kwant przesunięcia okna jest większy - ok. 0.5 cm (złożoność jest niższa niż $O(n \cdot m)$). Jednak wtedy wyniki są mniej dokładne - nie są rozpatrywane wszystkie konfiguracje punktów i niektóre klastry mogą zostać pominięte, w przeciwieństwie do DBSCAN.

Inną zaletą algorytmu DBSCAN jest znajdowanie klastrów posiadających mniej więcej równomierne rozłożenie obiektów (rys. 9.3). Algorytm ten jest mniej czuły na łączenie klastrów (tzn. nieprawidłowej redukcji fałszywych wskazań - głównego problemu standardowej klasteryzacji) (rys. 9.4). 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 - przydatnej w dalszej weryfikacji detekcji.


Wyniki i dyskusja

Testy zostały przeprowadzone na 20 obrazach mammograficznych (ucyfrowionych z rozdzielczością 43,5 oraz 45,5 mikronów z 12-bitową głębią koloru). W zbiorze testowym było dużo ostrych i bardzo jasnych artefaktów. Te, które zostały wykryte podczas detekcji, zostały policzone jako fałszywie pozytywne klastry.

Podczas testów wybrano regiony zainteresowania zawierające rozległe obszary tkanki piersiowej budzące szczególne podejrzenie raka. Próg na etapie lokalizacji pojedynczych obiektów był modyfikowany ręcznie (ustalenie największej wartości, która jest korzystna ze względu na relację wskazań



Rys. 9.3: Standardowe algorytmy zaliczają do jednego klastra wszystkie czarne obiekty. DBSCAN wykrywa jako klaster zgrupowanie równomiernie rozrzuconych obiektów, nie dołączając artefaktów.




Rys. 9.4: Standardowe algorytmy zaliczają do jednego klastra wszystkie czarne obiekty. DBSCAN dzieli obiekty na dwie grupy wzdłuż przewodów mlecznych bez dołączania artefaktów.


prawdziwych do fałszywych). Czułość detekcji wyniosła około 83% ze średnią liczbą 2 fałszywie pozytywnych klastrów na obraz. Detekcja nie wykrywa szczególnie delikatnych mikrozwapnień znajdujących się na tle mocno zarysowanych struktur, np. bardzo wyraźnych włókien.

Ważnym ulepszeniem algorytmu jest opracowanie automatycznej metody regulacji wartości progu w fazie lokalizacji, zależnej od średniego poziomu jasności (gęstości tkanki) i struktury tekstury (kompozycji tkanki) w sąsiedztwie lokalizowanego obiektu. Przykładowe wyniki detekcji i rekonstrukcji kształtów pokazane są na rysunkach 9.5 i 9.6.

Zaproponowana metoda łączy kilka technik przetwarzania obrazów w celu uzyskania maksymalnej wydajności - wysokiej czułości detekcji oraz wstępnej minimalizacji najbardziej oczywistych wskazań fałszywych. Opisany algorytm przesunął akcent z etapu dokładnej detekcji pojedynczych mikrozwapnień (jest to powszechnie stosowane rozwiązanie), ku analizie całych skupisk. Naszym założeniem była wstępna detekcja nadmiarowego zbioru kandydatów, redukowanego w znacznym stopniu w procesie klasteryzacji. W kolejnym kroku niektóre obiekty ze zdegradowanym kształtem zostają odrzucone przez segmentację. Ponadto segmentacja oraz wygładzanie kształtu służy do jak najwierniejszego opisu obiektów w celu poprawy skuteczności kolejnych etapów algorytmu – redukcji fałszywych wskazań



Rys. 9.5: Wykryte klastry mikrozwapnień: (a) Oryginalny region wskazany przez radiologa (biały kontur). (b) Uwydatnione mikrozwapnienia. Kształty wykrytych mikrozwapnień (czarne kontury). (d) Kształt klastra.



Rys. 9.6: Wskazanie fałszywie pozytywne: (a) Oryginalny region - artefakty znajdujące się w pobliżu wyraźnego włókna. (b) Wzmocniony obraz. (c) Kształty wykrytych obiektów (czarne kontury). (d) Kształt fałszywie pozytywnego klastra (wzdłuż włókna).

poprzez analizę statystyczną tekstury i cech kształtu pojedynczych obiektów i całych klastrów - nad którymi obecnie pracujemy. Rezultaty uzyskane dla badań mammograficznych z różnych baz i ośrodków są zbliżone, co sugeruje uniwersalność opracowanej metody.

9.3 MammoViewer – narzędzie do wielorozdzielczej analizy obrazów medycznych

MammoViewer jest narzędziem służącym wspomaganiu diagnostyki obrazowej poprzez wykorzystanie efektywnych metod prezentacji, przetwarzania, analizy i interpretacji (rozumienia) obrazów. 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/pbargiel/cad/>.

Obok wielu opcji usprawniających przetwarzanie i analizę obrazów zaimplementowano rodzinę transformacji falkowych z szerokim doбором filtrów ortogonalnych i biortogonalnych, przekształcenia z falkami bez decymacji, falkami 2W w siatce heksagonalnej. Zoptymalizowano sposób wizualizacji rozkładu współczynników falkowych z możliwością korekcji histogramu, progowaniem i odsumowaniem w dziedzinie falkowej.

Procedury te wykorzystano do poprawy percepcji zmian patologicznych w mammografii, radiografii cyfrowej, obrazach CT i US [46]. Algoritmy wstępnego przetwarzania danych w wielu skalach pozwoliły zwiększyć efektywność automatycznej detekcji potencjalnych patologii (metody CAD) [44]. Testy kliniczne wykonano w celu detekcji mikrozwapnień oraz poprawy percepcji guzków i mikrozwapnień w mammogramach. Obecnie prowadzone są badania nad poprawą efektywności detekcji wczesnego zawału mózgu w badaniach CT.

9.3.1 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 dołączane są inne formaty danych użyteczne w różnych systemach obrazowania medycznego.

Prezentacja obrazów

Przy otwieraniu pliku danych obrazowych dostępny jest podgląd, zmniejszanie, zwiększanie i dopasowanie do wymiarów okna wyświetlanego obrazu oraz jego parametry. 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. Zaimplementowano standardowe opcje doboru kontrastu, jasności, prezentacji i wyrównywania histogramu, obrotów, zamiany bajtów, przeskalowania rozdzielczości, etc. W przypadku danych 2 bajtowych możliwe jest definiowanie parametrów okna przesuwającego określającego zakres wyświetlanych wartości pikseli (z maksymalną szerokością okna 8 bitów).

Przetwarzanie i analiza obrazów

Dostępne są następujące funkcje:

- operacje geometryczne;
- 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);
- wymiarowanie struktur (linijka);
- wizualizacja poziomów jasności wzdłuż linijki (profile);
- operacje na regionach zainteresowań, dodawanie i wyświetlanie opisu tekstowego obrazu (format PGX lub dodatkowe pliki tekstowe);
- operacje na dwóch obrazach (dodawanie, odejmowanie itp.);
- aproksymacja histogramu funkcjami różnych rozkładów;
- ekstrakcja regionów z obrazu z obliczaniem cech kształtu i tekstury każdego z regionów.

9.3.2 Wielorozdzielcza analiza obrazów

Prezentacja, przetwarzanie i analiza informacji obrazowej w wielu skalach, z podziałem na podpasma częstotliwościowe zachowujące orientację przestrzenną oraz kierunkową pozwala znacznie efektywniej wspomagać diagnostykę obrazową [47].


MammoViewer umożliwia:

- transformację falkową z wyborem filtrów, liczby skal, zerowaniem wybranych podpasm;
- adaptacyjne progowanie w podpasmach z wyborem funkcji progowania, rekonstrukcją oraz wizualizacją obrazu różnicowego;
- wizualizację rozkładu współczynników falkowych z przeskalowaniem do pełnego zakresu wartości, wyrównywaniem rozkładu współczynników w podpasmach (rys. 9.7);
- transformację bez decymacji w wielu skalach (współczynniki falkowe dla każdego podpasma dają pełny obraz);
- transformację 2W na siatce heksagonalnej metodą liftingu z adaptacyjnym progowaniem;
- skalowalną filtrację Laplacian-of-Gaussian z tworzeniem ścieżek lokalnych maksimów dla obrazów po filtracji LoG w wielu skalach (rys. 9.8).

Większość implementacji wielorozdzielczych ma charakter nowatorski, z możliwością dostosowania parametrów przekształceń do konkretnych zastosowań.

9.3.3 Poprawa percepcji

Poprawa percepcji (rys. 9.9) polega na zwiększeniu lokalnego kontrastu i uwydatnieniu wybranych cech w regionach występowania patologii najlepiej bez wzmocnienia (z jednoczesną redukcją) szumu. Wykorzystując selektywność reprezentacji w wielu skalach MammoViewer poprzez prezentację rozkładu wartości współczynników falkowych pozwala lepiej zlokalizować patologie, dobrać parametry algorytmu progowania bądź uwydatniania np. małych współczynników. Modyfikacja współczynników w dziedzinie transformacji skutkuje (po rekonstrukcji) poprawą percepcji uwydatnionego sygnału użytecznego (np. mikrozwapnień, obszarów hypodensyjnych w CT).



Rys. 9.7: Analiza wielorozdzielcza w programie MammoViewer (GUI, rozkłady współczynników falkowych).


9.3.4 Metody detekcji patologii

Metoda lokalizacji, klasteryzacji i segmentacji nadmiarowego zbioru obiektów zainteresowania (potencjalnych mikrozwapnień) wykorzystuje 2 rodzaje dekompozycji: filtrację LoG z różną skalą na niskoczęstotliwościowej transformacie falkowej bez decymacji oraz przekształcenie falkowe. Ocena korelacji przestrzennych współczynników z różnych podpasm obu hierarchii wielorozdzielczych pozwala eliminować artefakty, przecięcia włókien efektywniej wyszukując mikrozwapnienia.


9.3.5 Metody diagnozy patologii

9.3.6 Kompresja i indeksowanie

Systemy indeksowania obrazów medycznych po zawartości są wykorzystywane do wspomagania diagnostyki poprzez stosowanie referencyjnych baz danych diagnostycznych. Wielorozdzielcza analiza obrazu ułatwia konstruowanie efektywnej reprezentacji kodowej obrazów oraz ekstrakcję cech porządkujących treść diagnostyczną w indeksach obrazowych. MammoViewer jest włączany obecnie w system kliniczny jako narzędzie efektywnej kompresji falkowej w badaniach nad optymalizacją falkowej przestrzeni cech w



Rys. 9.8: Użycie skalowalnych filtrów LoG i hierachii falkowej do wykrywania mikrozwapnień.



Rys. 9.9: Poprawa percepcji mikrozwapnień z wykorzystaniem falek bez decymacji (oryginał, uwydatnienie oraz dwa obrazy współczynników falkowych).

indeksowaniu i klasyfikacji mammogramów [44].

9.3.7 Zastosowania

9.3.8 Wnioski i kierunki dalszego rozwoju

Komputerowe wspomaganie diagnozy jest dziedziną ciągle intensywnie rozwijającą się. Powstały już wartościowe zaawansowane technologicznie rozwiązania, takie jak systemy detekcji zmian patologicznych w mammografii. Systemy te udoskonalają sposób diagnozowania (zwiększają skuteczność detekcji oraz usprawniają opiekę kliniczną). Połączenie CAD z mammografią cyfrową i PACS w sieci "szpitali bez murów, bez granic" ('mammogrid') tworzy nową jakość w mammografii [52].

Mimo tak dużego zainteresowania dziedziną CAD w badaniach piersi, ciągle jest jeszcze wiele do zrobienia. Przede wszystkim jest to komputerowe wspomaganie diagnozy – szacowanie prawdopodobieństwa złośliwości zmian patologicznych. Analiza złośliwości wymaga połączenia informacji z kilku obrazów mammograficznych (dwie standardowe projekcje, zdjęcia celowane oraz badania poprzednie) oraz obrazów z innych modalności (USG, MRI).

Wynikiem automatycznej diagnozy może być nie tylko wartość numeryczna, ale także wizualizacja przypadków najbardziej podobnych. Obecnie trwają prace nad tworzeniem dużych baz różnych badań piersi oraz inteligentnym ich przeszukiwaniem.

Bardziej szczegółowe cele, które stawia sobie zespół to:

- Modelowanie zmian patologicznych (analiza wielorozdzielcza, bazy skończonych wzorców 2W)
- Integracja w MammoViewer: normalizacja reprezentacji mammogramów (indeksacja, kompresja) + poprawa percepcji + automatyczna diagnoza
- Implementacja w systemach klinicznych (w ramach zawiązanej współpracy ze Szpitalem Wolskim i Centrum Onkologii), eksperymenty przy współudziale radiologów
- Współpraca MammoViewer z cyfrowym mammografem (Onkologia) oraz systemem telediagnostycznym i bazami referencyjnymi

Rozdział 10

Inne metody wspomagania radiografii cyfrowej

10.1 Ontologia

10.1.1 Pojęcie ontologii w filozofii

Historia ontologii zaczyna się w IV w p.n.e, kiedy Arystoteles stworzył system uniwersalnych kategorii (pod nazwą „metafizyka”) pozwalających poklasyfikować wszystkie istniejące byty. Sam termin ontologia wywodzi się z języka greckiego (greckie Ontos- byt, logos- słowo), i pojawił się po raz pierwszy na początku siedemnastego wieku w pracach niemieckich filozofów J. Clauberga i Ch. Wolfa gdzie oznaczał zamiennie wraz ze swoją starszą nazwą „metafizyka arystotelesowską teorię bytu [117]. Rozważania na temat ontologii pojawiają się również w pracach takich filozofów jak Gottfried Leibniz, Immanuel Kant, czy Bernard Bolzano [140].

Współcześnie Ontologią nazywa się jeden z podstawowych działów filozofii - teorię bytu. Problemy jakimi zajmuje się ontologia to: jak można wszystko poklasyfikować? Jakie klasy pojęć są niezbędne do opisu i wnioskowania na temat danego procesu ? Należy podkreślić, że Ontologia nie jest nauką wyjaśniającą mechanizmy funkcjonowanie świata, nie dotyczy też sposobu w jaki człowiek go postrzega [140].

10.1.2 Pojęcie ontologii w systemach informatycznych

Na początku lat dziewięćdziesiątych używany w filozofii termin ”ontologia” pojawił się w dziedzinie systemów informatycznych. Wraz ze zmianą dziedziny jego znaczenie uległo zmianie. Istnieje wiele definicji ontologii, w niniejszym opracowaniu ograniczono się do przedstawienia dwóch z nich.

Definicja Grubera

Klasyczna, najczęściej cytowana, a zatem subiektywnie najpopularniejsza definicja ontologii podana przez T. Grubera w 1993 roku [118, 119] stwierdza, że ontologia jest formalną specyfikacją wspólnej warstwy pojęciowej.

Definicja Grubera zakłada, że każdy deklaratywny formalizm opisujący daną dziedzinę musi opierać się na jej warstwie pojęciowej (ang. conceptualisation) w znaczeniu opisanym przez Genseretha i Nilssona w [120]. Warstwa pojęciowa to abstrakcyjny model zjawisk w ograniczonym wycinku rzeczywistości, otrzymany poprzez identyfikację istotnych pojęć z nim związanych. Oznacza to, że dla pewnej dziedziny zidentyfikowano występujące w niej pojęcia (obiekty, zdarzenia, stany itp.) i relacje pomiędzy nimi. Dla przykładu wynikiem bardzo pobieżnej ontologicznej analizy dziedziny medycyny są takie pojęcia jak: choroba, symptom, terapia i relacje pomiędzy nimi takie jak "choroba wywołuje symptomy", "terapia leczy choroby". Przymiotnik formalna oznacza, że model musi być czytelny dla maszyny, specyfikacja to wymóg jednoznacznego sformułowania definicji pojęć i relacji, określenie wspólna odnosi się do faktu, że wiedza zawarta w ontologii powinna być akceptowana przez ogół użytkowników. W [118] Gruber definiuje formalnie konceptualizację dziedziny jako (C, I, R, F, A) gdzie:

C — zbiór wszystkich pojęć opisujących dziedzinę,

I — zbiór obiektów istniejących w dziedzinie, nazywanych też instancjami klas,


R — zbiór relacji zdefiniowanych na zbiorze C ,

F — zbiór funkcji zdefiniowanych na zbiorze pojęć zwracających jako wynik działania jedno z pojęć należących do modelowanej dziedziny,

A — zbiór aksjomatów nakładających ograniczenia na możliwe w modelu znaczenia pojęć, relacji i funkcji.

Niewątpliwe zalety definicji Grubera, to ogólność i prostota, ale wysuwano wobec niej szereg zarzutów i wątpliwości [121, 122, 123]. Najpoważniejszy zarzut dotyczy oparcia definicji ontologii na koncepcji warstwy pojęciowej. Termin ten wywodzi się z epistemologii (odrębnej dziedziny filozofii - teorii poznania) i dotyczy sposobu spostrzegania świata przez obserwatora, a modelując dziedzinę należy dążyć do maksymalnie obiektywnego jej przedstawienia [123]. Przyjęcie konceptualizacji w sensie zaproponowanym przez Genseretha i Nilssona w [120] prowadzi do uznania dwóch różnych konfiguracji klocków za dwie różne konceptualizacje dziedziny (rys. 10.1).

Obszerną dyskusję tego problemu, sięgającą do filozoficznych podstaw interpretacji relacji opisano w [121, 122].



Rys. 10.1: Dwie warstwy pojęciowe "świata klocków", czy dwa różne widoki dziedziny? Rysunek na podstawie [6].

W [123] poddano w wątpliwość zasadność umieszczenia w definicji ontologii wymogu współdzielenia wiedzy. Czy model zbudowany na potrzeby tylko jednej aplikacji nie ma prawa do nazywania się ontologią [123]? Budowa ontologii jest zawsze związana z konstrukcją słownika zawierającego zbiór formalnych definicji pojęć będących opisem modelowanej dziedziny. Słownik ten w definicji Grubera jest zawarty tylko *implicite*. Interpretację ontologii jako słownika reprezentującego wiedzę o danej dziedzinie opisano w [132].

Definicja Maedche

Współczesna definicja ontologii podana przez Maedche w 2002 roku [124], nie korzysta z kontrowersyjnego pojęcia warstwy pojęciowej, i oddziela strukturę samej ontologii od struktury opisującego ją leksykonu. Wg Maedche ontologię definiują dwa zbiory, zbiór O określający strukturę ontologii, oraz zbiór L zawierający strukturę opisującego ją leksykonu. Struktura ontologii definiująca pojęcia i występujące między nimi relacje ma postać $O = \{C, R, Hc, Rel, A\}$ gdzie:

C — stanowi zbiór wszystkich pojęć zdefiniowanych w modelu,

R — jest zbiorem nietaksonomicznych relacji (zwanymi właściwościami, slotami lub rolami), definiowanych jako nazwane połączenie między pojęciami,

Hc — stanowi zbiór taksonomicznych relacji pomiędzy pojęciami,

Rel — zdefiniowane nietaksonomiczne relacje pomiędzy pojęciami,

A — zbiór aksjomatów.

Struktura leksykonu ma postać $L = \{Lc, Lr, F, G\}$ gdzie:

Lc - definicje leksykonu dla zbioru pojęć,

Lr - definicje leksykonu dla zbioru relacji,

F - referencje dla pojęć,

G - referencje dla relacji.

W definicji Maedchea ontologię tworzą taksonomia pojęć i semantyczna interpretacja terminów użytych do ich opisu. Dlatego tłumaczenie terminów występujących w ontologii z jednego języka narodowego na drugi nie zmienia struktury pojęciowej samej ontologii.


Podsumowanie

Na początku lat dziewięćdziesiątych, kiedy powstawały pierwsze ontologie [142, 143, 144, 145] jako podstawowe powody ich tworzenia wymieniano:

1. Systematyzacja i objaśnienie struktury wiedzy w danej dziedzinie [132]
2. Umożliwienie i ułatwienie współdzielenia struktury wiedzy i informacji w danej dziedzinie zarówno przez ludzi jak i systemy komputerowe [118, 132, 146]
3. Umożliwienie i ułatwienie ponownego użycia wiedzy (knowledge reuse) zarówno przez ludzi jak i systemy komputerowe [118, 132, 146]

Dzisiaj podstawowymi powodami konstrukcji modeli ontologicznych są ich sieciowe zastosowania. Na zakończenie omówienia pojęcia ontologii warto podkreślić charakterystyczne, często mylnie interpretowane jej cechy (zobacz rys. 10.2):

1. Ontologii nie należy utożsamiać z katalogiem czy taksonomią obiektów w danej dziedzinie. Ontologia dostarcza przesłanek pozwalających je budować [140, 122].
2. Ontologia związana jest z obiektem, a nie z jego subiektywnym odbiorem [140, 122]
3. W ontologii relacje (zależności) między obiektami nie są opisywane funkcyjnie [140]
4. Istnieje wiele ontologii – nie jest możliwe stworzenie jednej ogólnej ontologii [140]



Rys. 10.2: Ogólne ontologie różnią się między sobą w klasyfikacji nawet najbardziej ogólnych pojęć. Rysunek na podstawie [141].

10.1.3 Budowa ontologii - metodologie

Podstawowe metodologie budowy modeli ontologicznych

Sytuację w dziedzinie budowy modeli ontologicznych najtrafniej podsumowują autorzy [125] stwierdzając, że w obecnie konstrukcja ontologii ma więcej wspólnego z opartą na doświadczeniu inżynierią niż z nauką, ale że istniejące metodyki stanowią niepodważalnie duży wkład na drodze do powstania spójnego podejścia do projektowania ontologii. Przegląd doświadczeń różnych grup projektowych nabytych przy konstruowaniu ontologii opisano w [125, 126]. Nie ma jak dotąd jedynej, zalecanej przez wszystkich metody budowania ontologii [125]. W niniejszym opracowaniu ograniczono się do podania źródeł opisujących podstawowe metodologie, wyliczenia ich etapów i krótkiego komentarza dotyczącego faz budowy modelu ontologicznego.

- Metoda KBSI IDEF5 (1994) [127] opracowana przez Knowledge Based Systems Incorporation składa się z nast. etapów:
 1. Cel i zakres – określenie celu zawiera zbiór kryteriów określających go i wymagania stawiane ontologii. Zakres definiuje ograniczenia i części modelu, które muszą być zrealizowane.
 2. Zbieranie danych — uzyskanie danych koniecznych do budowy

ontologii przy użyciu typowych technik akwizycji wiedzy, tj. analizy tekstów, protokołów i wywiadów z ekspertami.

3. Analiza danych – ontologia powstaje jako produkt analizy zebranych danych
 4. Stworzenie wstępnego modelu — stworzenie prototypu ontologii, zawierającego prototypy pojęć, ich własności i łączących je relacji
 5. Udoskonalanie i zatwierdzanie – prototyp ontologii jest iteracyjnie udoskonalany i testowany. Do struktur ontologii są poddawiane aktualne dane i rezultat jest porównywany z założoną strukturą.
- Metoda TOVE — TOronto Virtual Enterprise (1995) [128] - metodologia tworzenia ontologii związana z konkretną dziedziną zastosowań - modelowanie przedsiębiorstwa
 1. Scenariusze motywacyjne – punkt wyjścia stanowi zbiór trudnych do rozwiązania problemów w przedsiębiorstwie (w danej dziedzinie), które ontologia ma rozwiązać. Problemy mogą być podane w formie przykładów.
 2. Pytania kompetencyjne — wymagania stawiane ontologii (powstałe w oparciu o punkt 1.), opisane jako nieformalne pytania, na które ontologia ma dostarczyć odpowiedzi.
 3. Specyfikacja terminologii — formalne zdefiniowanie obiektów, atrybutów i relacji tworzących ontologię.
 4. Specyfikacja aksjomatów — zdefiniowanie zbioru aksjomatów które specyfikują definicje terminów i ograniczeń ich interpretacji, najczęściej przy użyciu logiki pierwszego rzędu.
 5. Faza oszacowania modelu, która ocenia kompetencję modelu w rozwiązywaniu zadań postawionych w punkcie 1.
 - Metoda EMA - Enterprise Model Approach (1996) [129] - metodologia tworzenia ontologii również związana z modelowaniem przedsiębiorstwa
 1. Identyfikacja celu - określenie celu ontologii i poziomu formalizacji na jakim powinna być ona opisana.
 2. Identyfikacja zakresu - określenie zakresu informacji, które mają być włączone do ontologii (np. za pomocą scenariuszy motywacyjnych jak w TOVE), stworzenie listy istotnych pojęć, skreślenie nieistotnych i ich synonimów.

3. Stworzenie formalnych definicji pojęć wyszczególnionych w punkcie 2.
 4. Oszacowanie stworzonej ontologii. Ten etap może spowodować powtórne wykonanie etapów 2 i 3.
- Metonologia (1997) [130]
 1. Specyfikacja - identyfikacja celu ontologii. Należy opisać : użytkowników, scenariusze użytkowania, wymagany stopień formalizacji, oraz zakres ontologii tzn zbiór reprezentowanych terminów, ich charakterystykę i wymaganą dokładność.
 2. Faza akwizycji wiedzy częściowo realizowana jest na etapie pierwszym. Nie jest zalecana żadna konkretna metoda, podkreśla się jednak znaczenie analizy tekstów z danej dziedziny i akwizycję wiedzy od eksperta.
 3. Budowa warstwy pojęciowej modelu (ang. conceptualisation) terminologia z danej dziedziny jest przedstawiana w postaci hierarchii istotnych pojęć ich atrybutów, relacji pomiędzy nimi przy użyciu nieformalnej reprezentacji.
 4. Integracja w celu umożliwienia kompatybilności z innymi ontologiami powinny zostać dołączone definicje z innych ontologii. Wskazana ontologia Ontolingua.
 5. Implementacja ontologię należy zapisać w formalny sposób (wskazane narzędzie Ontolingua)
 6. Oszacowanie - ten etap wyróżniono jako szczególnie ważny. W [130] zamieszczono zbiór zaleceń pozwalających na wykrycie niekompletności, niespójności i redundancji w modelu.
 7. Etap dokumentacji stworzenie dokumentacji wykonanych działań.

Budowa ontologii – wskazówki pragmatyczne

Wskazówki są następujące:

1. W wszystkich metodologiach początkiem budowy modelu jest określenie jego celu i zakresu. Taki początek pracy jest użyteczny na dalszych etapach pracy, ponieważ ułatwia akwizycję wiedzy i dostarcza kryteriów dla oszacowania modelu. Wskazany w TOVE sposób określania celu i zakresu modelu (scenariusze motywacyjne) jest zbyt mocno związany z konkretną dziedziną zastosowań - modelowanie przedsiębiorstwa i nie poleca się go przy budowie ontologii z innej dziedziny.

2. Wszystkie metodologie zawierają etap akwizycji wiedzy. Mimo, że w niektórych metodologiach jest on wyodrębniony jako osobny etap budowy modelu, w praktyce odbywa się przez cały cykl życiowy ontologii.
3. Żadna z metodologii nie dostarcza technik pozwalających choćby pół-automatycznie identyfikować istotne w ontologii pojęcia ograniczając się do ogólnego stwierdzenia, że należy w tym celu korzystać z istniejących metod akwizycji wiedzy, oraz że pojęcia w ontologii powinny być maksymalnie zbliżone to obiektów (fizycznych lub logicznych) i relacji w opisywanej dziedzinie.
4. Budowa ontologii jest procedurą iteracyjną opartą na udoskonalaniu wstępnego, stworzonego na pewnym etapie pracy modelu.
5. Wszystkie metodologie zawierają etapy oszacowania modelu i jego utrzymania.

Poniżej przedstawiono fazy projektu mającego na celu stworzenie ontologii. Należy podkreślić, że nie jest to próba stworzenia nowej metodyki, a jedynie pragmatyczna synteza proponowanych podejść. Fazy są następujące:

1. Cel i zakres ontologii
2. Akwizycja wiedzy
3. Budowa ontologii
 - (a) Identyfikacja istotnych w modelu pojęć (klas, atrybutów)
 - (b) Budowa hierarchii pojęć/klas
 - (c) Budowa definicji klas i atrybutów
 - (d) Specyfikacja ograniczeń
 - (e) Formalizacja aksjomatów (jeśli model je zawiera)
 - (f) Budowa bazy wiedzy modelu - tworzenie instancji klas
4. Ocena wyników modelowania
5. Wdrożenie (poza niniejszym opracowaniem)
6. Utrzymanie (poza niniejszym opracowaniem)

Krótkie omówienie wybranych faz budowy ontologii

Cel i zakres ontologii Jednym z najprostszych i jednocześnie skutecznych sposobów na określenie zakresu i poziomu szczegółowości ontologii jest metoda "pytań o znajomość rzeczy" (ang. competency questions) [131]. Na początku pracy należy stworzyć listę pytań, na które musi odpowiedzieć baza wiedzy modelu. Lista ta jest również bardzo użyteczna przy szacowaniu modelu. Ad. Akwizycja wiedzy - potencjalnymi źródłami wiedzy są:

1. Wywiady z ekspertami
2. Obserwacja i interpretacja pracy eksperta
3. Słowniki z modelowanej dziedziny
4. Publikacje z modelowanej dziedziny
5. Inne ontologie

Budowa ontologii Etap akwizycji wiedzy jest punktem wyjścia do etapu właściwej budowy modelu tj. konstruowania hierarchii pojęć oraz tworzenia ich definicji. Należy pamiętać, że mimo zapisu tych etapów w postaci listy wykonanie tych czynności szeregowo w praktyce nie jest możliwe. Muszą one być wykonywane równolegle. Należy pamiętać, że każda relacja może być też modelowana jako pojęcie. Znalezienie odpowiedzi na pytanie jakie pojęcie powinno stanowić klasę, jakie atrybut a jakie relację często zależy od docelowej aplikacji. W [129] opisano trzy podejścia do budowy hierarchii klas:

1. Z góry w dół (ang. top-down) - Startuje się od najogólniejsze pojęcia w opisywanej dziedzinie, nadrzędnego dla wszystkich pojęć w modelu. Daje to dobrą kontrolę stopnia szczegółowości, ale jednocześnie prowadzi do włączenia do ontologii zbyt wielu klas nadrzędnych, których istnienie budzi wątpliwości końcowych użytkowników ontologii.
2. Z dołu do góry (ang. bottom-up) - daje dobrą kontrolę poziomu szczegółowości, wadą tego podejścia są trudności w określaniu nadklas dla znacząco różnych pojęć.
3. Od środka (ang. middle-out) najczęstszy w praktyce i zalecany w [129] sposób konstruowania hierarchii klas. Zaczyna się od pojęć, najważniejszych z punktu widzenia projektu, następnie w miarę potrzeb dokonuje atomizacji, czy też generalizacji.

Ocena wyników modelowania przegląd technik Oszacowanie ontologii jest tematem ważnym z dwóch powodów. Przede wszystkim twórcy ontologii muszą mieć możliwość efektów swojej pracy i podjęcia decyzji o skorygowaniu błędnych etapów budowy modelu. Drugim powodem jest istnienie dzisiaj bibliotek ontologii. Ich potencjalni użytkownicy powinni mieć możliwość oceny, która z ontologii najlepiej odpowiada ich potrzebom. Metody szacowania ontologii można podzielić na dwie podstawowe grupy: ocena ontologii jako całości lub ocena tylko jej wybranego poziomu. W niniejszym opracowaniu ograniczono się do podania literatury dotyczącej szacowania ontologii jako całości. Są to :

1. porównanie ocenianej ontologii z tzw. "złotym standardem" (tzw. "wzorcową ontologią") [146]
2. ocena ontologii na podstawie wyników działania aplikacji do której budowy została użyta [147]
3. porównanie ontologii ze źródłem danych (zbiorem dokumentów opisujących dziedzinę) na podstawie którego powstała [148]
4. oszacowanie (przez ekspertów z danej dziedziny), które ma na celu stwierdzenie na ile dobrze model spełnia wymagania określone przez swój cel, zakres np. w postaci pytań o znajomość rzeczy [149]

10.1.4 Edytor ontologii Protege-2000

Narzędzia formalizacji ontologii to klasa programów nazywanych "edytorami ontologii" umożliwiających zapis modelu w formie czytelnej dla komputera, tzn. formalizację, przeglądanie, modyfikację i wizualizację. Istnieje ich obecnie kilkadziesiąt. Opis i ocenę najbardziej znanych można znaleźć w [136]. Spośród opisanych tam programów wybrano edytor Protege-2000 (rys. 10.3). Edytor ontologii Protege-2000 został stworzony 15 lat temu w Departamencie Informatyki Medycznej Uniwersytetu Stanford. Jest to proste a jednocześnie efektywne narzędzie tworzenia pojęciowych modeli dziedzin wiedzy (modeli ontologicznych). Początkowo był to specjalistyczny program wspomagający akwizycję wiedzy dla medycznych systemów ekspertowych. Obecnie jest używany do tworzenia modeli z różnych dziedzin (od medycyny i genetyki po elektronikę, geografię czy awiację. Może służyć zarówno do tworzenia samych ontologii, jak również na ich podstawie Baz Wiedzy. Jest narzędziem darmowym, typu open-source, językiem implementacji jest Java. Edytor Protege-2000 pozwala użytkownikowi na:

1. Stworzenie modelu dziedziny poprzez zdefiniowanie klas pojęć istotnych w modelu, ich hierarchii, atrybutów i wzajemnych relacji;


2. Definiowanie i personalizowanie formularzy służących do budowy bazy wiedzy w oparciu definicje klas;
3. Budowę bazy wiedzy - tworzenie instancji uprzednio zdefiniowanych klas modelu;
4. Zapis modelu w wybranym formacie: XML, RDF, OWL lub HTML. Tak zapisana ontologia może być przedmiotem dalszego przetwarzania.

Model wiedzy edytora ontologii Protge-2000

Model wiedzy użyty w Protge-2000 jest oparty na ramach będących podstawowymi składnikami tworzonego modelu [138]. Za twórcę ram [139] uważa się Minskyego, który użył tej metody reprezentacji wiedzy do rozpoznawania obrazów. Nazwał on ramą strukturę danych opisującą obiekt, w którym mieszczą się wszystkie typowe i oczekiwane informacje, a także przypuszczenia o obiekcie. Minsky oparł swój pomysł na analizie zachowania człowieka znajdującego się w nowej sytuacji i otoczeniu, ale mającego o niej pewne wcześniejsze wyobrażenia. Według [139] człowiek wydobywa wówczas z pamięci określoną strukturę danych (ramę) i konfrontuje nową sytuację z wiedzą wówczas niej zawartą. Gdy człowiek zetknie się z nowym obiektem wówczas jego reakcją będzie próba zapamiętania go i określenia jego cech. Jest to równoważne wykreowaniu nowej ramy.

W ramowych systemach reprezentacji wiedzy przez pojęcie/klasę rozumie się zbiór obiektów o wspólnych właściwościach (atrybutach). Pojęcia reprezentowane są przez ramy zawierające sloty opisujące właściwości pojęcia. Systemy reprezentacji wiedzy oparte na ramach są pojęciowo proste, a ich taksonomiczna hierarchia pojęć jest intuicyjnie zrozumiała dla ekspertów z danej dziedziny.

Podstawowe struktury służące do budowy ontologii w edytorze Protege-2000 tj.: metaklasy, klasy, sloty, i fasety są ramami. Zbiory metaklas, klas, slotów i faset i ograniczeń są rozłączne. Modelowany obiekt może być metaklasą, klasą, atrybutem lub fasetą. Te cztery typy ram grają różne role w procesie budowy modelu i akwizycji wiedzy. [136]. Baza wiedzy Protege-2000 zawiera model i instancje poszczególnych klas wraz z właściwymi wartościami dla atrybutów.




Rys. 10.3: Organizacja interfejsu edytora Protg-2000. Główne okno programu zawiera menu pozwalające na zarządzanie modelem i zakładki umożliwiające stworzenie zapisanie, modyfikację i wizualizację modelu dziedziny. Lewy panel zawiera pierwszy poziom hierarchii klas modelu mammografii.


Podstawowe składniki ontologii tworzonej w Protege-2000 na przykładzie fragmentu ontologii mammografii

Reasumując ontologia w stworzona w Protege-2000 przy użyciu przy użyciu ramowego modelu wiedzy składa się z następujących obiektów:


1. Slotów — zbioru właściwości dla wszystkich klas modelu. Sloty są obiektami globalnymi w modelu, definiowanymi niezależnie od klas. Utworzone w modelu sloty można przyłączyć do klasy, określają one wtedy jej własności. Każdy slot jest instancją metaklasz STANDARD-SLOT i dziedziczy jej właściwości: nazwa, dziedzina, typ wartości, kardynalność, oraz wartości: minimalna, maksymalna, domyślna i wzorcowa (rys. 10.4).
2. Metaklas, klas i ich instancji – metaklasa to klasa, której instancje są również klasami. Klasy i ich instancje odpowiadają pojęciom w modelowanej dziedzinie, są zorganizowane w strukturę hierarchiczną określającą dziedzinie cech (rys. 10.5 i 10.6).
3. Faset — opisujących własności slotów i nakładających na nie ograniczenia
4. Aksjomatów – pozwalających nakładać dodatkowe (niemożliwe do zrealizowania przy pomocy faset) ograniczenia na wartości atrybutów klas



Rys. 10.4: Zakładka Slots w modelu mammografii. Lewa część panelu pokazuje fragment zbioru wszystkich atrybutów zdefiniowanych w modelu. Prawa część panelu służy do określenia właściwości (facet), w tym przypadku jest wyróżniony w lewym panelu atrybut kształt-terminy.



Rys. 10.5: Zakładka Classes w modelu mammografii. Prawa część panelu fragment hierarchii klas modelu, lewa część definicja wyróżnionej klasy GUZ O GŁADKICH ZARYSACH.



Rys. 10.6: Zakładka Instances. Prawa część panelu - instancja klasy GUZ O GŁADKICH ZARYSACH.

Bibliografia

- [1] Red. J. Dziukowa (1998) "Mammografia w diagnostyce raka sutka". Warszawa, Bel Corp.
- [2] D. Kufe, R. Pollock et al (2003) "Cancer Medicine 6". BC Decker; <http://www.ncbi.nlm.nih.gov/books/bv.fcgi?rid=cmed>
- [3] American College of Radiology (ACR). "Breast imaging reporting and data system (BI-RADS)". 3rd ed. Reston, VA: ACR; 1998.
- [4] A. Przelaskowski, P. Surowski (2002) "Metody optymalizacji reprezentacji medycznych danych obrazowych do archiwizacji i transmisji telemedycznej". Projekt badawczy KBN 7T11E03920.
- [5] C. Beam, P.M. Layde, D. Sullivan (1996) "Archives of Internal Medicine". 156: 209-213.
- [6] Y. Jiang (2000) "Classification of Breast Lesions from Mammograms". W: Handbook of Medical Imaging, Academic Press, 341-357.
- [7] S. Liu (1999) "The analysis of digital mammograms: Spiculated tumor detection and normal mammogram characterization". Ph. D. Thesis, Purdue University.
- [8] S. Destounis (2004) "Computer-Aided Detection and Second Reading Utility and Implementation in a High-Volume Breast Clinic". Applied Radiology 33(9):8-15.
- [9] S.A. Butler, R.J. Gabbay, D.A. Kass, D.E. Siedler, K.F. O'Shaughnessy, R.A. Castellino (2004) "Computer-Aided Detection in Diagnostic Mammography". American Journal of Roentgenology 183(5):1511-1515.
- [10] H.D. Cheng, X. Cai, X. Chen, L. Hu, X. Lou (2003) "Computer-aided detection and classification of microcalcifications in mammograms: a survey", Pattern Recognition 36: 2967-2991.
- [11] <http://www.breastcancer.org>
- [12] <http://www.mrml.org>

- [13] <http://sprojects.mmi.mcgill.ca/mammography/>
- [14] <http://www.r2tech.com>
- [15] <http://www.icadmed.com>
- [16] <http://www.scanis.com>
- [17] <http://www.healthimaging.com> RSNA 2005 in review: "CAD: Expanding Applications and Accuracy".
- [18] L.J.W. Burhenne, S.A. Wood, C.J. DOrsi, S.A. Feig, D.B. Kopans, K.F. OShaughnessy, E.A. Sickles, L. Tabar, C.J. Vyborny, R.A. Castellino (2000) "Potential Contribution of Computer-aided Detection to the Sensitivity of Screening Mammography". *Radiology* 215: 554-562.
- [19] T.W. Freer, M.J. Ulissey (2001) "Screening Mammography with Computer-aided Detection: Prospective Study of 12,860 Patients in a Community Breast Center". *Radiology* 220: 781-786.
- [20] R.F. Brem, et al. (2003) "Improvement in sensitivity of screening mammography with computer-aided detection: A multiinstitutional trial". *AJR Am J Roentgenol* 181: 687-693.
- [21] A. Malich, et al. (2003) "Influence of breast lesion size and histologic findings on tumor detection rate of a computer-aided detection system". *Radiology* 228: 851-856.
- [22] S. Ciatto, et al. (2003) "Comparison of standard reading and computer aided detection (CAD) on a national proficiency test of screening mammography". *Eur J Radiol* 45: 135138.
- [23] P.E. Shile, J.A. Guingrich (2003) "Detecting "missed" breast cancers: A comparison of CAD systems". *Appl Radiol, Supplement*, 1-3.
- [24] A. Malich (2001) "Tumor detection rate of a new commercially available computer-aided detection system". *Eur Radiol* 11: 2454-2459.
- [25] J.A. Baker, E.L. Rosen, J.Y. Lo, E.I. Gimenez, R. Walsh, M.S. Soo (2003) "Computer-Aided Detection in Screening Mammography: Sensitivity of Commercial CAD Systems for Detecting Architectural Distortion". *AJR* 181: 1083-1088.
- [26] M.L. Giger (2004) "CAD in Breast Imaging". SCAR TRIP Session, Vancouver, Canada.
- [27] S.M. Lai, X. Li, W.F. Bishof (1989) "On techniques for detecting circumscribed masses in mammograms". *IEEE Trans. Medical Imag.* 8(4): 377-386
- [28] J. Dengler, S. Behrens, J.F. Desaga (1993) "Segmentation of microcalcifications in mammograms". *IEEE Trans. Medical Imag.* 12(4): 774-786.

- [29] M.F. Salfity, G.H. Kaufmann, P. Granitto, H.A. Ceccatto (2000) "Automated detection and classification of clustered microcalcifications using morphological filtering and statistical techniques". Instituto de Fisica Rosario, Argentina.
- [30] M. Nieniewski (1999) "Morphological method for extraction of microcalcifications in mammograms for breast cancer diagnosis". *Machine Graphics and Vision* 8(3): 427-448.
- [31] B. Betal, N. Roberts, G.H. Whitehouse (1997) "Segmentation and numerical analysis of microcalcifications on mammograms using mathematical morphology". *British J. of Radiology* 70: 903-917.
- [32] S. Quadrades, A. Sacristan (2001) "Automated extraction of microcalcifications BI-RADS numbers in mammograms". *Proc. IEEE ICIP*, 289-292.
- [33] R.N. Strickland, H.I. Hahn (1996) "Wavelet transforms for detecting microcalcifications in mammograms". *IEEE Trans. Medical Imag.* 15(2), 218-229.
- [34] T.C. Wang, N.B. Karayiannis (1998) "Detection of microcalcifications in digital mammograms using wavelets". *IEEE Trans. Medical Imag.* 17(4), 498-509 .
- [35] H.D. Cheng, Y.M. Lui, R.I. Freimanis (1998) "A novel approach to microcalcification detection using fuzzy logic thechnique". *IEEE Trans. Medical Imag.* 17(3), 442-450.
- [36] M. Ustymowicz, M. Nieniewski (2002) "Badania wykrywalności mikrozwapnień w mammogramach o wysokim stopniu subtelności na przykładzie bazy danych DDSM". *Materiały konferencyjne z IV Sympozjum Naukowego TPO*, 324-339.
- [37] H. Li, K.J.R. Liu, S.C.B. Lo (1997) "Fractal modeling and segmentation for the enhacement of microcalcifications in digital mammograms". *IEEE Trans. Medical Imag.* 16(6), 785-798.
- [38] W.M. Diyana, J. Larcher, R. Besar (2003) "A comparison of clustered microcalcifications automated detection methods in digital mammogram". *IEEE Trans. Medical Imag.*
- [39] J.K. Kim, H.W. Park (1999) "Statistical textural features for detection of microcalcifications in digitized mammograms". *IEEE Trans. Medical Imag.* 18(3), 231-238.
- [40] T. Netsch, H.O. Peitgen (1999) "Scale-space signatures for the detection of clustered microcalcifications in digital mammograms". *IEEE Trans. Medical Imag.* 18(9), 774-786.
- [41] K.S. Woods (1994) "Automated image analysis techniques for digital mammography". Ph.D. Thesis, University of South Florida.

- [42] S. Yu, L. Guan (2000) "A CAD system for the automatic detection of clustered microcalcifications in digitized mammogram films". *IEEE Trans. Medical Imag.* 19(2): 115-125.
- [43] A. Wróblewska, A. Przelaskowski (2003) "System automatycznej detekcji i klasyfikacji mikrozwapnień w cyfrowej mammografii". *Elektronizacja* 3: 8-11.
- [44] A. Wróblewska, P. Boniński, A. Przelaskowski, M. Kazubek (2003) "Segmentation and feature extraction for reliable classification of microcalcifications in digital mammograms". *Optoelectronics Review* 11(3): 227-235.
- [45] A. Wróblewska, A. Przelaskowski (2004) "Detection of microcalcifications with shape marking in digital mammograms". *SCAR Scientific Abstract Book*, Vancouver: 18-20.
- [46] P. Bargieł, A. Przelaskowski, P. Boniński, A. Wróblewska (2005) "Perception improvement of chosen pathological changes in mammograms and US images". 14th Int. Conf. Medical Physics ICMP 2005, Nuremberg, Germany
- [47] "Special Issue on Wavelets in Medical Imaging". *IEEE Trans. Medical Imag.* 22(3), 2003.
- [48] <http://marathon.csee.usf.edu/Mammography/Database.html>
- [49] P. Bargieł, A. Przelaskowski, A. Wróblewska (2004) "Wavelet methods in improving the detection of lesions in mammograms". *Int. Conf. on Computer Vision and Graphics*, Poland, Warszawa.
- [50] M. Ester, H.P. Kriegel, J. Sander, X. Xu (1996) "A density-based algorithm for discovering clusters in large spatial databases with noise". *Proc. 2nd Int. Conf. on Knowledge Discovery and Data Mining*.
- [51] M.J. Lado, P.G. Tahoces, A.J. Mendez, M. Souto, J.J. Vidal (1999) "A wavelet-based algorithm for detecting clustered microcalcifications in digital mammograms". *Med. Phys.* 26: 1294-1305.
- [52] L. Fratt (2004) "Breast CAD Comes of Age", *RSNA*.
- [53] M.P. Sampat, M.K. Markey, A.C. Bovik (2005) "Computer-Aided Detection and Diagnosis in Mammography", *Handbook of Image and Video Processing* (2nd edition): 1195-1217.
- [54] W.P. Kegelmeyer, J.M. Pruneda, P.D. Bourland, A. Hillis, M.W. Riggs, M.L. Nipper (1994) "Computer-aided mammographic screening for spiculated lesions". *Radiology* 191, 331-337
- [55] N. Karssemeijer, G.M. Brake (1996) "Detection of stellate distortions in mammograms". *IEEE Trans. Medical Imag.* 15

- [56] S.L. Liu, C.F. Babbs, E.J. Delp (2001) "Multi-resolution detection of spiculated lesions in digital mammograms". *IEEE Trans. Image Processing* 10
- [57] H.D. Li, M. Kallergi, L.P. Clarke, V.K. Jain, R.A. Clark (1995) "Markov random field for tumor detection in digital mammography". *IEEE Trans. Medical Imag.* 14, 565-576
- [58] T. Matsubara, H. Fujita, T. Endo, K. Horita, M. Ikeda, C. Kido, T. Ishigaki (1996) "Development of mass detection algorithm based on adaptive thresholding technique in digital mammograms". *Digital Mammography*
- [59] H. Li, Y. Wang, K.J. Liu, S.C. Lo, M.T. Freedman (2001) "Computerized radiographic mass detection – part I: Lesion site selection by morphological enhancement and contextual segmentation". *IEEE Trans Medical Imag.* 20(4), 289-301
- [60] H. Kobatake, M. Murakami, H. Takeo, S. Nawano (1999) "Computerized detection of malignant tumors on digital mammograms". *IEEE Trans. on Medical Imag.* 18, 369-378
- [61] N. Petrick, H.P. Chan, B. Sahier, D. Wei (1996) "An adaptive density-weighted contrast enhancement filter for mammographic breast mass detection". *IEEE Trans. Medical Imag.* 15, 59-67
- [62] W.E. Polakowski, D.A. Cournoyer, S.K. Rogers, M.P. DeSimio, D.W. Ruck, J.W. Hoffmeister, R.A. Reiners (1997) "Computer-aided breast cancer detection and diagnosis of masses using difference of Gaussians and derivative-based feature saliency". *IEEE Trans. Medical Imag.* 16, 811-819
- [63] D. Brzakovic, X.M. Luo, P. Brzakovic (1990) "An approach to automated detection of tumors in mammograms", *IEEE. Trans Medical Imag.* 9, 233-241
- [64] W. Qian, L. Li, L. Clarke, R.A. Clark, J. Thomas (1999) "Comparison of adaptive and non adaptive cad methods for mass detection". *Academic Radiology* 6, 471-480
- [65] B.R. Groshong, W.P. Kegelmeyer (1996) "Evaluation of a Hough transform method for circumscribed lesion detection". *Digital Mammography*
- [66] I. Christoyanni, E. Dermatas, G. Kokkinakis (2000) "Fast detection of masses in computer-aided mammography". *IEEE Signal Processing Magazine* 17(1), 54-64
- [67] I.N. Bankman, T. Nizialek, I. Simon, O.B. Gatewood, I.N. Weinberg, W.R. Brody (1997) "Segmentation algorithms for detecting microcalcifications in mammograms", *IEEE Trans. Inform. Techn. Biomed.* 1(2), 141-149

- [68] H. Qi, W.E. Snyder (1998) "Lesion detection and characterization in digital mammography by Bezier histograms". *Proc. 20th Annual Inter. Conf. IEEE Engineering in Medicine and Biology Society* 20(2)
- [69] A. Przelaskowski (2002), "Falkowe metody kompresji danych obrazowych". *Prace Naukowe, Elektronika*, z. 138, Oficyna Wydawnicza Politechniki Warszawskiej.
- [70] W. Sweldens (1994) "The lifting scheme: a construction of second generation wavelets". *Univ. So. Carolina preprint*.
- [71] W. Sweldens (1996) "The lifting scheme: a custom-design construction of biorthogonal wavelets". *Appl. Comput. Harmonic Analysis* 3:186-200.
- [72] I. Daubechies, W. Sweldens (1998) "Factoring wavelet transforms into lifting steps". *J. Fourier Anal. Appl.*, 4(3):247-269.
- [73] E. Piętka: *Zintegrowany system informacyjny w pracy szpitala*, Wydawnictwo Naukowe PWN, Warszawa, 2004
- [74] S. Molloy, Y. Zhou, G. Wamsely: *Scatter-Glare Estimation for Digital Radiographic Systems: Comparison of Digital Filtration and Sampling Techniques*, *IEEE Trans. Med. Imaging*, vol. 17, no. 6, December 1998
- [75] P. C. Johns, M. J. Yaffe: *X-ray characterisation of normal and neoplastic breast tissue*, *Physics in Medicine and Biology*, 32:675 - 695, 1987
- [76] R. Highnam, M. Brady: *Mammographic Image Analysis*, Kluwer Academic Publishers, 1999
- [77] D. R. Dance, G. J. Day: *Computation of scatter in mammography by Monte Carlo methods*, *Physics in Medicine and Biology*, 29:237 - 247, 1984
- [78] J. R. Cameron, J. G. Skofronick: *Medical Physics*, A Wiley-Interscience Publication, 1978
- [79] R. Highnam, M. Brady, B. J. Shepstone: *Computing the scatter component of mammographic images*, *IEEE Trans. Med. Imaging*, 13:301 - 313, June 1994
- [80] S. Naimuddin, B. Hasegawa, C. Mistretta: *Scatter-glare correction using a convolution algorithm with variable weighting*, *Medical Physics*, 14:330 - 334, 1987
- [81] J. Seibert, J. Boone: *X-ray scatter removal by deconvolution*, *Medical Physics*, 15:567 - 575, 1994 13] N.-S. Chang, K.-S. Fu,
- [82] N.-S. Chang, K.-S. Fu: *Query-by-pictorial-example*, *IEEE Trans. Software Eng.* SE 6 (6) (1980) 519-524.

- [83] P.M. Kelly, M. Cannon, D.R. Hush: *Query by image example: the Candid approach*, Proceedings of the of SPIE Conference on Storage and Retrieval for Image and Video Databases III, vol. 2420, 1995, pp. 238248.
- [84] A. Pentland, R.W. Picard, S. Sclaroff: *Photobook: tools for content-based manipulation of image databases*, Int. J. Comput. Vis. 18 (3) (1996) 233254.
- [85] W.Y. Ma, Y. Deng, B.S. Manjunath: *Tools for texture- and color-based search of images*, Proceedings of the of SPIE Conference on Human Vision and Electronic Imaging II, vol. 3016, San Jose, CA, 1997, pp. 496507.
- [86] C. Carson, M. Thomas, S. Belongie, J.M. Hellerstein, J. Malik *Blobworld: a system for region-based image indexing and retrieval*, Proceedings of the Third International Conference On Visual Information Systems (VISUAL99), no. 1614 in Lecture Notes in Computer Science, Springer-Verlag, Amsterdam, The Netherlands, 1999, pp. 509516.
- [87] S. Antani, L.R. Long, G.R. Thoma: *A biomedical information system for combined content-based retrieval of spine X-ray images and associated text information*, Proceedings of the Third Indian Conference on Computer Vision, Graphics and Image Processing (ICVGIP 2002), Ahamdabad, India, 2002.
- [88] R. Jain: *Workshop report: NSF workshop on visual information management systems*, SPIE Storage and Retrieval for Image and Video Databases, 1999.
- [89] R. Jain, A. Pentland, D. Petkovic: *NSF-ARPA workshop on visual information management systems*, 1995.
- [90] M. Flickner, H. Sawhney et al.:
- [91] , IEEE Comput. Mag., 28:23-32, 1995.
- [92] J. R. Bach, C. Fuller et al.: *The Virage image search engine: An open framework for image management*, SPIE Storage and Retrieval for Image and Video Databases, 1996.
- [93] J. Dowe: *Content-based retrieval in multimedia imaging*, SPIE Storage and Retrieval for Image and Video Databases, 1993.
- [94] MPEG-7: *Context and objectives (v.5)*, 1997.
- [95] www.hl7.org
- [96] W. Niblac, Barber et al.: *The QBIC project Querying images by content using color, texture and shape*, SPIE Storage and Retrieval for Image and Video Databases, 1994.
- [97] H. Tamura, S. Mori, T. Yamawaki: *Texture features corresponding to visual perception*, IEEE Trans. on Sys. Man. and Cyb., SMC-8, 6:460-473, 1978.

- [98] W. Equitz, W. Niblack: *Retrieving images from a database using texture algorithms from the QBIC system*, IBM Research Report, 1994.
- [99] T.M. Lehmann, M.O. Gld et al.: *Content-based image retrieval in medical applications for picture archiving and communication systems*, SPIE Conference on Medical Imaging, 2003.
- [100] B. Revet: *DICOM Cook Book for Implementations in Modalities*, Philips Medical Systems, 1997.
- [101] H. Muller, N. Michoux, D. Brandon, A. Geissbuhler: *A review of content-based image retrieval systems in medical applications clinical benefits and future directions*, International Journal of Medical Informatics, 2004.
- [102] M.O. Gld, M. Kohnen, D. Keysers et al.: *Quality of DICOM header information for image categorization*, International Symposium on Medical Imaging, 2002.
- [103] S. Antani, L.R. Long, G.R. Thoma: *A biomedical information system for combined content-based retrieval of spine X-ray images and associated text information*, Third Indian Conference on Computer Vision, Graphics and Image Processing (ICVGIP 2002), 2002.
- [104] www.mrml.org
- [105] T. Deselaers, D. Keysers, H. Ney: *FIRE - Flexible Image Retrieval Engine: ImageCLEF 2004 Evaluation*, CLEF 2004, 2004.
- [106] L. Tabr, B. Vitak et al.: *Beyond randomized controlled trials. Organized mammographic screening substantially reduces breast carcinoma mortality*, Cancer, 91(9):1724 - 1731, 2001
- [107] K. Kerlikowske, D. Grady et al.: *Variability and accuracy in mammographic interpretation using the American College of Radiology Breast Imaging Reporting and Data System*, J Natl Cancer Inst 90(23):18019, 1998
- [108] M. Jenicek: *Foundations of Evidence-Based Medicine*. CRC Press, 2003.
- [109] E. Carson, C. Cobeli: *Modelling methodology for physiology and medicine*. Academic Press, 2001.
- [110] Xiao-Hua Zhou, Donna K. McClish, Nancy A. Obuchowski Statistical Methods in Diagnostic Medicine Wiley 2002
- [111] Alan Agresti Categorical Data Analysis Wiley 2002
- [112] J. Koronacki. J. Mielniczuk Statystyka dla inżynierów i przyrodników. WNT 2001

- [113] Sahai S., Khurshid A.: Statistics In epidemiology CRC 1996
- [114] Vuytsteke P., Schoeters E., "Image Processing in Computed Radiology", International Symposium on Computerized Tomography for Industrial Applications and Image Processing in Radiology, Berlin, Germany, March 15-17, 1999
- [115] Periaswamy S., "Detection of microcalcification in mammograms using hexagonal wavelets", 1996
- [116] Lane A., Shuler S., "Hexagonal wavelet processing of digital mammography", 2003
- [117] [1] Nowa Encyklopedia Powszechna (1996) t.4 str. 647, Wydawnictwo Naukowe PWN Warszawa 1996.
- [118] [2] Gruber T.: *A Transactional Approach to Portable Ontologies*, Knowledge Acquisition, 5 (2), 1993, pp-199-221
- [119] [3] Gruber T.: *What is Ontology*, <http://www-ksl.stanford.edu/kst/what-is-an-ontology.html>
- [120] [4] Gensereh M.R., Nilson N.J.: *Logical Foundations of Artificial Intelligence*, Morgan Kaufman, 1987
- [121] [5] Guariano, N., Giaretta, P.: *Ontologies and Knowledge Bases: Towards a Terminological Clarification*. In N.Mars (ed.) *Towards Very Large Knowledge Bases: Knowledge Building and Knowledge Sharing* 1995 IOS Press, Amsterdam:pp 25-32
- [122] [6] Guarino N.: *Formal Ontology in Information Systems*, Proceedings of FOIS98, Trento, Italy, 6-8 June 1998. Amsterdam, IOS Press , pp. 3-15
- [123] [7] Bassara A.: *I Weż Tu Dogadaj Sie*, Gazeta IT nr 1 (20), styczeń 2004
- [124] [8] Maedche A.: (2002) *Ontology Learning for the Semantic Web*, Boston : Kluwer Academic Publ., 2002, ISBN 0-7923-7656-0
- [125] [9] Pinto H.S., Martins P.J.: *Ontologies: How Can They Be Built?* , Knowledge and Information Systems (2004) 6: 441464
- [126] [10] Jones D., Bench-Capon T., Visser P.: *Methodologies for Ontology Development*, in Proceedings of IT&KNOWS of the 15th IFIP World Computer Congress, Budapest, Hungary, 1998
- [127] [11] *The IDEF5 Ontology Description Capture Method Overview*, KBSI Report, Texas , <http://www.idef.com> (sprawdzono 05.06.2006)
- [128] [12] Gruninger M., Fox M.S.: *Methodology for the Design and Evolution of Ontologies* IJCAI-95 Workshop on Basic Ontological Issues in Knowledge Sharing, Montreal , August 19-20 th.

- [129] [13] Uschold M.: *Building Ontologies :Towards a Unified Methodology*, Proceedings of Expert Systems 96 - 16 th Annual Conference on Expert Systems Cambridge, December 16-18 th
- [130] [14] Fernandez M., Gomez-Perez, A., Juristo N.: *METHONOLGY: From Ontological Art. towards Ontological Engineering*, AAAI-97 Spring Symposium on Ontological Engineering, Stanford University, March 24-26 th
- [131] [15] Gruninger M., Fox M.S.: *The Role of Competency Questions in Enterprise Engeenering*, IFIP WG5.7 Workshop on Benchmarking Theory and Practice, Trondheim, Norway
- [132] [16] Chandrasekaran, B., Josephson, J.R., Benjamins V.R.: *What Are Ontologies, and Why We Need Them ?*, 1999 IEEE Intelligent Systems pp 20-26
- [133] [17] Guarino N.: (1997) *Understanding, Building and Using Ontologies* (1997) Int. Journal of Human-Computer Studies 1997 (46) pp: 293-310
- [134] [18] Tamma V.: (2002) *An Ontology Model Supporting Multiple Ontologies for Knowledge Sharing*, Thesis of University of Liverpool 2002 <http://www.csc.liv.ac.uk/~valli/Publ/html> (sprawdzono 07.06.2006)
- [135] [19] Gomez-Perez A.: (1994) *Some Ideas and Examples to Evaluate Ontologies*, Technical Report KSL-94-65, Knowledge Systems Laboratory, Stanford 1994
- [136] [20] Denny M.: (2004) *Ontology Tools Survey*, <http://www.xml.com/pub/a/2004/07/14/onto.html> (sprawdzono 08.06.2006)
- [137] [21] Noy, N.F., Musen, M.A., Mejino, Jr. J.L.V. and Rosse, C.: (2002) *Pushing the Envelope: Challenges in a Frame-Based Representation of Human Anatomy*, SMI Technical Report – SMI-2002-0925 <http://www.citeseer.ist.psu.edu/noy02pushing.html> (sprawdzono 08.06.2006)
- [138] [22] Noy, N.F., Fergerson, R.W., and Musen, M.A.: (2000) *The knowledge model of Protege-2000: Combining interoperability and flexibility*. In Proc. EKAW 2000. <http://citeseer.ist.psu.edu/noy01knowledge.html> (sprawdzono 08.06.2006)
- [139] [23] Minsky M.: *Framework for Representing Knowledge*, The Psychology of Computer Vision, P.Winston (Ed.), McGraw-Hill, 1975, <http://wcb.media.mit.edu/~minsky/papers/Frames/frames.html> (sprawdzono 08.06.2006)
- [140] [24] Smith B.: chapter *Ontology* in L.Floridi (ed.) Blackwell Guide to the Philosophy of Computing and Information, Oxford:Blackwell, 2003 pp-155-166

- [141] [25] Friedman Noy N., Hafner D.D.: *The State of the Art in Ontology Design a Survey and Comparative Review*, AI Magazine, 18(3):53-74, 1997 http://www2.enel.ucalgary.ca/People/for/Lectures/SENG209-22/PDF/AAAI_Ontology-Design.pdf (sprawdzono 10.06.2006)
- [142] [26] Lenat D.B., Guha R.V.: *Building Large Knowledge Based Systems: Representation and Inference* in the CYC Project Reading Mass.: Addison-Wesley, 1990, [http:// www.opecyc.org/](http://www.opecyc.org/) (sprawdzono 10.06.2006)
- [143] [27] Miller G.A.: *WORDNET: An On Line Lexical Database*, Int.Journal of Lexicography 3-4:pp235-312 <http://wordnet.princeton.edu> (sprawdzono 10.06.2006)
- [144] [28] GUM- Generalized Upper Model, <http://www.fb10.uni-bremen.de/anglistk/langpro/webpace/jb/gum/index.htm>
- [145] [29] Sowa J.F.: *Top-Level Ontological Categories*, Int. Journal of Human-Computer Studies 43(5-6):669-685, 1995
- [146] [30] Maedche, A., Staab, S.: *Measuring similarity between ontologies*. Proc. CIKM 2002. LNAI vol. 2473.
- [147] [31] Porzel, R., Malaka, R.: *A task-based approach for ontology evaluation*. ECAI 2004 Workshop Ont. Learning and Population. 2004
- [148] [32] Brewster C., et al.: *Data driven ontology evaluation*. Proceedings of Int. Conf. on Language Resources and Evaluation, Lisbon, 2004.
- [149] [33] Lozanotello, A., Gómez-Prez, A.: (2004) *Ontometric: A method to choose the appropriate ontology*. J. Datab. Mgmt., 15(2):118 (2004).