

# Koncepcje wspomaganie – wzmocnienie informacyjne

Materiały KWOD, A.Przelaskowski

- Definicje i opisy
- Historia i wizje rozwoju
- Schematy ogólne
- Wybrane przykłady (badania płuc, sutka, inne)



# Obrazowa diagnostyka medyczna

---

- Służy **rozpoznawaniu chorób** (potwierdzaniu ich istnienia, identyfikacji lub zaprzeczenia) na podstawie stwierdzonych objawów
  - Bazuje zasadniczo na symptomach pozyskanych z badań obrazowych, stwierdzonych na podstawie analizy cech zobrazowań pochodzących z różnych systemów - istotny jest jednak **cały obraz kliniczny**
  - Skutkuje konsekwencjami **decyzyjnymi** (opis - raport końcowy)
  - **Zróżnicowanie zastosowań**: może być silnie zintegrowana z innymi metodami diagnostycznymi lub niekiedy stosowana niezależnie, kontekst kliniczny, cel może być różnorodny (skrining, kontrolne, pełna diagnostyka, celowane, ocena/monitorowanie skutków leczenia, rehabilitacji itp.)
  - **Istotny wzrost skali zastosowań, zaawansowania technologicznego i funkcjonalnego, stopnia komputeryzacji obsługi oraz zestawu urządzeń wspomagających**
    - Większa skalowalność, specjalizacja, adaptacja, integracja
    - Wyraźna progresja skali zastosowań (rodzaj i liczba)
  - ...
-

# Użytkowanie informacji obrazowej – model aktywności diagnostów i klinicystów

- Pozyskiwanie informacji użytecznej diagnostycznie (sprawność posługiwania się narzędziami)
    - **Dobór źródeł** informacji (m.in. modalności obrazowania, parametryzacja, adaptacja do cech pacjenta i zadania klinicznego)
    - Wstępna ocena przydatności (m.in. kontrola jakości i wiarygodności obrazów)
    - Poprawa jakości/wydobywanie informacji (technologie systemów informacyjnych, inteligentne wspomaganie)
  - Analiza i rozumienie wymowy przekazu obrazowego, rozpoznanie i interpretacja symptomów (semantyka, modele wiedzy, umiejętności diagnostyczne)
    - Percepcja treści użytecznej
    - Ekstrakcja informacji diagnostycznej – anormalności i obszarów zainteresowania
    - Odczytanie wymowy zmian, ocena względem zasobów wiedzy, doświadczenia, okoliczności itd. (rozumienie – możliwie dogłębne, rezonans – synergia)
    - **Interpretacja** diagnostyczna – identyfikacja symptomów choroby, opis według protokołu
  - **Pragmatyka decyzji** i działań (model holistyczny, ustalenie znaczenia całościowej wymowy diagnostyki wobec określonego obrazu klinicznego)
    - Ustalenie konsekwencji obserwowanego obrazu klinicznego względem istniejących uwarunkowań i możliwości (odniesienie rozpoznanej choroby/stanu/rokowań do realnych możliwości leczenia)
    - Formułowanie decyzji i podjęcie konkretnych działań (rozszerzona diagnostyka, zabiegi, terapia)
-

# Rozmaitość form wspomaganiania

---

- Ewolucja form podpowiedzi
    - **Druga opinia**
    - Prescreening
    - Screening
    - Różny stopień **interakcji**
    - Rosnący udział automatyzacji oraz odwołań do zasobów referencyjnych
  - Istotne funkcje kontrolne
    - Ocena jakości/wiarygodności diagnostycznej obrazów, obiektywizacja interpretacji
    - Zapewnienie spójności i integralności danych w systemach informacyjnych (m.in. fuzja informacji obrazowej i klinicznej, korekta błędów)
    - Śledzenie/kreowanie logiki wnioskowania/postępowania (schematy, interakcje, wyjaśnianie)
  - Możliwości wspomaganiania
    - Ekstrakcja i identyfikacja **treści ukrytych** (zwiększenie zdolności postrzegania)
    - Porządkowanie, selekcja, wskazywanie ROI lub OOI, klasyfikacja komponentów informacji, opisywanie – **wyliczanie parametrów, aproksymacja**, porównywanie
    - Formowanie decyzji (różne kategorie, wariantowość, miary istotności, interakcje)
-

---

Ludzkie ograniczenia i szanse ...

# **BŁĘDY DIAGNOSTYKI**

---

# Modelowanie działań diagnosty - DOD


---

- Podstawowy model działania radiologa
    - Detekcja anormalności
    - Opis anormalności (analiza cech własnych, relacje, syntetyczna wymowa w schemacie: wrażenia-percepcja (postrzeganie)-wyjaśnianie-rozumienie)
    - Diagnoza, czyli interpretacja w odpowiednich kategoriach objaśniająco-decyzyjnych (poznanie w kategoriach obiektywnych sądów wraz z konsekwencjami)
  
  - Problemy/trudności
    - Brak standardów, czasami nawet konsensusu (brak stabilnych wzorców)
    - Silne zróżnicowanie zadań diagnostycznych
    - Duże zróżnicowanie umiejętności/doświadczeń
    - Istotna rola intuicji/subiektywizmu/odczuć
    - Rosnące znaczenie aktualizowanej wiedzy (duża rola doniesień, kongresów, ciągle inne przypadki), problem weryfikacji i adaptacji do nowych problemów (schematy)
    - Wzrost udziału techniki/informatyzacji w protokołach badań i gromadzeniu informacji (problem EbM)
-

# Błędy w radiologii ...

---

- Ponad 70 lat temu: znaczący poziom błędów radiologów (Garland49,59)
    - **30%** radiogramów płuc z patologią zostało przeoczonych (fałszywie ujemne)
    - **2%** nadinterpretowano (fałszywie dodatnie)
    - **20%** brak zgodności radiologów
  - **Dziś stopa błędu jest zbliżona** [Renfrew92, Berlin07]
    - **4%** błędów interpretacji w codziennej praktyce [Siegle98, Borgstede04]
    - Błędy percepcji (postrzegania) występują **4 razy częściej** od błędów poznawczych (interpretacji) [Kunt89] – **problem analizy wstępnej!**
    - Błędy przeoczenia (fałszywie ujemne) występują **5 razy częściej** niż błędy nadinterpretacji [Renfrew92] – **problem czułości!**
  - **Wniosek: wspomaganie skutecznie wyszukujące obszary/struktury podejrzane (detekcja anormalności)**
-





# Przyczyny błędów percepcji (postrzegania)

---

- w zakresie czynników postrzegania (indywidualnych)
    - NIEJEDNOZNACZNY OBRAZ POSTRZEGANIA - **zróźnicowanie percepcji** pojedynczych zmian przez obserwatorów, powodowanego subtelnością zmian, ograniczeniami postrzegania, zróźnicowaniem **właściwości narządu wzroku**
    - LUDZKI SUBIEKTYWIZM - naturalny **subiektywizm oceny, zmęczenie**, znużenie, monotonia, brak koncentracji, ale też **rutyna**, przyzwyczajenie, brak wystarczającej czujności, zdenerwowanie, **stres**
    - BRAK UWAGI - **syndrom "szczęśliwego oka"** (*happy eye syndrom*), kiedy to wykrycie jednej zmiany podejrzanej staje się przyczyną pominięcia innej (maleje czułość wyszukiwania kolejnych zmian)
    - BRAKI W DEFINICJI NORMY - **zmiennosc** struktury ciała i cech pacjenta, **nietypowosc przypadku** – duża zmienność anormalności, ograniczenia/zróźnicowanie sys. obrazowania, modeli patofizjologii, etiologii itp.
    - BRAK SCHEMATU OCENY – niejednoznaczności **formalnego modelu zachowań** obserwatora w procesie analizy obrazów, skutecznych metod obiektywizacji ludzkiego postępowania w tym procesie (problem *human equation* nierozwiązany)
    - **zawinione ludzkie** niedopatrzania, zaniedbania, złe przygotowanie (aspekty prawne)
  - w zakresie czynników środowiskowych
    - **ograniczenia technologii** obrazowania (jakościowe, fizyczne, sprzętowe, kadrowe)
    - nienajlepsza **organizacja warunków pracy** radiologa (czas, ergonomia, wygoda, ograniczenia czasowe, procedura oceniania, brak ciszy i spokoju, bałagan organizacyjny itd.)
-

# Przyczyny błędów interpretacji, problemy ogólne

---

- brak ustalonych wzorców patologii (bardzo zróżnicowane formy manifestacji patologii), niejednoznaczne kryteria odróżniania cech patologicznych, ich weryfikacji, względność ocen powodowana niepełnym obrazem badanej rzeczywistości
- brak (niedoskonałość) standaryzacji procesu opisu badań, jednolitych kryteriów i schematów oceny, obiektywnych i wymiernych form oceny
- konieczność podjęcia decyzji (brak decyzji jest też decyzją) w warunkach niepewności, różnego typu ograniczeń, w tym czasowych, braku pełnej informacji i jednoznacznych przesłanek, braku możliwości oceny powtórnej czy fachowej konsultacji
- rosnąca liczba danych coraz bardziej różnorodnych, niejednoznacznych, niezrozumiałych, wymagających trudnej i złożonej analizy oraz interpretacji przez diagnostę/eksperta

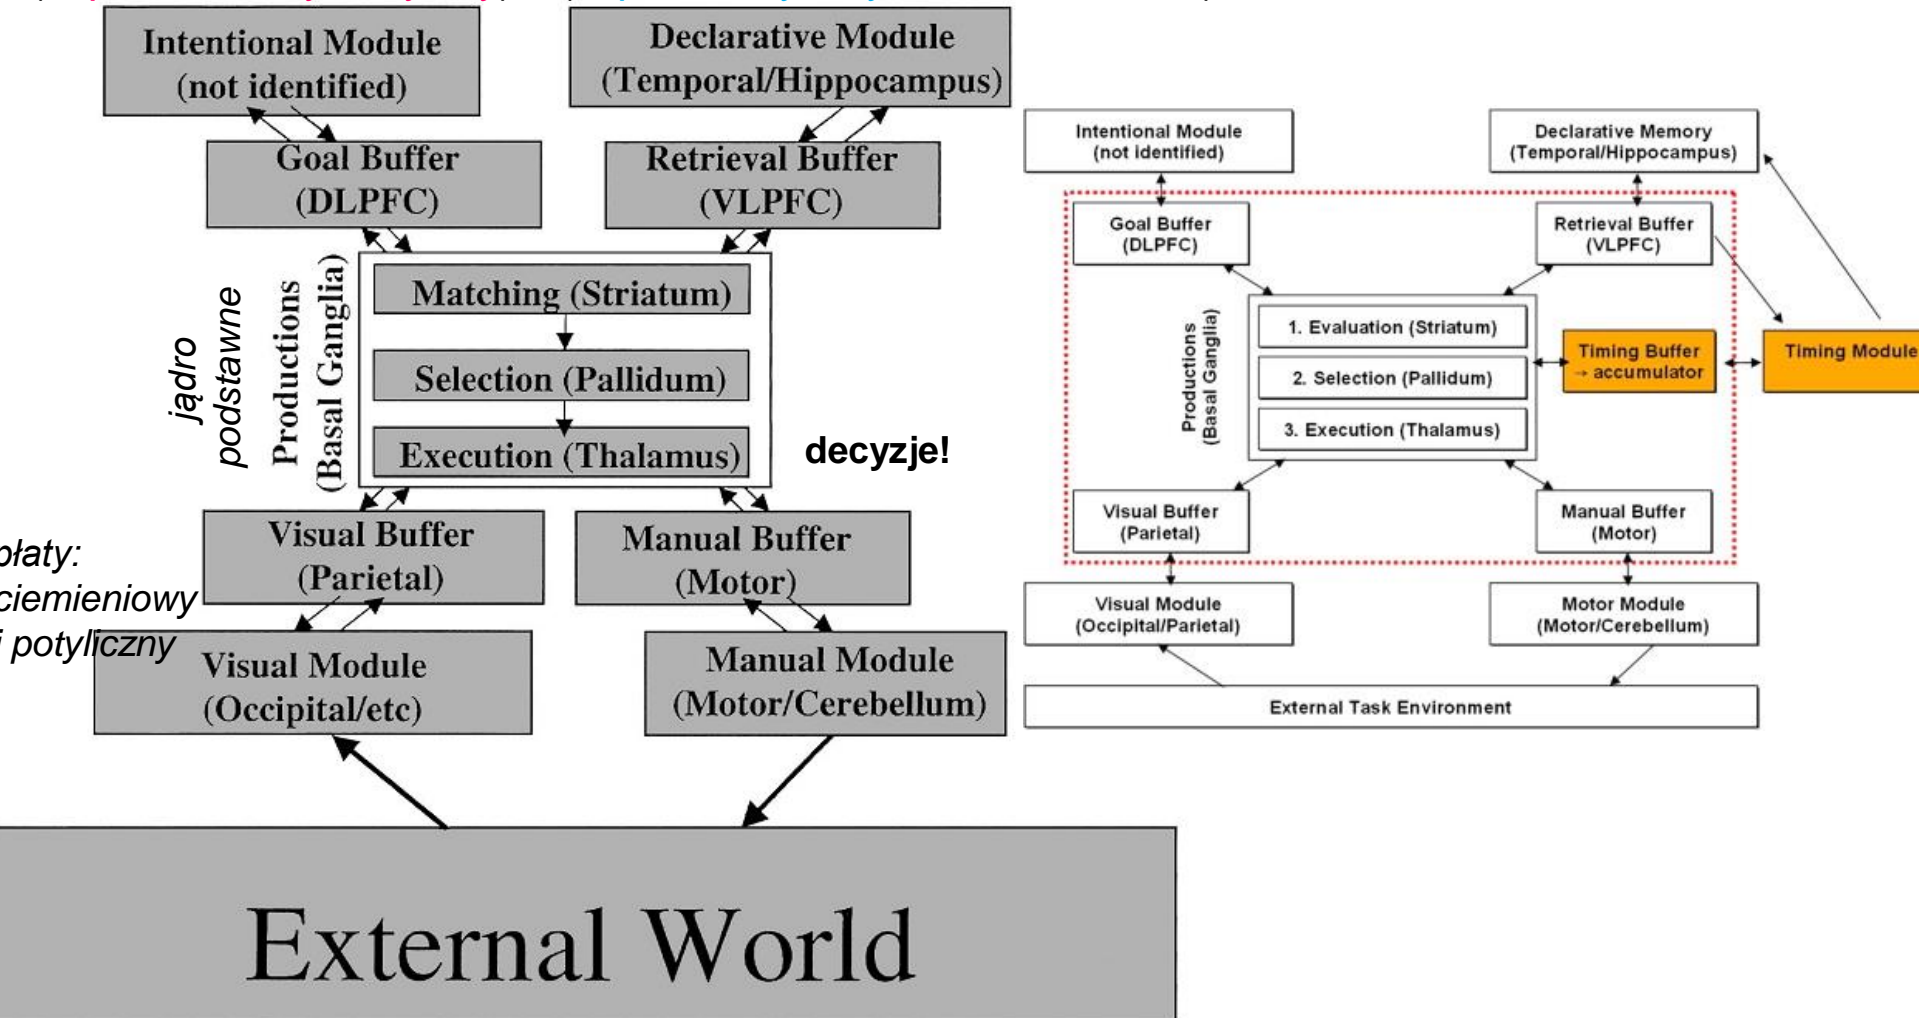
## Generalnie

- zadanie jest często bardzo złożone-skomplikowane, poszlakowe, przy niepełnej informacji, niejasnościach, niejednoznaczne, niestabilne, w pewnym stopniu losowe, o nieliniowej naturze
    - nieprzewidywalne ewentualności (konieczność kreatywnego i intuicyjnego myślenia, kojarzenia)
    - detekcja rzadkich nieregularności (osobliwości) przy braku stałej w czasie i przestrzeni zdolności percepcji
    - złożony, niejednoznaczny, nieprecyzyjny, „niepełny” model wiedzy, konieczność interpretacji treści, zmienne procedury oceny i podejmowania decyzji, a także form działania
    - czasowe zakłócenia niemal wszystkich elementów procesu wyjaśniania i decydowania
    - szczególna waga decyzji: istotna rola czasu i powagi problemu (szybkie, wymuszone, a przy tym odpowiedzialne decyzje)
    - pomiary/obserwacje dotyczą zwykle wąskiego wymiaru badanego zjawiska (**dziurka od klucza, góra lodowa**)
-

# Rozwiązanie problemów złożonych: procesy poznawcze – posiadanie wiedzy - aktywność

(aspekt twórczy, aktywny)

(aspekt statyczny, wiedza zastana)



---


*CAD czyli  
Informatywne wspomaganie  
zorientowane na diagnostę!*

**Różne scenariusze komputerowego wspomagania**


**METODY REDUKCJI LICZBY BŁĘDÓW  
DIAGNOSTYKI OBRAZOWEJ -  
POPRAWA SKUTECZNOŚCI  
DIAGNOZY/TERAPII**

---

# Metoda 1: skuteczne postrzeganie



# Problem ograniczonej skuteczności diagnostyki obrazowej



- Ciągłe problemy z użytecznością (czułością i rozróżnialnością) np. mammografii ...
- Artefakty, niejednoznaczność, mała specyficzność czyli przekłamania- USG, CT, rezonans...
- Konieczność fuzji różnych zobrazowań oraz informacji klinicznej, problem *big data*
- Nietypowy 'obraz' pacjenta (brak normalizacji), 'niestabilny' obraz patologii, brak adaptacji parametrów systemu, problem z powtarzalnością badań, niestabilność i nadmiarowość wskazań, niejasna relacja wskazań różnych systemów
- Zawodność sprzętu - kontrola jakości, nośniki, interfejsy, peryferia, zasoby, wizualizacje etc.
- Brak standardów wykorzystania narzędzi, obsługi, doboru profili itd.
- Zbytня złożoność, niezrozumienie nowych technologii, ich możliwości kontrolnych, sterowania, optymalizacji etc. (parametryzacja)
- Problem dostosowania do ciągle zmieniających się technologii ...
- Konieczność ciągłego kształcenia, weryfikacji, śledzenia rozwoju nauki/techniki ...

## Środki zaradcze

- **Doskonalenie (wzrost wiarygodności) technologii pomiaru i rekonstrukcji (adaptacyjna optymalizacja), a jednocześnie upraszczanie** form użytkowych obrazowania (integracja systemów obrazowania, automatyzacja, mobilność, lepsza semantyka wizualizacji, uzupełnianie obrazu tekstem, adaptacyjność, personalizacja itd.)
- Poprawa warunków pracy: wyjaśnianie służące rozumieniu, obiektywizacji, możliwości personalizacji działań i integracji decyzji, brak limitów czasowych w interpretacji badań obrazowych, ergonomia, wysoka jakość sprzętu itd.
- Większa informatywność systemów obliczeniowych (skuteczna ekstrakcja kluczowej informacji) ...

# Ciągłe *breaking news* – radiografia, fluoroskopia, angiografia i tomografia razem





**SIEMENS**

Multitom Rax - Twin Robotic X-ray scanner



# Metody redukcji błędów

- Pełna informacja i wiedza (przed)
  - wykorzystanie pełnej informacji klinicznej (uporządkowane, zweryfikowane, ustandaryzowane etc.)
  - wykorzystanie wcześniejszych badań radiologicznych lub raportów z tych badań
  - możliwość dodatkowych konsultacji, w tym telekonsultacji
  - wprowadzenie podwójnej, niezależnej oceny badań
- Uczyć się na błędach (po)
  - szczegółowa analiza (statystyczna, obliczeniowa) różnej kategorii błędów w badaniach retrospektywnych, z wyjaśnianiem i korygowaniem ich przyczyn
  - wypracowywanie skutecznych, obiektywizowanych, powtarzalnych technik oceny, zwiększenie możliwości korekty błędów (podpowiadacze, kontrola logiczna, etc)
  - kontynuacja i doskonalenie edukacji oraz szkoleń (e-edukacja, internet itd.)
  - lepsze przygotowanie organizacyjno-motywacyjno-mentalne ...





# Sposoby: doskonalenie rozpoznania

## ■ Przykład

- analiza retrospektywnej obrazów radiograficznych klatki piersiowej pacjentów z potwierdzonym później rakiem płuc, na których nie stwierdzono patologii – w **90% przypadków** można było dostrzec symptomy patologii

(Muhm J.R., Miller W.E., et al. (1983) Lung cancer detected during a screening program using four-month chest radiographs. Radiology 148:609-15)

- podobnie w retrospektywnej ocenie mammograficznej raka sutka – **75%**

(Harvey J.A., Fajardo L.L., Innis C.A. (1993) Previous mammograms in patients with impalpable breast carcinoma: retrospective vs. blinded interpretation. Am J Roentgenology 161:1167–72)

## ■ Przyczyny poprawy:

- inny schemat pracy – znana interpretacja: szuka się w obrazach znamion potwierdzonej patologii w odpowiednich miejscach lub względem określonych cech
- zawężone pole poszukiwań, dostosowane kryteria, ukierunkowane przekonanie
- wykorzystanie dodatkowych informacji dot. treści widocznej we wcześniejszym i późniejszym badaniu obrazowym itp.. (szerszy obraz kliniczny)


## ■ Nie zawsze nawet to skutkuje ...

*(po prostu nie widać!)*




# ASPECTS – Alberta Stroke Program Early CT Score

- Diagnostyka CT „pierwszej linii” ze względu na szybkość, powszechność i niskie koszty
- ASPECTS jest **10. punktową oceną ilościową** topograficzną skanów CT według ustalonego porządku regionów
- Jest to prosty, powtarzalny system klasyfikacji
  - bazujący na skrupulatnej, konsekwentnej analizie
  - o znaczącej wiarygodności
  - standaryzujący proces detekcji i raportowania symptomów wczesnego udaru niedokrwiennego
  - **pomocny we wspomaganie leczenia trombolitycznego** – nakierowany na decyzję
- Anormalność musi być widoczna przynajmniej **na dwóch sąsiednich warstwach** (unikanie efektu uśrednienia, przypadkowych korelacji)
- Wyznaczenie oceny: startujemy z 10pkt i odejmujemy 1 punkt za każdym razem, gdy w danym regionie pojawią się zmiany niedokrwienne
- Stąd norma ma 10 pkt, a bardzo rozległy udar – blisko 0pkt



# Szczególna ocena wybranych regionów



- Charakterystyka niedokrwiennej regionów: M1, M4 – kora przednia, M2, M5 – kora boczna i M3, M6 – kora ciemieniowa
- Ocena hipodensyjności w kolejnych czterech regionach: wstążka wyspy (I – insular ribbon), jądro ogoniaste (C – caudate nucleus); jądro soczewkowate (L – lentiform nucleus), torebka wewnętrzna (IC – internal capsule)
- Wszelkie zmiany niedokrwienne warstw CT **na poziomie głowy jądra ogoniastego** i poniżej (czyli I, C, L, IC) są oceniane w regionie zwojowym (*ganglionic*) razem z M1-3
- Niedokrwienne zmiany **powyżej poziomu głowy jądra ogoniastego** są oceniane w regionie nad-zwojowym (*supraganglionic*) - M4-6
- Ograniczenia metody:
  - Dotyczy tylko regionów środkowej tętnicy mózgu
  - Słaba jakość (artefakty), zmiany związane z podeszłym wiekiem i pewne szczególne przypadki zmian ograniczają skuteczność metody



# Regiony precyzyjniej

The prognosis prediction significance of Hounsfield unit value for stroke patients treated by intravenous thrombolysis

Zhengqi Zhu,<sup>1</sup> Ru Zhang,<sup>1</sup> Kaixuan Ren,<sup>1</sup> Ruochen Cong,<sup>1</sup> Xiangyang Zhu,<sup>2</sup> Li Zhu,<sup>1</sup> and Tianle Wang<sup>2\*</sup>



# Procedura ASPECTS

- Analiza obrazów z optymalnym oknem
  - Zawężenie okna do 35-45 HU na poziomie 35-45 HU



WW-80 WL-40



WW-70 WL-40



WW-60 WL-40



WW-50 WL-40



WW-40 WL-40





WW-35 WL-35

- Obiektywizacja ocen
- Efektem wzrost czułości przy zachowanej specyficzności ocen
- Ocena wszystkich dostępnych warstw badania CT (obejmujących obszar zasilany tętnicą środkową mózgu MCA)

# Użyteczność ASPECTS

- Przykłady ocen
- U pacjentów, u których ocena według ASPECTS wyniosła powyżej 7 punktów **uzyskano 3-krotnie większe** prawdopodobieństwo, że po leczeniu trombolitycznym będą funkcjonalnie niezależni od otoczenia [Hill,2003]



*utrata mowy,  
porażenie połowicze*




Figure 3. 59 year-old female with aphasia and right-sided hemiplegia. CT-ASPECTS = 8, DWI-ASPECTS = 1.



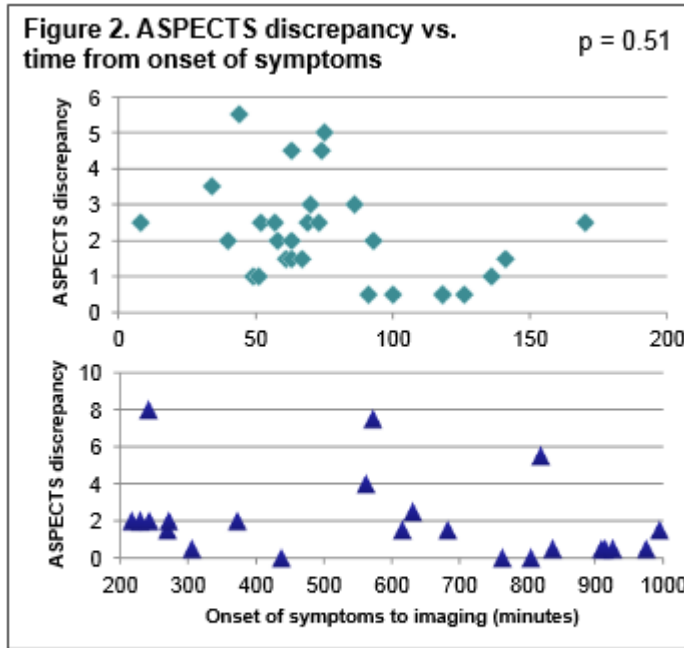


Figure 4. 95 year-old male with slurred speech, right facial droop. CT-ASPECTS = 10, DWI-ASPECTS = 9. Arrow indicates M2 lesion.

# Rozbieżności ocen



**Table 2. Inter-rater agreement ( $\kappa$ ) by region/modality**

Region	CT	DWI
M1	0.14	0.53
M2	0.36	0.65
M3	0.70	0.66
M4	0.63	0.86
M5	0.27	0.28
M6	0.33	0.52
Caudate	0.31	0.53
Lentiform nucleus	0.11	0.58
Insula	0.46	0.75
Internal capsule	0.32	0.46

**Table 3. Sensitivity and specificity of CT-ASPECTS by region**

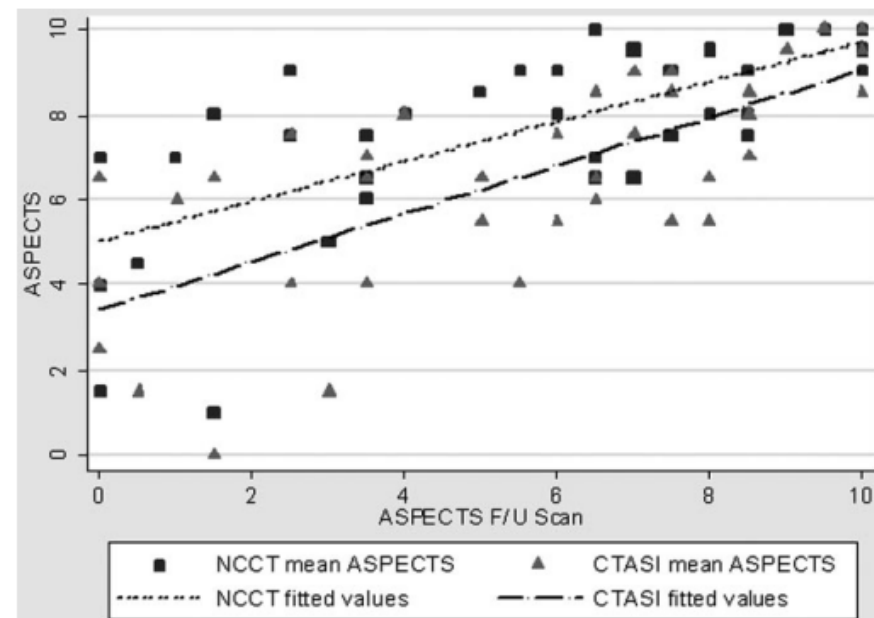
Region	Sensitivity	Specificity
M1	17.0	95.0
M2	43.4	89.4
M3	19.0	97.0
M4	27.0	95.2
M5	26.0	86.5
M6	17.3	88.8
Caudate	52.2	96.8
Lentiform nucleus	44.2	85.5
Insula	40.7	93.9
Internal capsule	21.4	93.5

rs for CT-ASPECTS was calculated for each of the 10 ASPECTS regions using DWI as the gold standard. <math>\kappa < 0.2</math> poor, moderate, <math>\kappa < 0.5</math>.

**Figure 3.** Scatter plot of mean ASPECTS scores for CTA-SI and NCCT compared with final ASPECTS on follow-up imaging. The estimated lines are derived from simple linear regression equations and imply that there is a consistent difference between NCCT ASPECTS and CTA-SI ASPECTS regardless of final infarct volume.

## ASPECTS on CTA Source Images Versus Unenhanced CT Added Value in Predicting Final Infarct Extent and Clinical Outcome

Shelagh B. Coutts, MBChB; Michael H. Lev, MD; Michael Eliasziw, PhD;



# Najważniejsze: większa zgodność opinii

- Podstawowa zaleta ASPECTS: **zobiektywizowana procedura oceny**, która pozwala porównywać efekty obrazowania bardziej niezależnie od zmienności czynnika ludzkiego
- Miara: współczynnik kappa - określa stopień zgodności dwukrotnej oceny (pomiarów) tej samej zmiennej w różnych warunkach; m.in. porównuje się opinie dwóch ekspertów (odtworzalność) lub jednego z oceny dwukrotnej (powtarzalność)
  - Nieważony (Cohena) – zakres 0-1 (losowa zgodność – pełna zgodność)
  - Ważony – macierz wag z 1 na przekątnej, a poza z przedziału <0,1); przykład wag liniowych  $w_{i,j}$ :

$$\kappa = \frac{P_r - P_u}{1 - P_u}$$

1	0.75	0.5	0.25	0
0.75	1	0.75	0.5	0.25
0.5	0.75	1	0.75	0.5
0.25	0.5	0.75	1	0.75
0	0.25	0.5	0.75	1

$p_{i,}$  oraz  $p_{.,j}$ - sumy końcowe

$P_r = \sum_{i=1}^c \sum_{j=1}^c w_{i,j} p_{i,j}$   
 $P_u = \sum_{i=1}^c \sum_{j=1}^c w_{i,j} p_{i,} p_{.,j}$  - kolumn i wierszy tabeli obserwacji (kontyngencji)

TABLE 2: Pairwise interobserver agreement between independent observers for the 1/3 MCA territory rule and ASPECTS, with knowledge of the affected side

Observer Pairs	Balanced $\kappa^*$	
	1/3 MCA Territory (<1/3 vs >1/3)	ASPECTS (<7 vs >7)
Two stroke neurologists	.61	.85
Two neuroradiologists	.52	.89
Two radiology residents	.64	.71
A stroke neurologist and a neuroradiologist	.44	.61
A stroke neurologist and a neuroradiologist	.51	.63
A stroke neurologist and a radiology resident	.54	.75
A stroke neurologist and a radiology resident	.46	.56
A neuroradiologist and a radiology resident	.43	.75
A neuroradiologist and a radiology resident	.45	.67
A neuroradiologist and a stroke neurologist	.43	.67
A radiology resident and a stroke neurologist	.38	.83
A radiology resident and a stroke neurologist	.20	.60
A stroke neurologist and a neuroradiologist	.47	.71
A neuroradiologist and a radiology resident	.51	.83
A neuroradiologist and a radiology resident	.39	.63

\* Balanced kappa:  $\kappa > .80$  implies excellent reliability;  $.61 \leq \kappa \leq .80$  implies good reliability;  $.41 \leq \kappa \leq .60$  implies moderate reliability;  $.21 \leq \kappa \leq .40$  implies fair reliability;  $\kappa \leq .20$  implies poor reliability (26).

## Use of the Alberta Stroke Program Early CT Score (ASPECTS) for Assessing CT Scans in Patients with Acute Stroke

J. H. Warwick Pexman, Philip A. Barber, Michael D. Hill, Robert J. Sevick, Andrew M. Demchuk, Mark E. Hudson, William Y. Hu, and Alastair M. Buchan



# Przykład na zgodność ocen

<http://manuals.pqstat.pl/statpqpl:zgodnpl:nparpl:kappalpl>

W obrazie radiologicznym oceniano uszkodzenie wątroby w następujących kategoriach: brak zmian (1), zmiany łagodne (2), podejrzenie raka (3), rak (4). Oceny dokonywało dwóch niezależnych radiologów bazując na grupie 70 pacjentów. Chcemy sprawdzić zgodność postawionej diagnozy.

	brak zmian	zmiany łagodne	podejrzenie raka	rak
brak zmian	23	4	3	0
zmiany łagodne	2	12	5	2
podejrzenie raka	5	4	4	0
rak	1	2	1	2

Hipotezy:

$$\mathcal{H}_0 : \kappa = 0,$$

$$\mathcal{H}_1 : \kappa \neq 0.$$

Ze względu na to, że diagnoza wystawiona jest na skali porządkowej, właściwą miarą zgodności byłby ważony współczynnik Kappa.

Test istotności Kappa-Cohena	
Liczność - ilość par	70
Typ	ważona (wagi liniowe)
Współczynnik Kappa	0,390194
Błąd dla Kappa	0,090462
-95% CI dla współczynnika Kappa	0,212893
+95% CI dla współczynnika Kappa	0,567496
Błąd dla rozkładu Kappa	0,086638
Statystyka Z	4,503732
Wartość p (asymptotyczne)	0,000007


Test istotności Kappa-Cohena	
Liczność - ilość par	70
Typ	ważona (wagi kwadratowe)
Współczynnik Kappa	0,418658
Błąd dla Kappa	0,110945
-95% CI dla współczynnika Kappa	0,201208
+95% CI dla współczynnika Kappa	0,636107
Błąd dla rozkładu Kappa	0,118935
Statystyka Z	3,520052
Wartość p (asymptotyczne)	0,000431

# Koncepcja rozszerzona – Stroke Bricks

- Powiązanie układu naczyniowego (ukrwienie mózgu) z regionami efektów niedokrwienia – rozpoznania udaru, relacja:
  - a) obserwowany symptom neurologiczny (np. afazja – zaburzenie mowy)
  - b) przyczyna: deficyt naczyniowy (wszystkie struktury naczyniowe powyżej namiotu mózdzku)
  - c) region mózgu z upośledzeniem ukrwienia
  - d) obszar możliwych zmian martwiczych (weryfikowany w CT/DWI)
- Liczba punktów w skali 0-15 (każdy deficytowy region plus 1pkt)
- Oceny dokonuje neurolog (ogólnie klinicysta) jako sugestią dla radiologa
- Sugestia ta może być wykorzystana w CAD



Table 1. Common neurological symptoms and corresponding *Stroke Bricks* segments.

Symptom	Regions	Symptom	Regions
gaze palsy or total gaze paresis	M1 M4	homonymous hemianopsia	P M2 M3
expressive (motor) aphasia	M1 M4	upper limb paresis	M5 CR BGIC
hemineglect	A3 M6	lower limb paresis	A2 CR BGIC
sensory aphasia	M3 M6	upper limb sensory loss	M5 CR BGIC T
disorientation	A1 M1 M4	lower limb sensory loss	A2 CR BGIC T
central facial nerve palsy	M5 CR BGIC	face hemisensory loss	M5 CR T
central hypoglossal nerve palsy	M5 CR BGIC	dysarthria	A1 M1 M4 BGIC



Zaburzenia mowy, grymas twarzy, porażenie nerwów, niedowład kończyn ...

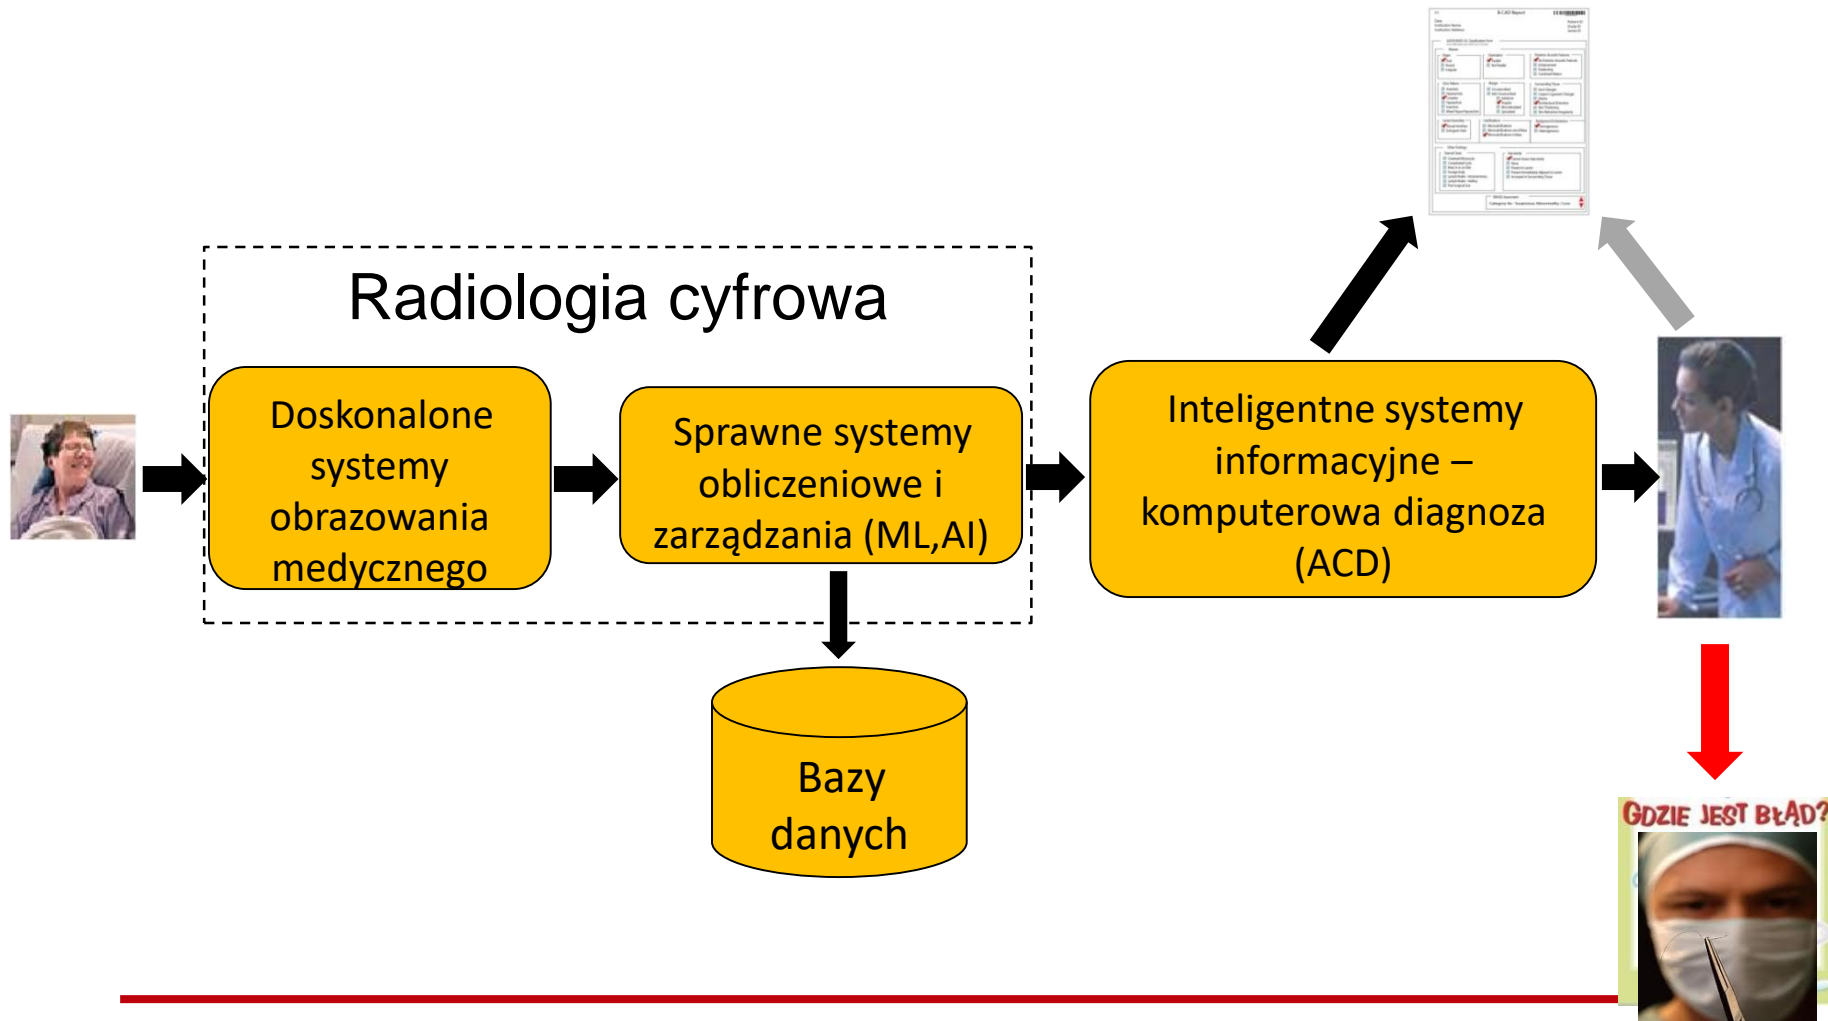
# Przykłady rozpoznań



*sugestie i potwierdzenie*



# Metoda 2: inteligentne wyliczenia ....




# Obróbka poznawcza obrazów medycznych

---

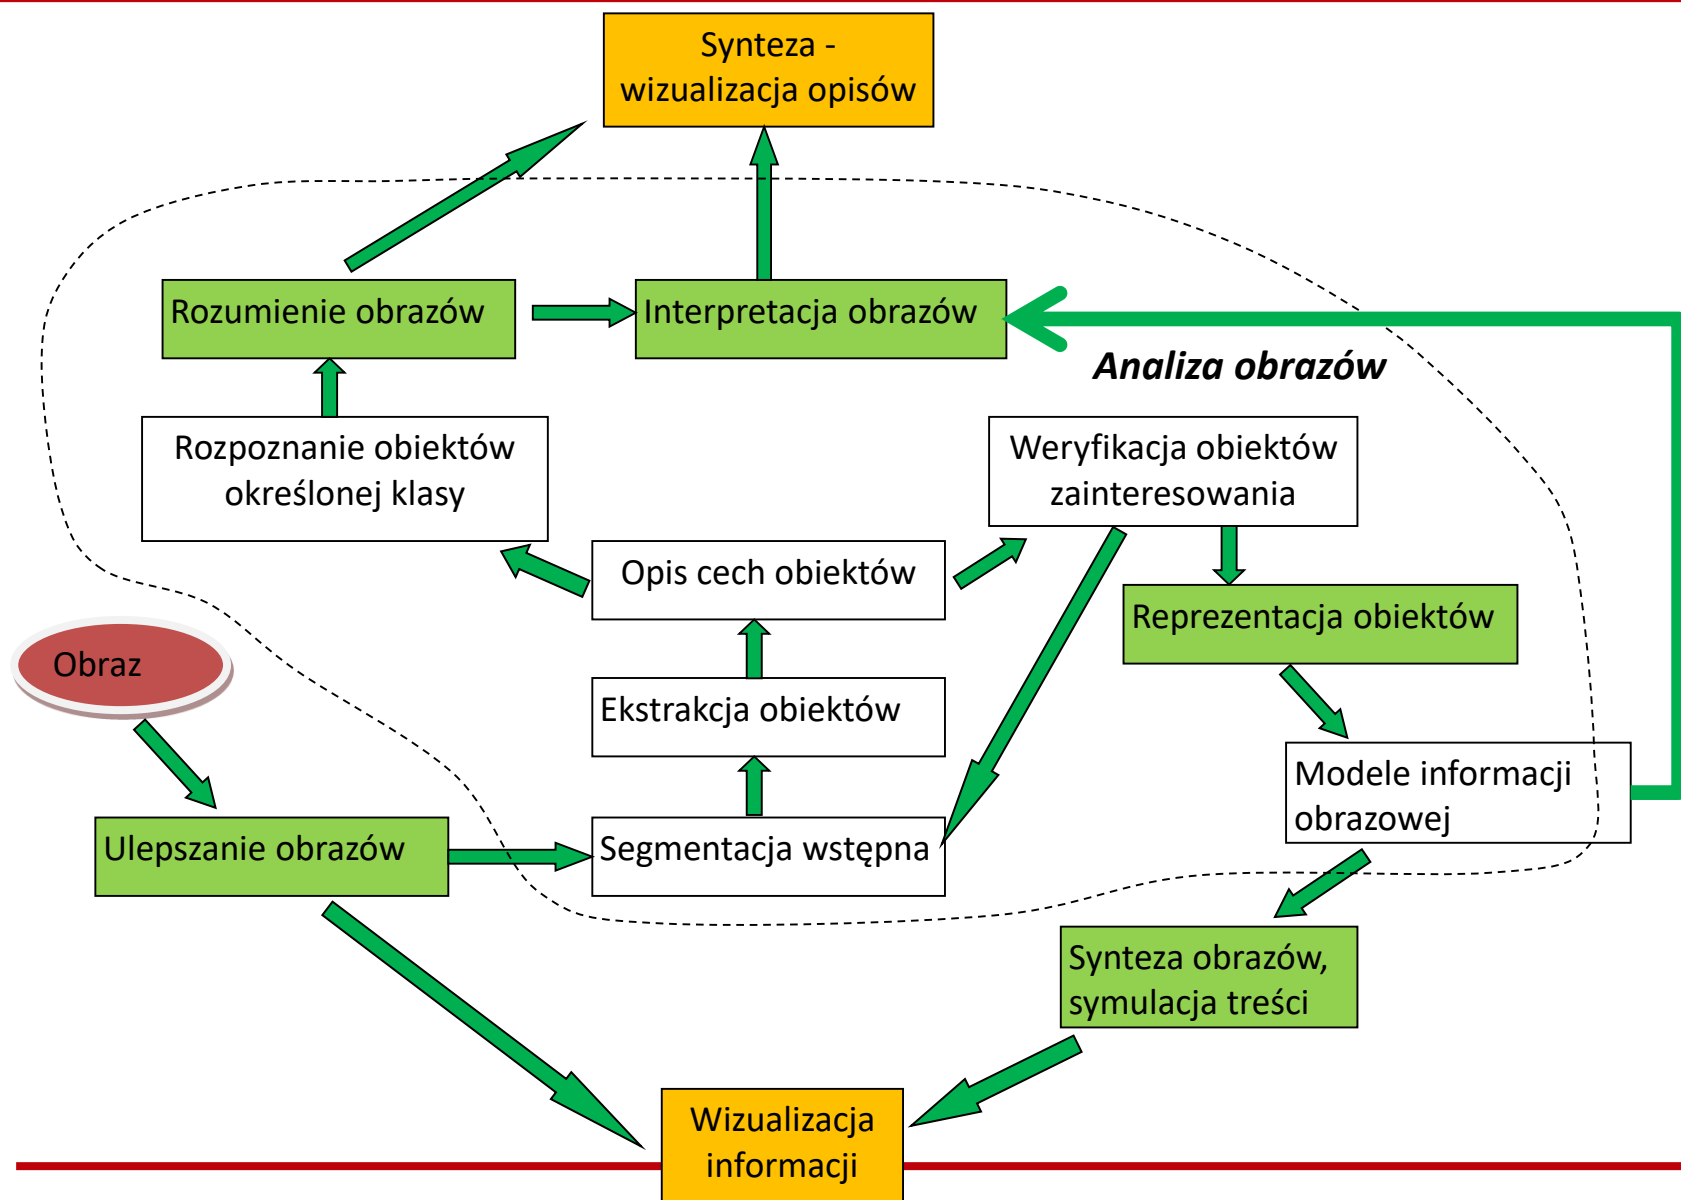
Wychodzimy od ustalonych modeli użytkowych (klinicznych, radiologicznych)

- Ulepszanie obrazów (ocena i poprawa jakości)
  - Wizualizacja, **modelowanie odbiorcy, modele treści**
  - Normalizacja (skalowanie, dopasowanie, przekształcenia geometryczne, kontrastowanie itp.)
  - Segmentacja (obszarowa, konturowa, obiektowa ...)
  - Analiza **komponentów treści**, właściwości, modelowanie wielopoziomowe....
  - Analiza cech struktur (obiektów)
    - kształtów, konturów, szkieletów, względnych rozmiarów, połączeń
    - tekstury, charakteru wysycenia , kierunkowych oscylacji, regularności, nieciągłości, ogólniej osobliwości
  - Grupowanie, wydzielanie i różnicowanie klas (w przestrzeni cech)
  - Selekcja cech, klasyfikacja (problem uczenia)
  - Rozpoznanie treści jako **integracja zabiegów analizy i klasyfikacji** – ROZUMIENIE całościowej wymowy (przekazu informacji)
  - **Aproksymacja wymowy treści**, optymalizacja rekonstrukcji według kryteriów jakości z regularyzacją, wiarygodność kryteriów, formowanie przekazu obrazowego
-




# Typowe sposoby wykorzystania komputerowej obróbki obrazów medycznych



# Schemat wykorzystania metod obrazowych – elementy informatyki obrazów bez specyfiki radiologicznej



# Przykład: ulepszanie badań bronchoskopowych




Skala ocen: -3 ... 3

Obserwatorzy	Metoda	MSU SS	WHE	CL1	CL2	CL3	WA1	WA2	WA3
Lekarze	Średnia ocen	1.94	-1.81	0.16	-1.04	-1.59	0.66	1.44	1.41
	Odch. Std.	0.08	0.44	0.66	0.05	0.47	0.04	0.08	0.22
Inżynierowie	Średnia ocen	-0.10	-0.44	1.58	-0.42	-1.33	1.40	1.52	1.47
	Odch. Std.	1.96	1.42	0.54	1.81	1.76	0.55	0.99	1.46



# Przykłady: wydzielanie obiektów




*K. Mikula, A. Sarti, F. Sgallari, Co-Volume Level Set Method in Subjective Surface Based Medical Image Segmentation, rozdz. 11 w Handbook of biomedical image analysis, Kluwer Academic Press, 2005*


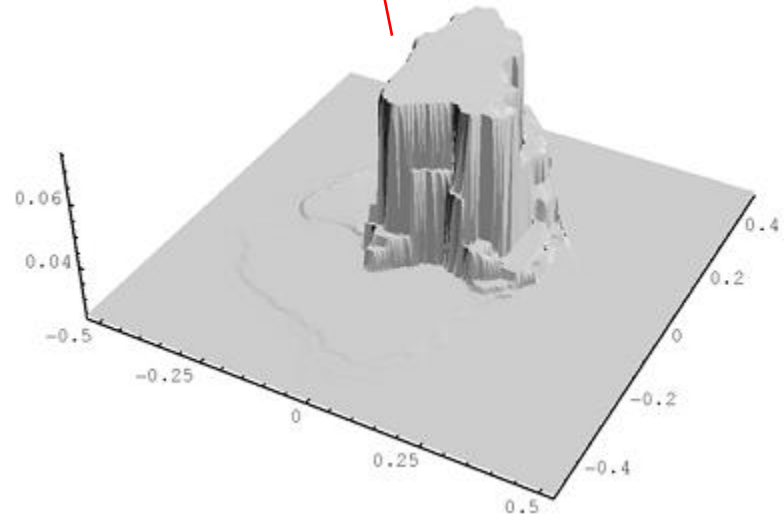



metoda poziomic (level sets): zaszumienie pieprz i sól (odszumienie po 2 i dziesięciu krokach)

metoda dyfuzyjna: wydzielenie ludzkich komórek

koncepcja: model obiektu różnicowanego względem nie-obiektów z optymalizacją względem dobieranych kryteriów






# Przykłady analizy - metoda poziomic: segmentacja przedsionka, komory i guza



# Modelowanie konturów względem otaczających obszarów

- Obiektowe metody analizy obrazów (przede wszystkim segmentacji), obszarowo-krawędziowe (nawiązanie do obiektowych metod aktywnych konturów - **ACM** oraz kształtów – **ASM** oraz poziomic (*level sets*) – **LSM**)
  - **Ogólnie**: skalowalny, elastyczny, poruszający się wzorzec, wyznaczony na podstawie danych (a priori lub wstępnej analizy przypadku) służy ustaleniu realnego obrysu obiektu o właściwościach (kształcie, konturach, relacji do tła) danej klasy/typu
  - **ACM**: wzorzec a priori konturu definiowany przez zbiór punktów węzłowych zbiegających do lokalnego maksimum gradientu
  - Główne cechy dotyczą stopnia deformowalności (elastyczność vs. sztywność) oraz rodzaju podatności na zmiany lokalne (giętkość)



# Aktywne kształty i poziomice

- **ASM**: statystyczne modele kształtu obiektów służące dopasowaniu konturów, parametryczne modele krzywej konturu  $\mathcal{K}(\mathbf{p})$  tymalizacja konturu za pomocą energetycznej funkcji kosztu (ASM)
  - Czynniki wewnętrzny (model obiektu): kontrola właściwości krzywej konturu, jej regularność, gładkość ustalana jest poprzez równoważenie wpływu dwóch składników: odpychania (rozciągający) i przyciągania (kurczący)
  - Czynniki dopasowania (tło-gradientowy, obrazowy): na podstawie analizy lokalnych gradientów następuje wpasowywanie w obrysy obiektów o pożądanym właściwościach (przede wszystkim silnie zarysowanych krawędziach)
  - Czynniki zewnętrzny: nakładanie przez użytkownika (**wiedza**) dodatkowych ograniczeń, np. iteracyjnych modyfikacji parametrów modeli obrysów obiektów czy też uwzględnienie specyficznej wiedzy dziedzinowej (np. dotyczącej specyfiki patologii)


$$E[\mathcal{K}(\mathbf{p})] = \alpha \int_0^1 E_{con}(\mathcal{K}(\mathbf{p}))d\mathbf{p} + \beta \int_0^1 E_{img}(\mathcal{K}(\mathbf{p}))d\mathbf{p} + \gamma \int_0^1 E_{ext}(\mathcal{K}(\mathbf{p}))d\mathbf{p}$$

- Rozszerzenie: pseudo-czasowy model konturu  $\mathcal{K}(t) = v(x_{\mathcal{K}}, y_{\mathcal{K}}, t) \cdot \vec{N}$  opisanego parametrami i śledzonego za pomocą mapy gradientu i modelu hiperpowierzchni (wielowymiarowość dziedziny obrazów) (*level sets*)


# Koncepcja poziomic (zarys)

- Uogólnienie problemu dopasowania konturu obiektów z wykorzystaniem dodatkowego wymiaru czasu  $t$
- Śledzenie hiperprzestrzeni za pomocą powierzchni w przestrzeni 3D lub krzywych na płaszczyźnie


$\mathcal{S}(x, y, t) : \mathbb{R}^2 \times [0, T] \rightarrow \mathbb{R}$



$\mathcal{S}(\mathcal{K}(t), t) = 0 \Rightarrow \frac{\partial \mathcal{S}}{\partial \mathcal{K}} \cdot \frac{\partial \mathcal{K}}{\partial t} + \frac{\partial \mathcal{S}}{\partial t} = 0$




Kontur opisany zestawem parametrów  $\mathbf{p}$

$$\mathcal{K}(\mathbf{p}, t) = \{(x, y) | \mathcal{S}(x, y, t) = 0\}$$


- Hiperpowierzchnia przemieszcza się pod wpływem estymowanego pola prędkości

$$\vec{v}(x, y) = \frac{a_1 - a_2 c}{g(|\vec{M}(x, y)|)} \cdot \vec{N}(x, y) = v(x, y) \cdot \vec{N}(x, y)$$

$a_1, a_2$  – stałe,  $c$  – krzywizna,  $g$  – fcja skalująca



przykładowo

$$g(\vec{M}) = \begin{cases} 1 + |\vec{M}| & \text{if } \cos \theta \geq 0 \\ 1 + |\vec{M}|^2 & \text{if } -0.5 \leq \cos \theta < 0 \\ 1 + (3 \sim 5) |\vec{M}|^2 & \text{otherwise} \end{cases}$$

# Metoda poziomic (formalizacja)

- Równanie *level setów*  $u_t = |\nabla u| \nabla \cdot \left( \frac{\nabla u}{|\nabla u|} \right)$
- Konkretyzacja problemu ( $u(t, x)$  – modelowany obiekt określony na  $Q_T \equiv [0, T] \times \Omega$ ,  $\Omega \subset \mathbb{R}^d$ ),  $I^0$  to segmentowany obraz. funkcje  $g(s) = 1/(1 + Ks^2)$ ,  $K \geq 0$ ,  $G_\sigma(x) = \frac{1}{(4\pi\sigma)^{d/2}} e^{-|x|^2/4\sigma}$ , gdzie  $\nabla G_\sigma * I^0 = \int_{\mathbb{R}^d} \nabla G_\sigma(x - \xi) \tilde{I}^0(\xi) d\xi$  oznacza wstępne, splotowe wygładzanie obrazu gradientów

$$u_t = \sqrt{\varepsilon^2 + |\nabla u|^2} \nabla \cdot \left( g(|\nabla G_\sigma * I^0|) \frac{\nabla u}{\sqrt{\varepsilon^2 + |\nabla u|^2}} \right)$$




Figure 4: A graph of the image intensity function  $I^0(x)$  corresponding to a "dumb-bell" image (left, see also Figure 5) and a graph of the function  $g(|\nabla I^0(x)|)$  (right) where a narrow valley along the edge can be observed. (Color Slide).

Figure 6: An initial ellipse driven by the vector field  $-\nabla g(|\nabla I^0(x)|)$  down to the valley to find the edge in the image  $I^0$ . (Color Slide).

Figure 5: Image given by the intensity  $I^0(x)$  from Figure 4 left and the arrows representing the vector field  $-\nabla g(|\nabla I^0(x)|)$ . (Color Slide).

# Przykłady działania poziomic




Figure 7: The situation is more complicated in case of a "noisy" image (middle); we plot also a graph of its intensity  $I^0(x)$  (left) and corresponding surface  $g(|\nabla I^0(x)|)$  (right). (Color Slide).




Figure 8: The evolution only by advection leads to attracting a curve (initial ellipse) to spurious edges, the evolution must be stopped without any reasonable segmentation result (left); by adding regularization term related to curvature of evolving curve the edge is found smoothly (right).











Figure 11: Subjective surface based segmentation of a "batman" image. In the left column we plot the black and white image to be segmented together with isolines of the segmentation function. In the right column there is a shape of the segmentation function. The rows correspond to time steps 0, 1 and 10 which gives the final result;  $\varepsilon = 1$ . (Color Slide).

# Mapy krawędzi (kierunek i wartość gradientu) - efekty

Ogólnie: koncepcja modelu *a priori* deformowanego globalnie i dopasowanego według lokalnych cech przypadku




Nikos Paragios, *Level Set Methods in Medical Image Analysis: Segmentation*



Quming Zhou, 'Extract object boundaries in images using level set', *Final report*



# Przykłady analizy obszarowej: mieszanina regionów gaussowskich (pasowanie modelu stochastycznego)



$$P(x_i) = \sum_{k=1}^K \pi_k P_k(x_i), \quad i = 1, \dots, M \cdot N$$


$$\sum_{k=1}^K \pi_k = 1,$$

$$P_k(x_i) = P(x_i | R_k)$$

gęstość estymowana

automatycznie

ręcznie przez radiologa



gęstość pomierzona

# Podsumowanie: granice sukcesu (?), czyli możliwości sztucznej-komputerowej inteligencji obliczeniowej...

---

Komputer (maszyna licząca) świetnie rachuje, optymalizuje według ustalonych kryteriów, podpowiada według znanych lub wyuczonych schematów (logika) ...

nieźle rozpoznaje i klasyfikuje złożone, powtarzalne obiekty i relacje, gorzej z oryginalnym poznaniem, interpretacją poza schematami, oceną innego, nowego...

ma problemy z rozumieniem, kreatywnością, oceną realnych, złożonych, osobliwych (nieschematycznych) problemów ...



kot czy pies?

a to?

Nasz cel: wspieranie realnych dylematów ... Metoda: wykorzystanie zdolności obliczeniowych do predykcji/regresji/aproksymacji/ekstrapolacji rzeczywistości badanej (funkcja trafnie opisująca rzeczywistość)

---

# (Automatyczna) diagnoza komputerowa - ACD

---

- Historyczne przyczyny niepowodzeń:
    - Ograniczenia zdolności obliczeniowych, schematyzm komputerów
    - zróznicowana jakość/specyfika obrazów medycznych - ogólnie duża zmienność uwarunkowań technologicznych wpływających znacząco na właściwości (cechy wizualne) obrazowanych struktur
    - brak uniwersalnych metod - duża złożoność informacji obrazowej, słabe modele, brak odpowiednio zaawansowanych, a jednocześnie uniwersalnych algorytmów komputerowego przetwarzania obrazów
    - ograniczenia w zakresie reprezentatywnej wiedzy obrazowej - brak regularnych wzorców patologii oraz stabilnych, reprezentatywnych zbiorów ich cech specyficznych
    - ograniczenia w zakresie zobiektywizowanej, uzgodnionej, sformalizowanej wiedzy klinicznej (diagnostycznej, medycznej)
    - ograniczenia w zakresie modeli użytkowych - zaniedbanie walorów użytkowych, brak wiarygodnego kontekstu komercjalizacji- specyfiki wymagań pragmatycznych
-

# Przykłady prac w zakresie ACD


---

- Lodwick G.S., Haun C.L., Smith W.E., et al. (1963) **Computer diagnosis of primary bone tumor**. Radiology 80:273-5
  - Becker H., Nettleton W., Meyers P., Sweeney J., Nice C. Jr. (1964) Digital computer determination of a **medical diagnostic index** directly from chest X-ray images. IEEE Trans Biomed Eng BME-11:67-72
  - Myers P.H. Nice C.M., Becker H.C., et al. (1964) **Automated computer analysis** of radiographic images. Radiology 83:1029-34
  - Kruger RP, Towns JR, Hall DL, et al. (1972) **Automated radiographic diagnosis** via **feature extraction and classification** of cardiac size and shape descriptors. IEEE Trans Biomed Eng BME-19(3):174-86
  - Kruger RP, Thompson WB, Turner AF. (1974) **Computer diagnosis** of pneumoconiosis (*pylica płuc*). IEEE Trans Syst Man Cybernetics SMC-4(1):44-7
  - Conners R., Harlow C., Dwyer S. (1982) **Radiographic image analysis**: past and present. In Proc. 6th. Int. Conf. Pattern Recognition, Munich, Germany, pp. 1152–1168
  - .....
  - Współczesny deep learning, CNN, GANs etc. ....
  - .....
-

# Model czy dane? Model z danych? Dylematy ...

- Regularna niepewność świata modeli (R.A. Fischer-**Empirical model building, 1922r.**) czy też losowa niepewność królestwa danych (statystyczny świat Tukey- the Age of Tukey, 1975r.)
- Fischer (1922 r.): jeśli znamy jakościowy (zrozumiały) charakter hipotetycznej populacji, odsuwamy problemy statystycznej manipulacji; **w świetle danych testujemy model i doskonalimy go**
- **Podejście Fischera stosowane jest od dawna do** rozwiązywania rzeczywistych i złożonych problemów, wykorzystuje całościowe spojrzenie na problem; tworzony jest całościowy model zjawiska bez ułatwiających uproszczeń; **model z wiedzy jest weryfikowany względem realnych danych (uwarunkowań) i udoskonalany**
- J.Tukey(The future of data analysis, 1962r.): Najważniejsza maksyma, którą powinni wziąć pod uwagę analitycy danych brzmi: o wiele lepsza jest konkretna (choć tylko przybliżona) odpowiedź na właściwe pytanie/żądanie (bez konieczności rozumienia), niż precyzyjna/zrozumiała/wiarygodna odpowiedź na przybliżone pytanie. Analiza danych musi w najlepszym przypadku postępować według przybliżonych odpowiedzi, ponieważ wiedza na temat tego, na czym naprawdę polega problem, **będzie w najlepszym przypadku przybliżona**
- Podejście Tukeya **pozwała się 'mówić' danym bez ingerencji modelu, uzyskując pragmatyczny, przybliżony model obliczeniowy 'z danych'** (który próbuje się później wyjaśniać – zrozumieć model: XAI)
- **Dane służą tworzeniu modeli, a może ich testowaniu?**  
**dane -> (człowiek) -> model**

# Diagnoza rozwoju technologii ...



- zadanie okazało się trudniejsze niż rozróżnienie kota i psa ...
- nowa technologia, w tym komputerowa, zasadniczo nie rozwiązuje problemu błędów percepcji (poznania), ale niejako je przemieszcza w inny, nowy obszar nieznanej dziedziny, gdzie mogą pojawić się nowe, nawet liczniejsze pomyłki (Oestmann J.W., Greene R., et al. (1988) *Lung lesions: correlation between viewing time and detection*. Radiology 166:451-3)
- likwidacji dotychczasowych przyczyn błędów towarzyszy pojawienie się nowych źródeł błędów, a proces ten wydaje się nieuchronny – efekt poznawania nieskończoności
- korzystanie z nowych, doskonalszych narzędzi nie powoduje, że człowiek staje się niezawodny w swoim działaniu, albo jego rola może być pominięta – dalej poruszamy się po omacku, chociaż w innej przestrzeni - dając większe możliwości/zaufanie maszynom, konsekwencje naszych pomyłek mogą być poważniejsze (a przyczyny niejasne)...
- receptą rozwój technologiczny- ale jaki? – służący głębszemu poznaniu istoty/rdzenia problemu (większe rozumienie/wiedza – trafniejsze decyzje)
  - doskonalenie ludzkiego postrzegania (lepszy pomiar i przekaz wyników) z zachowaniem naturalności poznania
    - heurystyka poznania (np. zdjęcia celowane, adaptacyjna rekonstrukcja)
    - obserwacje, wpisanie w realne mechanizmy kliniczne, badanie ludzkich zachowań, tworzenie lepszych narzędzi, konstrukcja wiarygodnych modeli procesów decyzyjnych
  - kształtowanie lepszych uwarunkowań ludzkiej pracy w szerokim kontekście (od modelu ergonomicznego po biznesowy) – dajmy sobie czas na uczenie i naturalne poznawanie
  - wzrost trafnych decyzji poprzez powszechność wiedzy, zwiększenie kultury, potencjału poznawczego (wyrobienie intuicji poznawczej)
  - współpraca poprzez zdrową konkurencję (dobro wspólne, otwartość, łatwa kontrola)

# Intuicja poznawcza

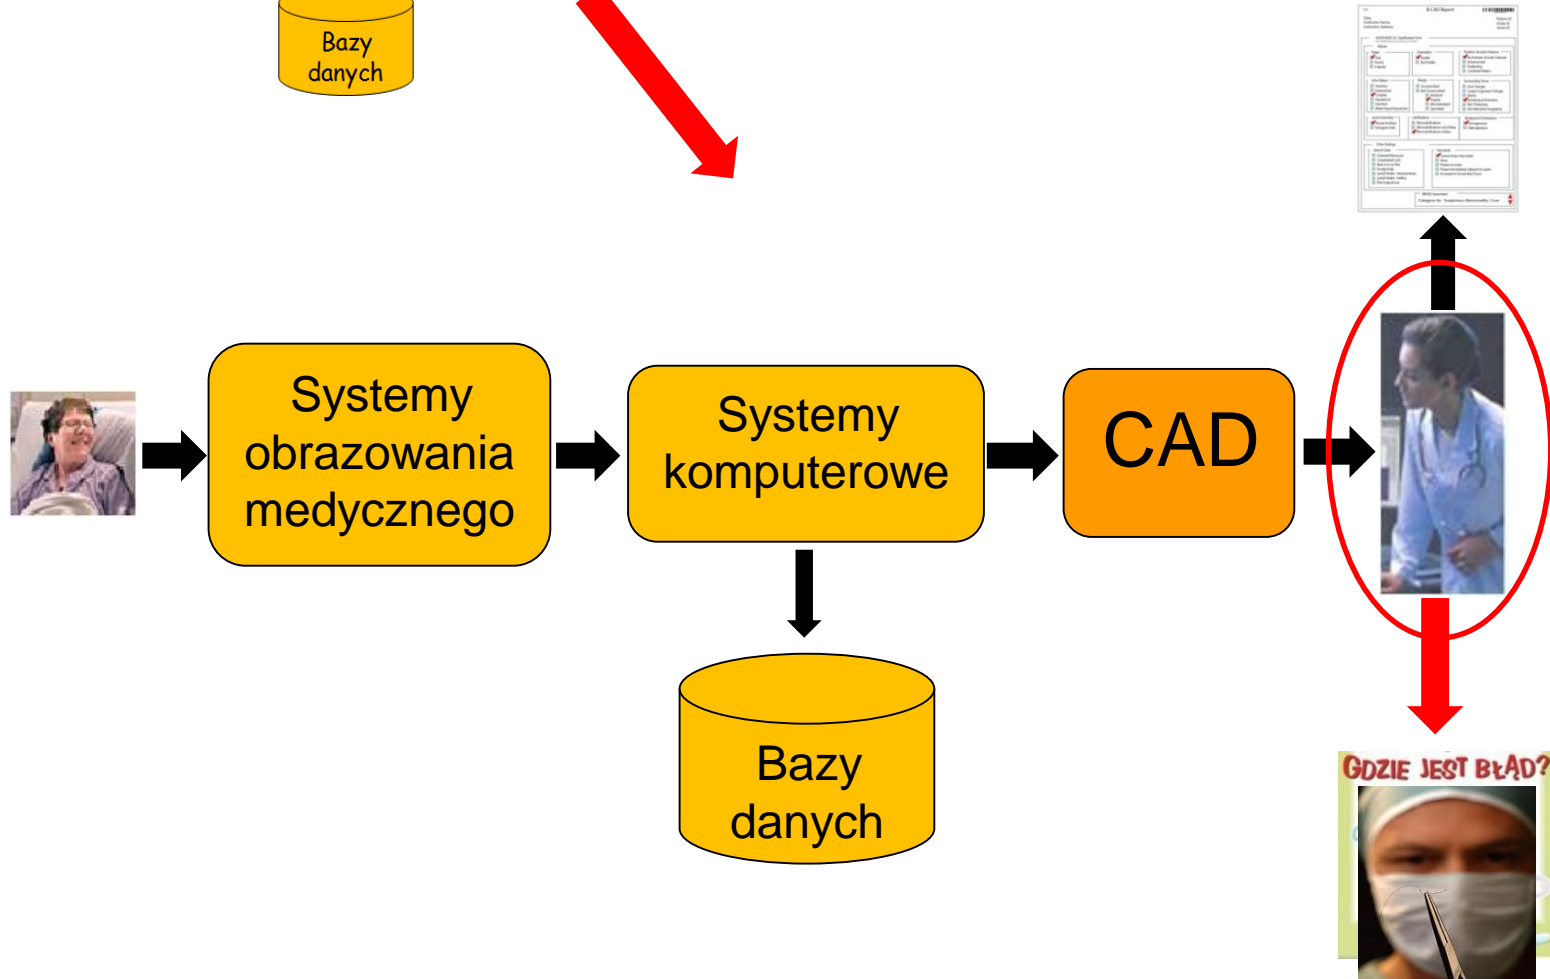
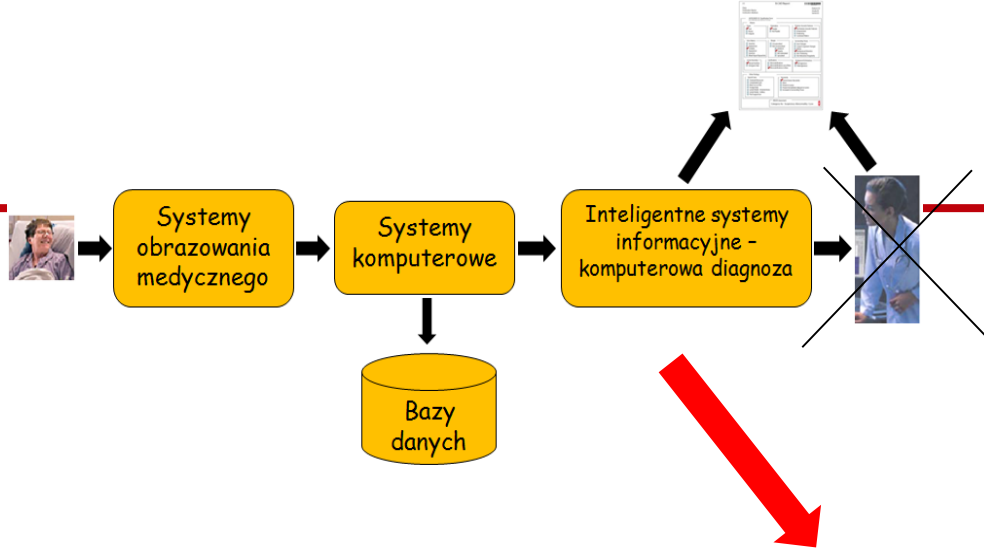
łac. *intuitio* – wejrzenie; wewnętrzne przekonanie, że masz rację

- to zdolność do nagłego przeblysku myślowego, w którym dostrzega się rozwiązanie problemu lub znajduje odpowiedź na nurtujące pytanie
- pozwala na szybkie dopasowanie rozwiązania problemu do zaistniałych uwarunkowań
- nie emocje, a raczej proces podświadomy, którego nie sposób kontrolować, to przewidywanie, domyślanie się nie wynikające z klarownych reguł wnioskowania
- proces bardziej kreatywny, działający na wyższym poziomie abstrakcji w porównaniu do myślenia logicznego - w praktyce, można jedynie dopuszczać lub odrzucać sugerowane przez intuicję rozwiązania

**To rozum, który się śpieszy**

- jest cechą aktywnej inteligencji, której zwykle nie towarzyszy świadoma myśl
- zdolność bezpośredniego pojmowania, dotarcia do bezpośredniej wiedzy bez udziału obserwacji czy rozumu
- myślenie intuicyjne jest podobne do percepcji, czyli błyskawiczne i bez wysiłku - **wgląd, olśnienie** pojawiające się w trakcie rozwiązywania problemu, przeczucie, szybkie rozpoznanie, pojawiające się przekonanie sięgające do istoty problemu, którego nie jesteśmy w stanie uzasadnić
- myślenie intuicyjne wykorzystuje 3 zasadnicze zjawiska
  - mimowolne uczenie się, automatyczne, nieuświadomione zdobywanie wiedzy
  - automatyzm zachowania, sztywne sposoby reagowania wynikające z doświadczenia życiowego (twórcze wykorzystanie doświadczenia)
  - markery somatyczne ostrzegające organizm (odczucia generowane na podstawie wtórnych emocji, wcześniejszych doświadczeń, to fizjologiczny sygnał ostrzegawczy o przewidywanych skutkach podjęcia decyzji) – całe ciało poznaje ...

# Metoda 3: CAD





# Nowa propozycja: **CAD** (zasady ogólne rozwoju według Laboratorium Kurta Rossmanna)

---

## *Kurt Rossmann Laboratories*

- **poznanie, czyli rozumienie procesów** zachodzących w pracy radiologa opisującego badania (dorobek człowieka, wiedza i umiejętności - rozumienie istoty podmiotowej pracy radiologa, kontekstu decyzyjnego, klinicznego, biomedycznego etc.)
  - **pragmatyzacja badań, czyli perspektywa komercjalizacji** rozwiązań znajdujących zastosowanie w praktyce klinicznej (teoria informacji - pragmatyzm poznawczy, zrozumienie uwarunkowań aplikacyjnych, istota modeli użytkowych)
  - **realizacja wspólnymi siłami, promocja i doskonalenie narzędzi w skali globalnej** (współpraca, integracja wysiłków, doświadczeń)
  - Wnioski:
    - **Interdyscyplinarna integracja wysiłków poznawczych** (od poziomu biofizycznego po abstrakcję matematyczną i sprawność narzędzi informatycznych)
    - **Metody hybrydowe, zintegrowane, pragmatyczne** - wiarygodne kryteria subiektywno-obliczeniowe (**metody nie są najważniejsze, rozwiązania przyjdą na myśl same, jeśli zrozumiesz problem i go opiszesz**)
    - **zdrowa filozofia rozwoju** (globalny wysiłek jako dobro wspólne, perspektywa)
-

# CAD

---


- Uzyskano poprawę efektywności interpretacji badań
    - wspomaganie zamiast zastępowania ocen radiologów wskazaniami narzędzi obliczeniowych
    - wyposażenie specjalistów w dodatkowe możliwości, np. narzędzia sugerujące zmiany podejrzane (tj. odbiegające od normy - anormalne), generujące różne formy podpowiedzi/wyjaśnienia/informacje
  - To dodatkowa opinia weryfikowana ostatecznie przez lekarza
  - Siła CAD:
    - obiektywizacja analizy, powtarzalność, formalna referencja ocen (jak obraz, tak i jego analiza jest przedmiotem oceny)
    - komplementarność wskazań w odniesieniu do ocen radiologów
    - użyteczność w przypadkach trudnych jako źródło dodatkowych informacji
    - zintegrowane przetwarzanie informacji na różnym poziomie abstrakcji (łączenie cech hybrydowych)
    - możliwości kontrolne, uzupełniające (np. preskrining)
-

# CAD versus ACD

---

- Komputery i/lub eksperci
    - ACD – dominująca rola algorytmów komputerowych (kryteria obliczeniowe))
    - CAD – integracja roli specjalistów i metod komputerowych
  - Wydajność/skuteczność
    - ACD: komputery muszą przynajmniej dorównywać specjalistom
    - CAD: efektywność algorytmów może być ograniczona - komputery stanowią **uzupełnienie** warsztatu lekarza (nie chodzi o naśladowanie!)
  - Użyteczność
    - ACD: ograniczona efektywność, brak spektakularnych sukcesów, mała przydatność
    - CAD: użyteczność wspomaganie nawet za pomocą prostych technik komputerowych
  - Konkluzje
    - **“we should stop trying to make computers act like diagnosticians”**  
R. Engle (1992) *Attempts to use computers as diagnostic aids in medical decision making: A thirty-year experience*, In *Perspectives Biol. Med.*, 35:207-217
    - jeśli nawet dopuszczamy „role samodzielne” metod komputerowych w procesie diagnozy, to robimy to stopniowo, rozważnie, pod kontrolą jedynie jako element uzupełnienia w kontekście określonych ścieżek klinicznych (*wygodny śrubokręt*)
    - medycyna bazująca na formalizowanych faktach (*evidence-based medicine*) oraz personalizacja (*personalized medicine*)
-

# CAD – IDEA



Celem jest zwiększenie skuteczności pracy radiologa poprzez

- zmniejszenie liczby błędnych wskazań
- redukcję różnicowania ocen
- obiektywizację (porównywalność, powtarzalność) diagnozy

# Komputerowe wspomaganie diagnostyki obrazowej –

---

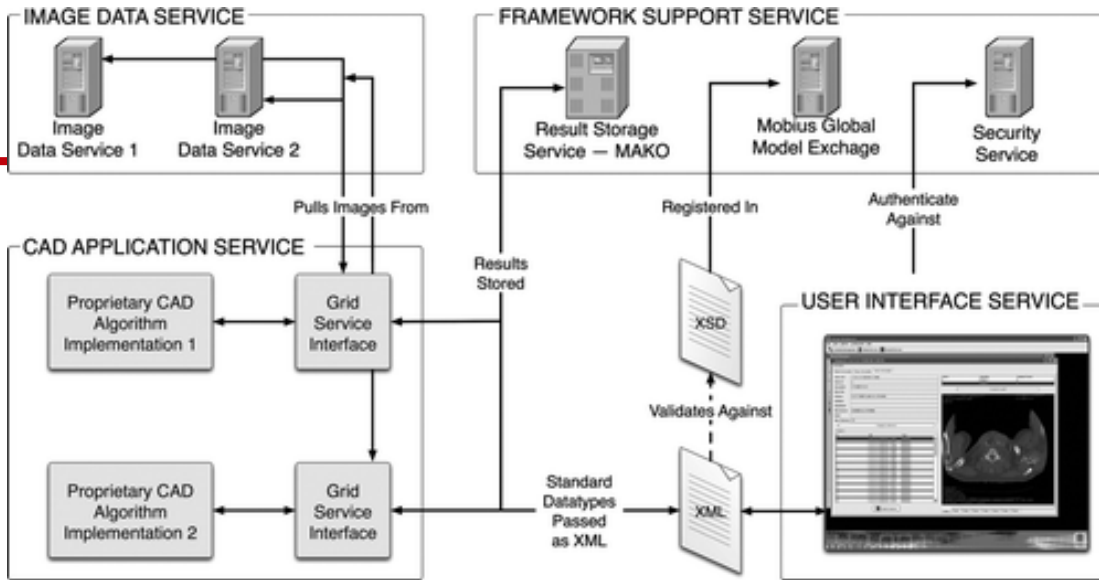
umiejętne wykorzystanie technologii obliczeniowych celem  
wspierania podmiotowych aktywności radiologa

- **Umiejętne włączenie wspomagających technologii obliczeniowych** (w tym teleinformatycznych) **w proces diagnozy** (wykorzystującej obrazowanie) **celem jej obiektywizacji** (powtarzalność), **udoskonalenia** (szybciej, precyzyjniej), **redukcji błędów** – *od dostarczenia dodatkowej informacji i kontroli jakości, poprzez poprawną wizualizację, poprawę percepcji, poznania i rozumienia, aż do automatycznej detekcji i prób interpretacji zmian*
  - **Cel zasadniczy** - **wspieranie decyzji diagnostycznych radiologa** metodami przetwarzania, analizy, rozpoznawania i rozumienia obrazów, **integrowanymi z uwarunkowaniami klinicznymi** (dane, ścieżki, wytyczne, wspieranie decyzji) oraz **specyfiką systemów pomiarowych** (obrazowania)
  - **Podmiotowa rola diagnosty**, wskazania CAD mają jedynie charakter pomocniczy (asystent, narzędzie, funkcja drugiej oceny) służąc wygodzie i zwiększeniu niezawodności pracy radiologa – **koncepcja wzmocnionej inteligencji**
-


# Nowoczesne technologie stosowane w CAD

- Rosnąca moc obliczeniowa nowoczesnych technologii
  - Struktury gridowe
    - Pan T.C., Gurcan M.N., Langella S.A. et al. (2007) **GridCAD: grid-based computer-aided detection system**. RadioGraphics 27:889–897
    - Gurcan M.N., Pan T., Sharma A. et al. (2007) **GridIMAGE: a novel use of grid computing to support interactive human and computer-assisted detection decision support**. J Dig Imag 20(2):160-171
  - Obliczenia w chmurach
    - H. Yoshida, Y. Wu, W. Cai et al. (2011) **Mobile Cloud-Computer-aided Diagnosis System for Colon Cancer Screening with Motion-based Virtual Colonoscopic Navigation**, Proc RSNA
- Rozwój metod inteligencji obliczeniowej
  - algorytmy rozpoznawania, optymalizacji, numeryka
    - Shiraishi J, Li Q, Appelbaum D, Doi K (2011) **Computer-aided diagnosis and artificial intelligence in clinical imaging**, Semin Nucl Med
    - Verma B., Zakos J. (2001) **A computer-aided diagnosis system for digital mammograms based on fuzzy-neural and feature extraction techniques**. IEEE Tran Inf Tech Biomed 5(1):46-54
    - Land W.H., McKee D.W., Anderson F.R. et al. (2006) **Using computational intelligence for computer-aided diagnosis of screen film mammograms**. Chapter 10 in Recent advances in breast imaging, mammography, and computer-aided diagnosis of breast cancer. SPIE Press Monograph vol. PM155, pp. 321-381
  - formalizacja wiedzy medycznej (ontologie): T.T. Dao, F. Marin et al. (2009) **Ontology-based Computer-Aided Decision System: a new architecture and application concerning the musculoskeletal system of the lower limbs**, ECIFMBE 2008, Proc 22, pp. 1540–1543








Library for Mammography) –  
 icznych mammogramów,  
 em telekonsultacji



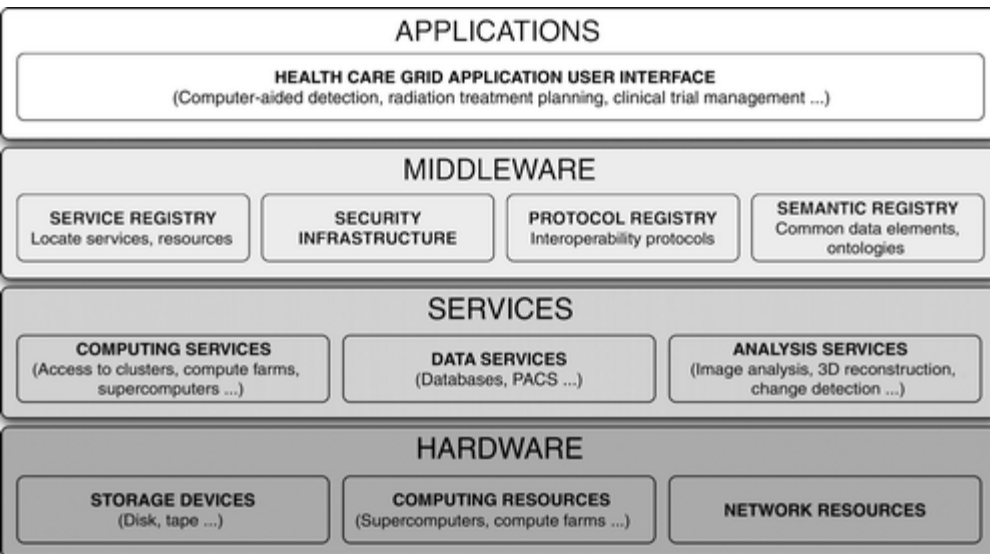
Algorithms and data at different locations  
 Data cannot be moved due to their large size or security issues






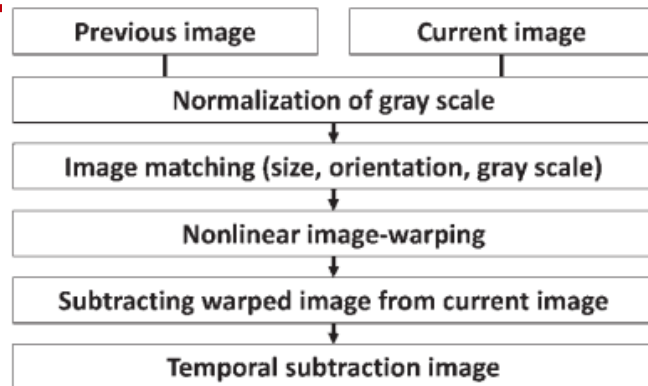


Algorithms moved to data for execution



Algorithms removed from data source  
 Results produced at the site of data



# Przykłady trendów CAD



płuca w CT:  
dwa guzy

Previous image    Current image    Temp. Sub. image    Temp. Sub. with CAD



# Przykład CAD z ontologią (leczenie szpotawości i deformacji rotacyjnych)




Fig. 1 Scenario of the CADS. ( $D_i$ ,  $S_i$ ,  $R_i$ : Diagnosis, Surgery, Rehabilitation number  $i$ ,  $M_i$  or  $M_i^j$ ; monitoring number  $i$ ). Bold box illustrated where the expert interact with CADS.

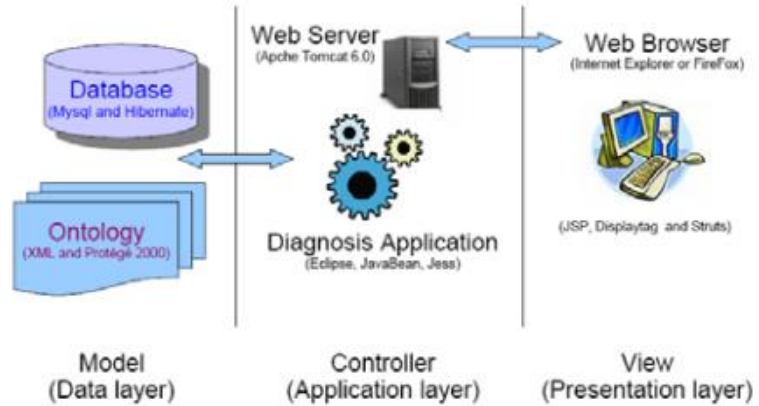


Fig. 2 The multi-layers architecture of our CADS

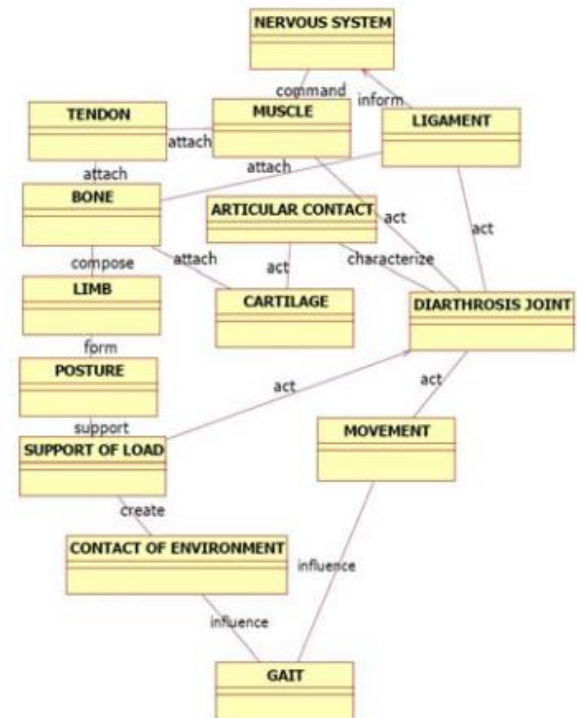


Fig. 3 General architecture of the OSMMI ontology [7]

## Ontology-based Computer-Aided Decision System: a new architecture and application concerning the musculoskeletal system of the lower limbs

T.T. Dao, F. Marin and M.C. Ho Ba Tho

# Systemy CAD

- **1998** - **ImageChecker** firmy **R2 Technology**, akceptacja FDA, mammografia
- **Mammografia** - **SecondLook** firmy CADx Medical Systems (2002 rok), KODAK Mammography Computer-Aided Detection System proponowany przez Carestream Health do mammografii analogowej(2004)
- w obszarze **diagnostyki raka sutka**: B-CAD firmy Medipattern do **sonomammografii** (FDA-2005) - detekcja i opis przede wszystkim guzów, systemy **MRI-CAD**: CADstream firmy Confirma jako, AuroraCAD firmy Aurora Imaging Technology, SpectraLook firmy iCAD
- **rentgenografia klatki piersiowej** - detekcja i pomiary guzków: IQQA-Chest firmy EDDA Technologies/Philips (FDA - 2004), xLNA firmy Philips Medical Systems (wykrywa guzki o średnicy od 5 mm), Rapid Screen CAD firmy Riverain Medical (pierwszy system CAD do rentgenografii płuc zatwierdzony przez FDA w 2001 roku), Lung VCAR firmy GE Healthcare;
- **tomografia komputerowa płuc**: Syngo Lung CAD firmy Siemens Medical Solutions (zatwierdzony przez FDA, wykrywa guzki poniżej 3 mm), CAD-Lung firmy Median Technologies, CADLung firmy Medicsight, ImageChecker Lung CT firmy Hologic/R2 Technology (zatwierdzony przez FDA w 2001);
- **tomografia wątroby**: IQQA-Liver firmy EDDA Techology;
- **echokardiografia**: Axis Auto EF CAD firmy Siemens Medical Solutions;
- **kolonografia CT**: Medicsight ColonCT firmy Medicsight, CAD firmy Philips Medical Systems, CAD Colon firmy iMED, CAD-Colon firmy Median Technologies, iCAD VeraLook;
- **badania MR prostaty**: VividLook, CADView firmy iCAD, Merge CADstream, Invivo DynaCAD,
- ltd.

# Nie wszystko się udaje – dlaczego?

---

- Wysoka efektywność (czułość, specyficzność) z eksperymentów niekoniecznie przekłada się na skuteczność kliniczną, ponieważ:
    - Występuje pewna liczba wskazań fałszywych, co ogranicza zaufanie radiologów
    - Brak rozumienia zasad działania narzędzi (problem trafnej interpretacji wskazań)
    - Brak doświadczenia w użytkowaniu nowoczesnych technologii teleinformatycznych
    - Brak protokołu badań klinicznych, procedur uwzględniania wskazań pomocniczych czy automatycznych podpowiedzi
  
  - Obserwowany efekt: brak statystycznie istotnej poprawy czułości przesiewowych badań diagnostycznych przy jednoczesnym obniżeniu swoistości podejmowanych decyzji
    - Badania na dużej grupie testowej - Fenton J.J., Taplin S.H., Carney P.A. et al. (2007) Influence of computer-aided detection on performance of screening mammography. N Engl J Med 356(14):1399-409
    - Problem wiarygodnego potwierdzania klinicznej użyteczności CAD w dużej skali wydaje się nadal otwarty (pomimo kilkunastu lat klinicznych zastosowań)
    - **Samo zadanie okazuje się UŻYTKOWO zbyt skomplikowane (złożone, trudne) – także w wiarygodnej ocenie**
    - **Uproszczenia technologiczne/organizacyjne/decyzyjne TO NIE WSZYSTKO – KLUCZOWY JEST SPOSÓB UŻYTKOWANIA narzędzi i rozumienie ich wskazań! (synergiczna integracja metod i ludzi na różnych poziomach)**
-




# **KONCEPCYJNE DOSKONALENIE CAD:**


- INTEGRACJA 'CZŁOWIEK-KOMPUTER',**
  - UPROSZCZENIE I OBIEKTYWIZACJA ZADAŃ**
-

# Rozumienie/wyjaśnianie obrazów - doskonalenie CAD ....

*Poznanie: dominacja warstwy  
numeryczno-analityczno-  
pojęciowej (CAD)*



*Działanie: dominacja warstwy  
decyzyjnej, logiczno-zadaniowej  
(CDS)*



# Użytkowania informacji: diagnostyczne rozpoznanie ...

---

- Diagnozowanie - proces potwierdzanie, identyfikacja choroby
  - Diagnostyka obrazowa (radiolog) – potwierdzanie anormalności i sugestia interpretacji lub brak potwierdzenia
  - Schematyzacja procesu diagnozy jest trudna
    - istnieje wiele szkół, indywidualnych metod i sposobów, nawyków i intuicyjnych przyzwyczajzeń
    - próby standaryzacji napotykają duży opór
    - modelowanie istoty tego procesu jest jednak niezbędne w rozwoju inteligentnych systemów informacyjnych (*baza i rozszerzenia*)
  - Diagnozowanie obejmuje (model)
    - a) proces selektywnego pozyskiwania informacji o pacjencie (klinicznej)
    - b) proces analizy, oceny informacji obrazowej (wyznaczanie komponentów rozpoznanej treści, formowanie kompleksowej wymowy)
    - c) łączną, synergiczną interpretację całej informacji (obrazu klinicznego), zgodnie z posiadaną wiedzą
    - d) formułowanie decyzji diagnostycznej (inaczej ocena symptomów patologii – interpretacja w kategoriach diagnostycznych)
-

# Obliczeniowe wyłuskanie informacji, a nawet dalej ....

---

- Selektywne ustalanie wymowy przekazu informacji (model)
    - dostęp do źródeł danych – zapewnienie kompletu wiarygodnych danych dobrej jakości
    - percepcja i poznanie danych (opis według relacji dane → treść)
      - analiza danych w kontekście ich semantyki
      - ocena treści ogólnej vs postrzeganie istotnych szczegółów
      - poprawne odczytanie zintegrowanej treści przekazu (głębsze zależności i wnioski, informacja vs artefakt)
    - rozumienie treści (treść → wymowa, czyli znaczenie nad słownikiem pojęć)
      - a) nazwanie informacji diagnostycznej – określenie istotnych cech, wskazanie anormalności - potencjalnych objawów chorobowych (struktury, regionu), wykluczenie podejrzeń, fałszywych sugestii
      - b) ocena uwarunkowań: ocena kontekstu wystąpień anormalności, cech podejrzanych, wszystkiego co może mieć znaczenie, określenie wzajemnych relacji pomiędzy komponentami treści
      - c) odczytanie specyficznej, kompleksowej i zupełnej wymowy treści (rzutowanie treści w zestaw pojęć i relacji na poziomie diagnozy)
    - rozumienie pozostaje na poziomie formalnych modeli, doskonalonych i obiektywnych wpasowując informacje i efekty poznawcze w kontekst kliniczny, ułatwia interpretację
    - poznanie: rzutowanie modeli na sformalizowane protokoły badań, schematy decyzyjne, klasyfikacje kształtujące formy leczenia (*model idzie ścieżkami klarownych znaczeń*)
-


# Efekt: interpretacja zostaje w rękach lekarzy – jaki poziom abstrakcji, formalizacji?

- Ułatwianie decyzji diagnostycznej (CAD + CDS)
  - **przetwarzanie:** gromadzenie (pod kontrolą) informacji, przetwarzanie z kryteriami użyteczności i analiza, komputerowe rozumienie treści
  - **modelowanie uwarunkowań decyzji diagnostycznych** według schematu: syntaktyka – semantyka – pragmatyka (formułowanie odpowiedzi, ustalanie reguł użytkowych, kształtowanie sposobu użytkowania)
- **Interpretacja** - wyjaśnienie zgromadzonej informacji – obserwowanych symptomów czy anormalności (skutków) poprzez określenie ich przyczyny (weryfikacja odpowiedzi komputerowych)
  - docieranie do źródeł informacji diagnostycznej, weryfikacja, ocena wiarygodności (*analiza wyjaśnień systemów*)
  - właściwa ocena - wyjaśnianie dostępnej informacji na bazie własnych doświadczeń, wiedzy, a nawet intuicji (sprawa świadomości)
  - kojarzenie i wnioskowanie, w tym o charakterze indukcyjnym
  - wykorzystanie konsultacji, dostępnych źródeł najbardziej aktualnej wiedzy dziedzinowej, dodatkowych obserwacji itp.
- Optymalizacja CAD bierze pod uwagę także formalizowane schematy procesów interpretacji przez ekspertów (doskonalenie sposobu użycia CAD)
- **Metoda:** model obliczeniowy (wychodzi z danych) i model wiedzy (wychodzi od doświadczeń), synchronizują się, dopasowują i prowadzą do poznania (rezonans poznaczy)




# Metodologia: zmiana zasadniczej koncepcji obliczeniowej - dostarczyć najlepszą reprezentację informacji (nie naśladować!)


Podójście tradycyjne (REPREZENTACJE RÓŻNICUJĄCE):  
jak policzyć to, co widać (naśladowanie człowieka - rozpoznać)




Rozszerzenie (REPREZENTACJE UPROSZCZONE): pokazać to, co można policzyć (wyliczyć niewidzialne, głęboko) – reprezentacja rzadka, niezmiennicza (rzadka o ustalonym znaczeniu) - uformować z nich uproszczony obraz znaczeń (wspieranie człowieka – wyluskać istotę)




# Postrzeganie innej reprezentacji obrazów – wizualizacja cech osobliwych (wyjątkowych)



to samo lepiej



inne, rzadkie



# Metoda podstawowa: uproszczenie przekazu informacji obrazowej – analogia (nie wprost) do DOD

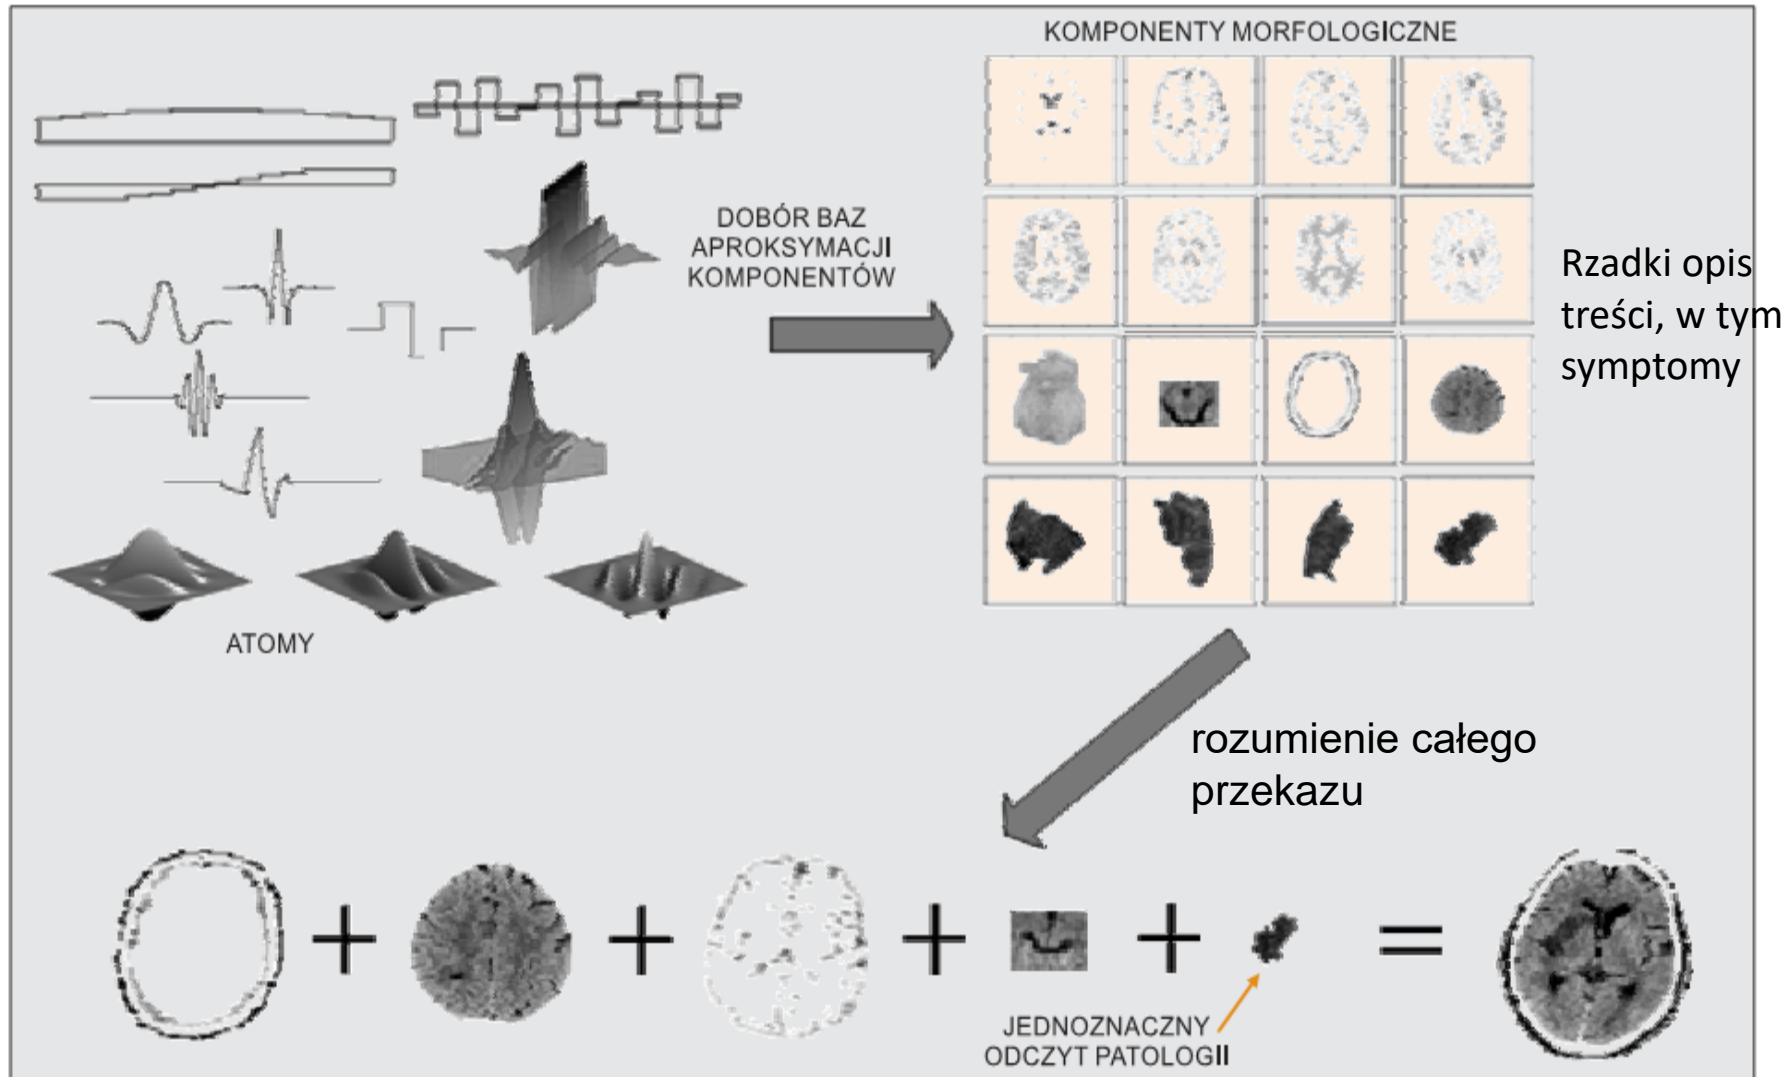
---

- 1) **Potencjalne reprezentacje treści** = **uproszczenie** (źródło, dane, model (reprezentacja rzadka, semantyka), słowniki, ...)
- 2) **Wymowa** = **rozumienie numeryczne** (komponenty treści, wiedza formalna, opis przypadku, zadanie, kontekst kliniczny, ...)
- 3) **Interpretacja wspomagająca** = **przekaz ludzki** (kompresowalna reprezentacja treści, wymowa, zadanie, użytkownik, protokoły, formy raportowania, wizualizacja, ...)


**Efekt : Informacja** (najbardziej istotna) w uproszczonej formie **przekazu służy właściwej interpretacji eksperta**

---

# Wydobywanie komponentów w zintegrowanym opisie całego przekazu (falki-chromosomy?!)




# Metoda podstawowa: klarowność wydobytej informacji (rzadkiej, osobliwej)



- Redukcja nadmiarowości
- Koncentracja na zasadniczych przesłankach do interpretacji
- Pomoc poprzez uproszczenie form wnioskowania, które różnicuje znaczenia




# Klarowność interpretacji

wczesne CT










późne CT

# Uproszczenia różnicujące ...



Coraz oszczędniej  
reprezentujemy



0.005%



---

# **RODZAJE CAD, PODSTAWOWE SCHEMATY I PRZYKŁADY**

---

# Rozróżnienie metod typu CAD

---

**Systemy CADet (komputerowo wspomagana detekcja):**

wyrafinowane metody (algorytmy) detekcji anormalności, tj. regionów, cech, struktur lub obiektów podejrzanych (czyli potencjalnie związanych z patologią)

**Systemy CADx (komputerowo wspomagana diagnoza):** wyrafinowane metody (algorytmy) analizy, rozumienia i interpretacji określonych (wskazanych) anormalności w celu sformułowania prawdopodobnej diagnozy różnicującej wykrytej zmiany - zmiana złośliwa/łagodna/wskazanie fałszywe lub inna skala raportu

Systemy CAD2 jako

$$\text{CAD2} = \text{CADet} + \text{CADx}$$

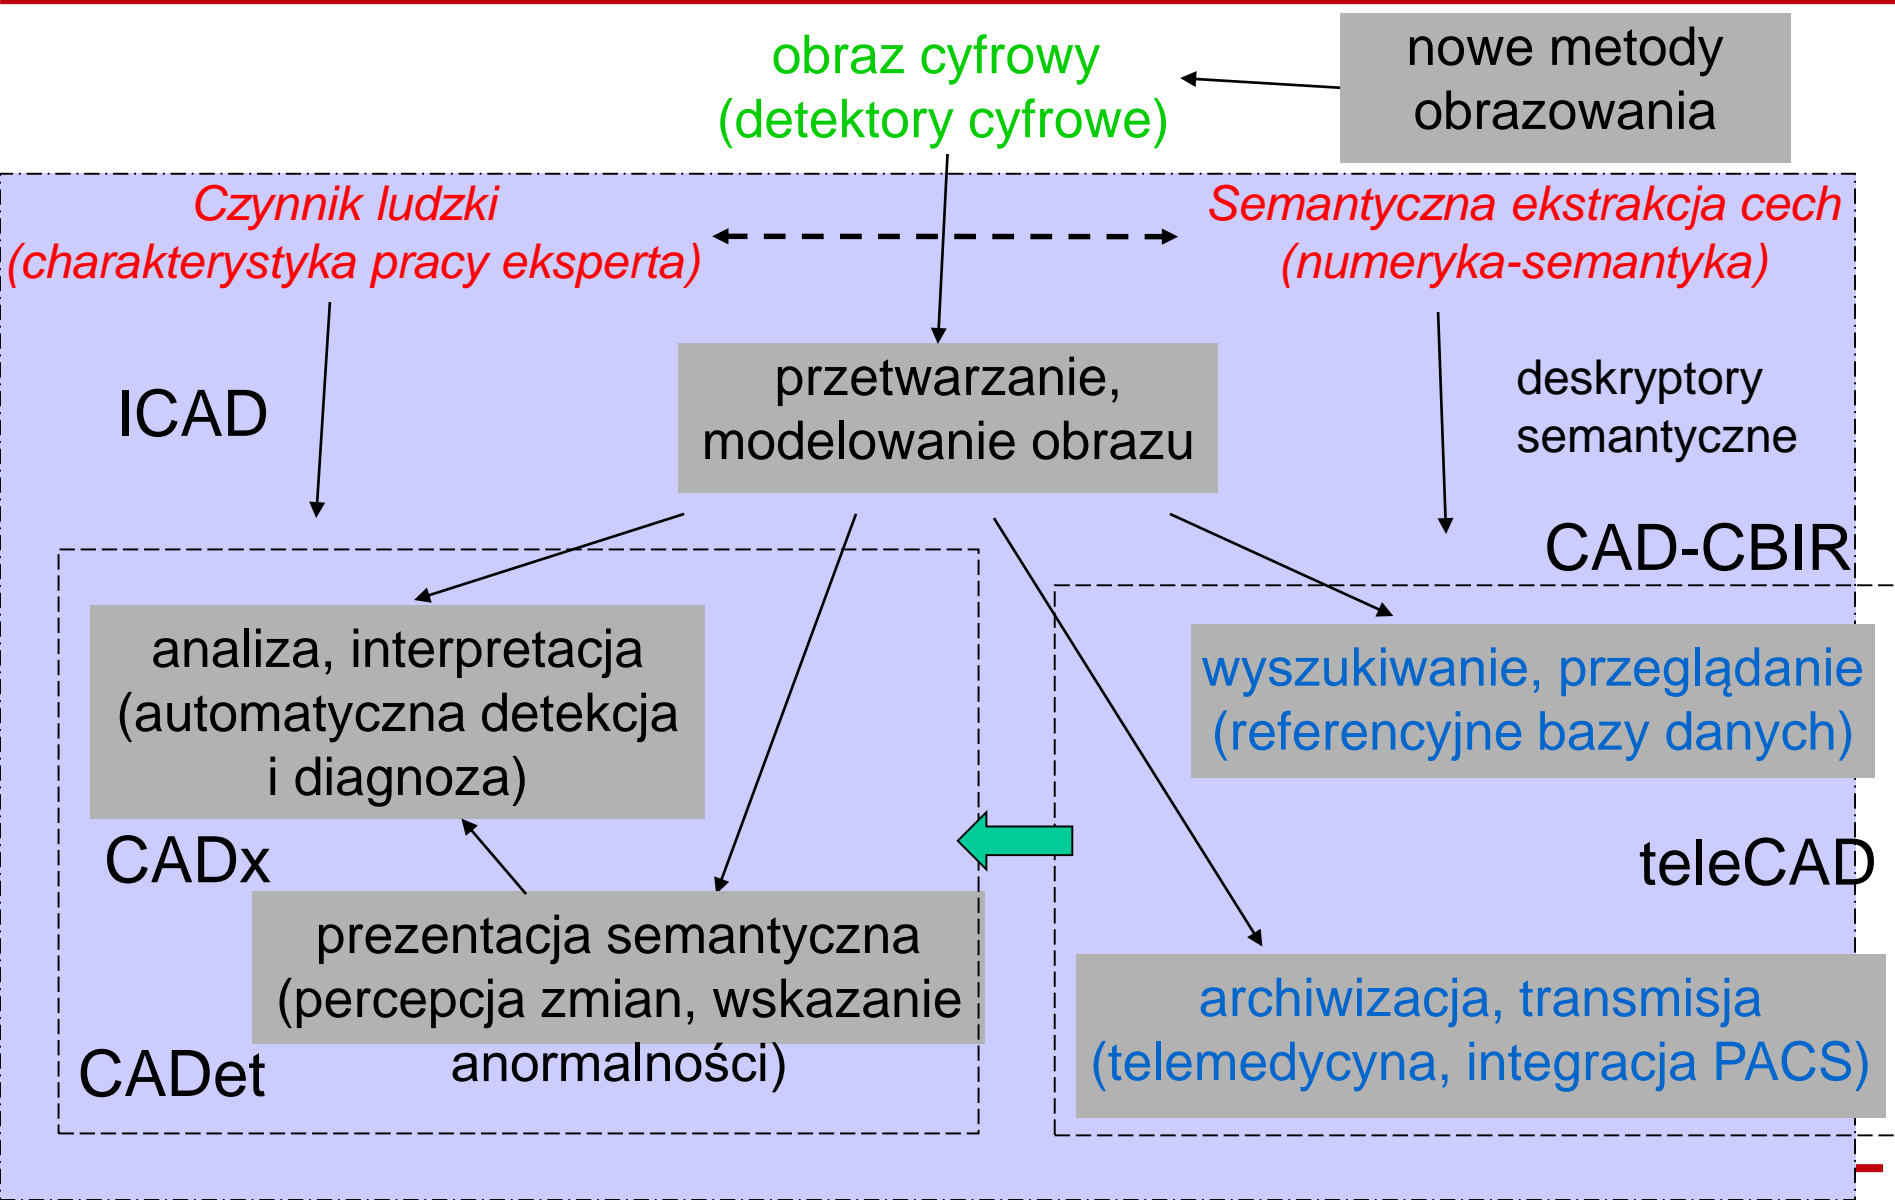
**Systemy ICAD (komputerowo wspomagana diagnoza z interakcją):** wyrafinowane metody (algorytmy) analizy, rozumienia i interpretacji określonych anormalności (CADx) wskazanych i korygowanych poprzez interakcję z użytkownikiem (możliwe wykorzystanie CADet)

$$\text{ICAD} = (\text{CADet}) + \text{CADx} + \text{I}$$


**Teleinformatyczne systemy CAD (TeleCAD, CAD-CBIR)**

---

# Relacja systemów CAD



# Typowe schemat realizacyjny CAD


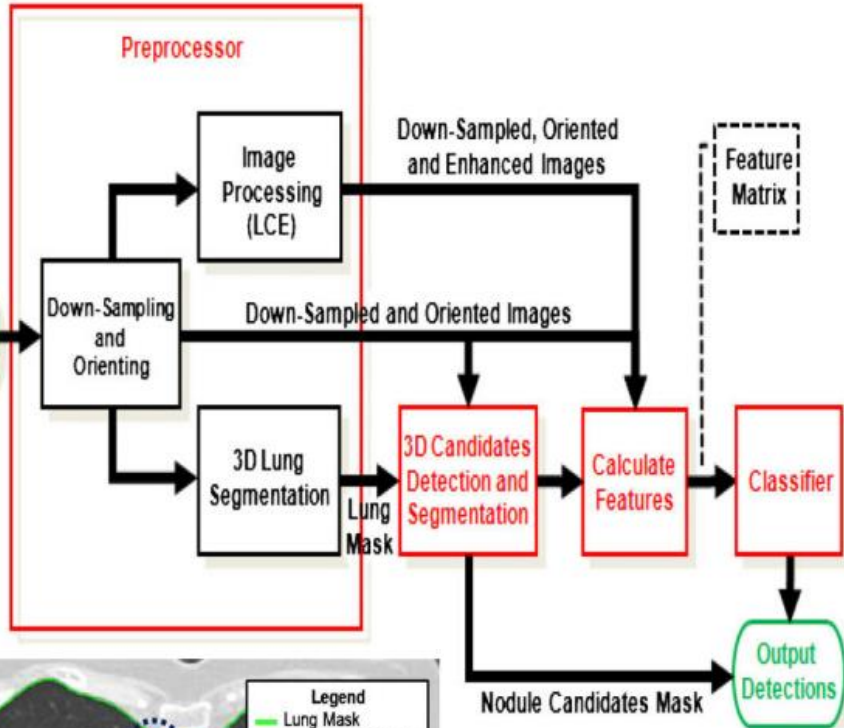









# Guzki w płucach

LCE z jądrem gaussowskim

11x11

51x51










Legend  
 - Lung Mask  
 - Nodule candidates  
 - True Positive




Legend  
 - Lung Mask  
 - TR Segment

Temesguen Messay<sup>a,\*</sup>, Russell C. Hardie<sup>a</sup>, Steven K. Rogers<sup>b</sup>  
 A new computationally efficient CAD system for pulmonary nodule detection in CT imagery  
 Medical Image Analysis 14 (2010) 390–406

# Zmiany wątrobowe

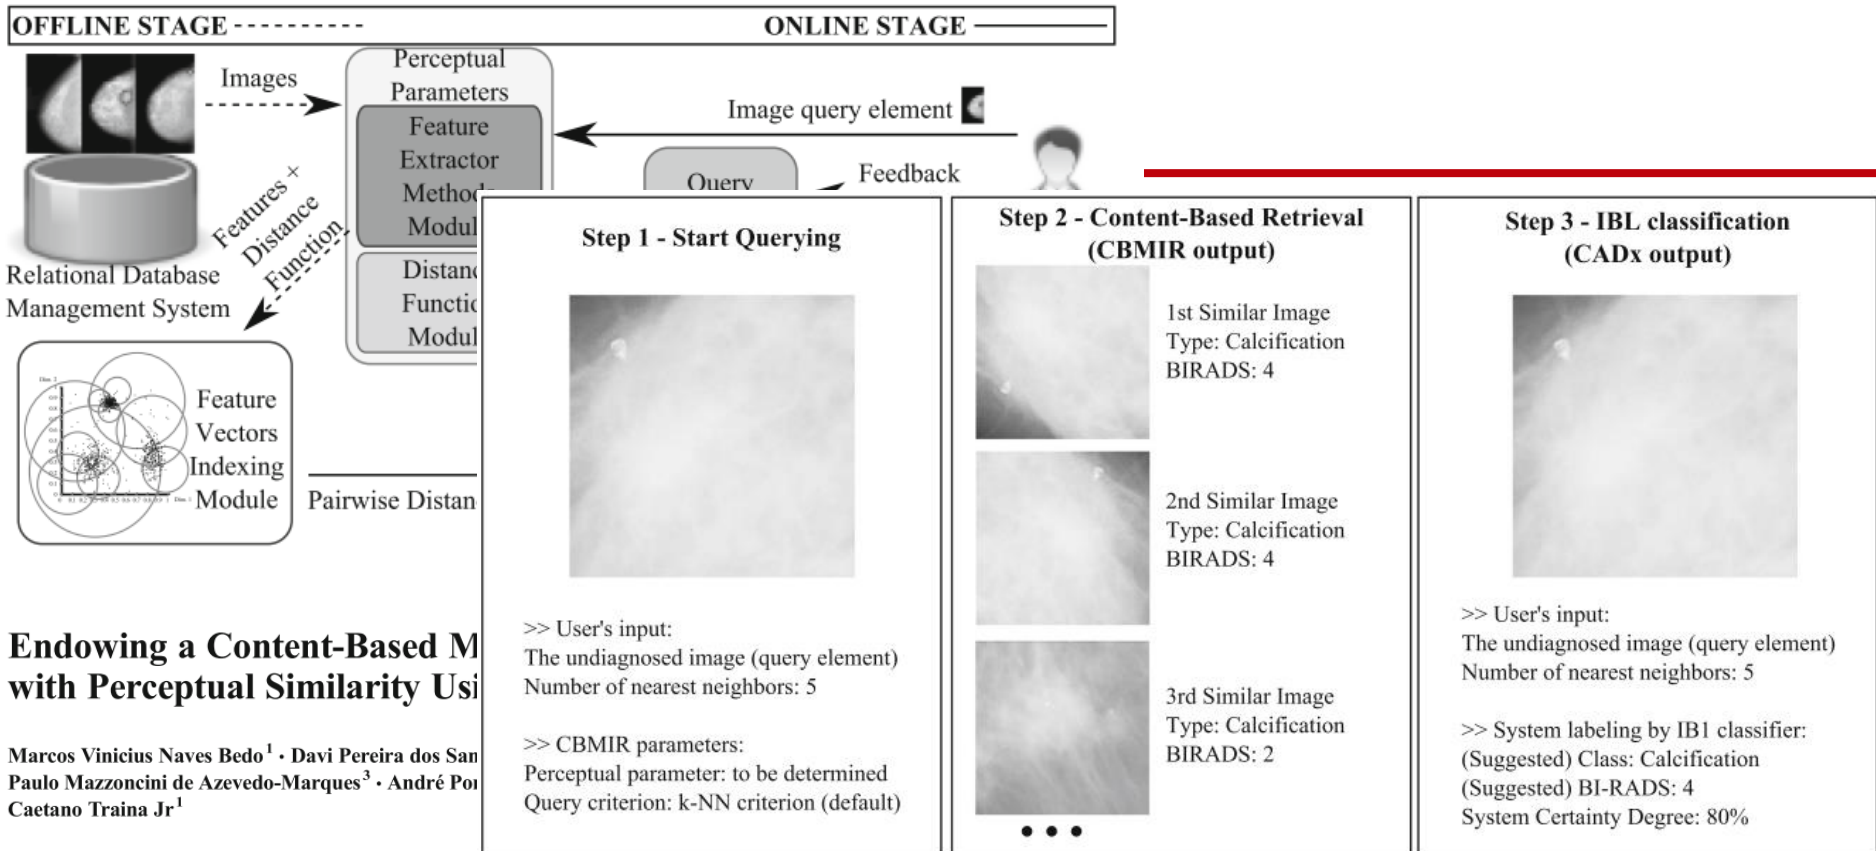


**Fig. 1** Conventional gray scale B-mode liver US images. **a** Normal liver (homogeneous echotexture with medium echogenicity). **b** Typical cyst (thin walled anechoic lesion with posterior acoustic enhancement). **c** Typical HEM (well defined echogenic lesion with posterior acoustic shadowing). **d** Typical MET (center surrounded by echogenic rim).



**Fig. 5** a-e NOR, Cyst, HEM, HCC and MET image with IROIs and SROI marked. Note: For NOR image, all IROIs and SROI are taken at the same depth. A single extreme ROI is considered as SROI. For liver images with lesions, SROI is extracted from background liver parenchyma surrounding the lesion approximately at the same depth as that of the center of the lesion and liver ducts. All IROIs are extracted by cropping IROIs

## Neural Network Ensemble Based CAD System for Focal Liver Lesions from B-Mode Ultrasound

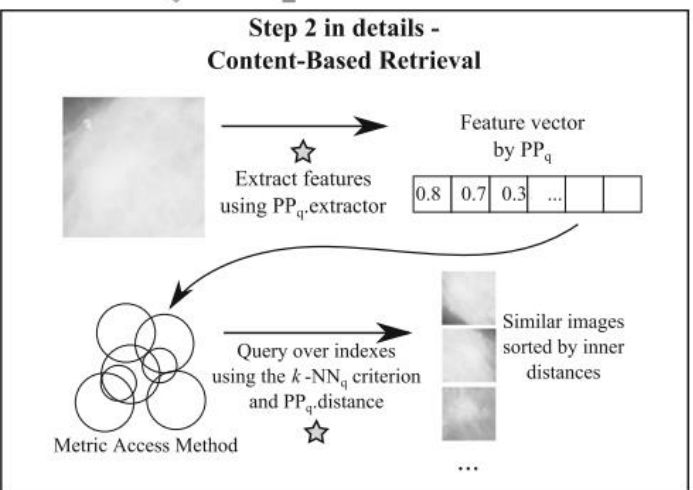
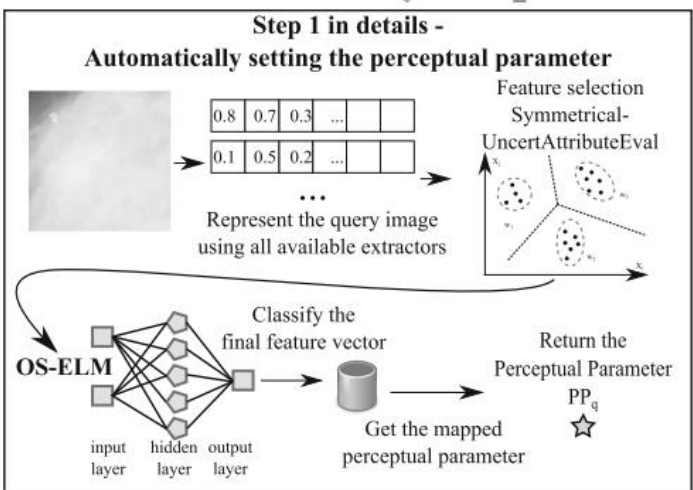


## Endowing a Content-Based M with Perceptual Similarity Usi


Marcos Vinicius Naves Bedo<sup>1</sup> · Davi Pereira dos San  
 Paulo Mazzoncini de Azevedo-Marques<sup>3</sup> · André Poi  
 Caetano Traina Jr<sup>1</sup>

J Digit Imaging (2016) 29:22–37


## IBL-Instance-Based Learning



# Kilka koncepcji zaawansowanych technologii wspomagania



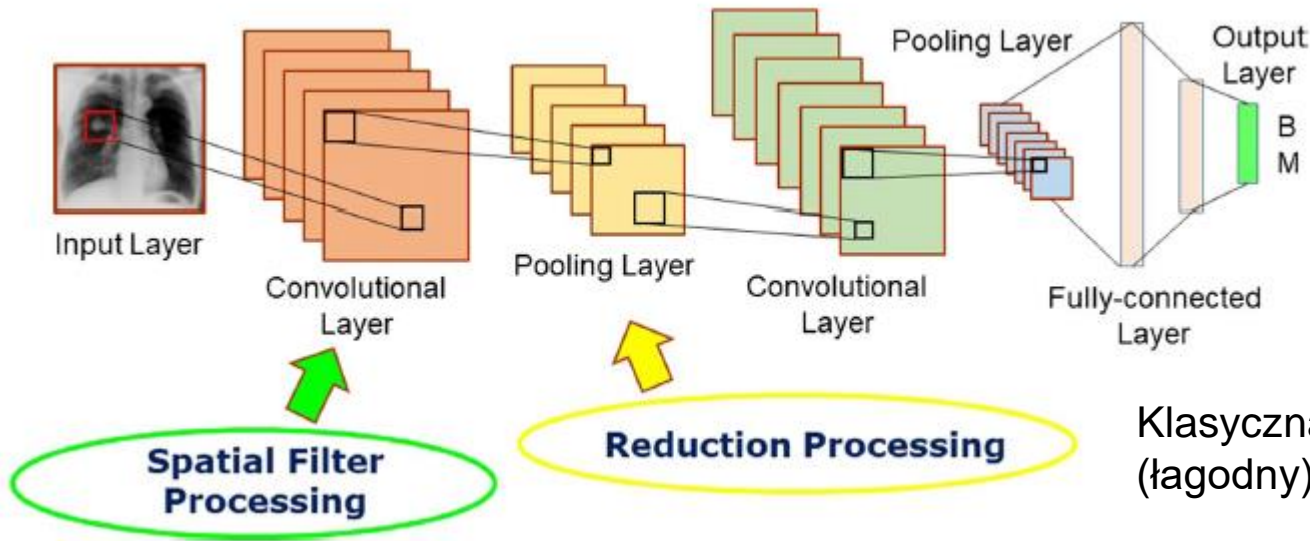
Ogólna architektura systemów eksperckich (ES)



Juri Yanase, Evangelos Triantaphyllou  
 A systematic survey of computer-aided diagnosis in medicine: Past and present developments  
[Expert Systems With Applications 138 \(2019\) 112821](#)




# Przykłady: orientacyjna struktura CNN służąca rozpoznawaniu guzów w radiogramach płuc oraz efekty DL segmentacji



Klasyczna struktura rozpoznania B (łagodny) vs M (złośliwy)


Wzorcowy obrys wykonany przez lekarza




Efekty segmentacji DL

# Poważne problemy – nowotwory złośliwe w Polsce


**RYSUNEK 2.1.** Struktura zachorowań u mężczyzn  
**FIGURE 2.1.** Structure of incidence, males




**RYSUNEK 2.3.** Struktura zgonów u mężczyzn  
**FIGURE 2.3.** Structure of deaths, males



**RYSUNEK 2.2.** Struktura zachorowań u kobiet  
**FIGURE 2.2.** Structure of incidence, females



**RYSUNEK 2.4.** Struktura zgonów u kobiet  
**FIGURE 2.4.** Structure of deaths, females



NOWOTWORY ZŁOŚLIWE W POLSCE  
 W 2020 ROKU

CANCER IN POLAND IN 2020



Urszula Wojciechowska, Klaudia Barańska, Irmina Michalek, Paweł Olasek,  
 Marta Mikiłowska, Joanna A. Didkowska

Publikacja opracowana ze środków finansowych Ministra Zdrowia Narodowej Strategii Onkologicznej, zadanie „Wspomaganie systemu rejestracji nowotworów”.  
 This report is published within „Cancer Registration” task by the National Cancer Strategy.

ISSN 0667-8251  
 Warszawa 2022

---

# **WSPOMAGANIE DIAGNOSTYKI CHOROÓB PŁUC**

---

# Przykład: wspomaganie diagnostyki chorób płuc

- zapalenie oskrzeli, zapalenie płuc, astma oskrzelowa, gruźlica, mukowiscydoza, odma opłucnowa, przewlekła obturacyjna choroba płuc, pylica płuc, rozstrzenie oskrzeli, sarkoidoza, śródmiąższowe choroby płuc, nowotwory ...



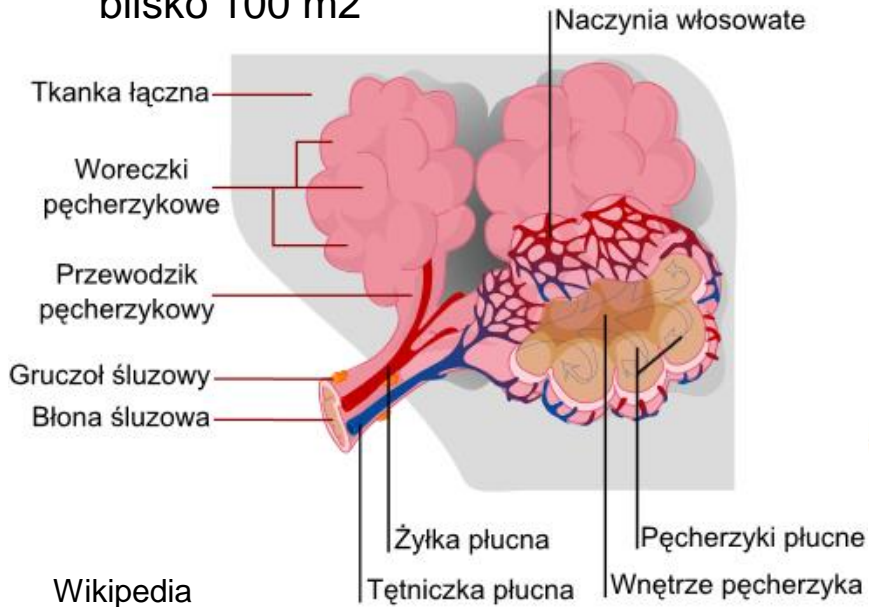
gruźlica obustronna



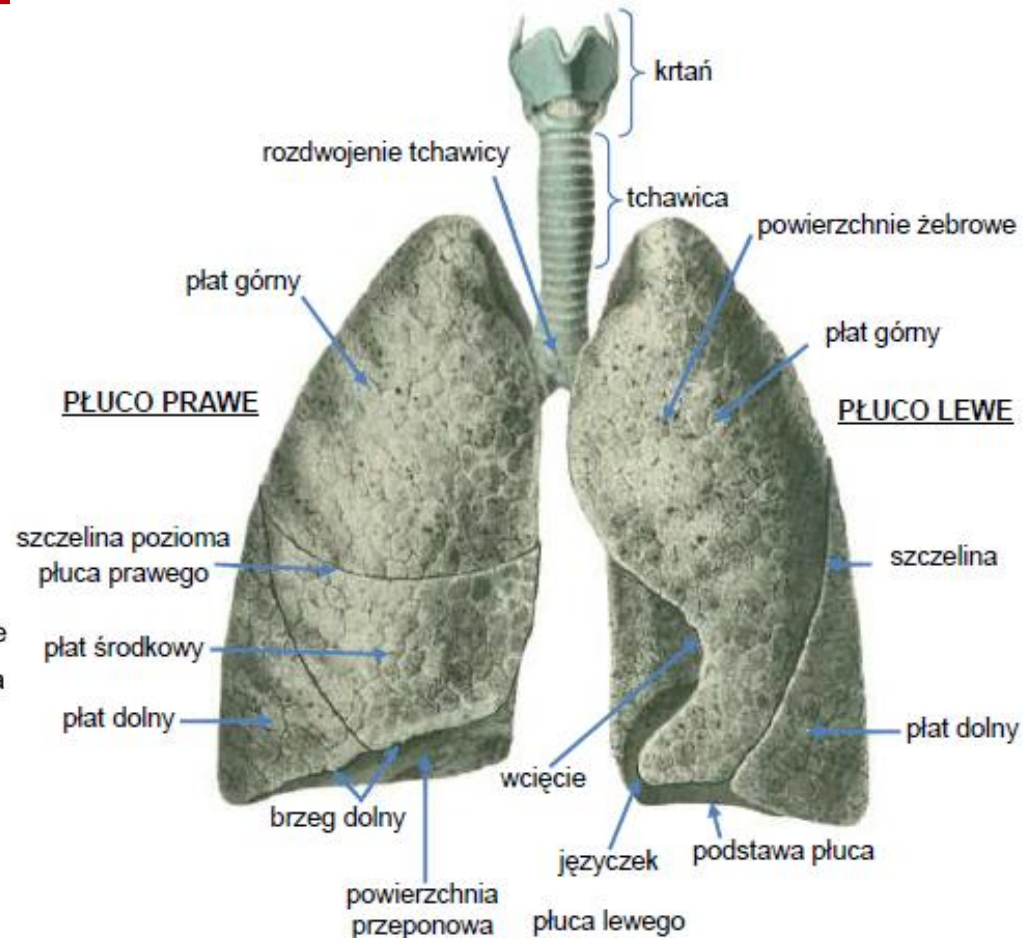
zwłóknienie płuc

# Płuca, czyli model diagnostyczny

- Budowa pęcherzykowa, powierzchnia blisko 100 m<sup>2</sup>



Wikipedia



[http://anatomic.w.interia.pl/ukl\\_odd.html](http://anatomic.w.interia.pl/ukl_odd.html)

*Jaka jest wzajemna relacja choroby i zobrazenia?*


# Rak płuca (oskrzela) – etiologia i epidemiologia

## Podział histologiczny

- Rak płaskonabłonkowy brodawkowy, jasnokomórkowy, drobnokomórkowy, bazaloidny
- Rak anaplastyczny drobnokomórkowy: mieszany
- Rak gruczołowy: zrazikowy, brodawkowy, oskrzelikowo-pęcherzykowy, lity, z produkcją śluzu, mieszany + warianty, wysokozróżnicowany płodowy, śluzowy, torbielowaty, śluzowy, z komórek sygnetowatych, z komórek jasnych
- Rak anaplastyczny wielokomórkowy + warianty: neuroendokryny, bazaloidny, typu lymphoepithelioma, z komórek jasnych, rabdoidny
- Rak mieszany: gruczołowo-płaskonabłonkowy
- Rakowiak: typowy i atypowy
- Raki gruczołów oskrzelowych: śluzowo-naskórkowy, gruczołowo-torbielowaty i inne

## Podział kliniczny

<b>Częstość występowania nowotworów złośliwych płuca</b>	
Typ histologiczny	Częstość (%)
Niedrobnokomórkowy rak płuca	80,4
Drobnokomórkowy rak płuca	16,8
Rakowiak	0,8
Mięsak	0,1
Nieokreślony rak płuca	1,9



# Skala problemu i rola metod obrazowania - duże znaczenie radiografii płuc



A Century of Radiology at <http://www.xray.hmc.psu.edu/rci>

- najczęstsza przyczyna zgonów na raka (28%)  
– rocznie na świecie umiera 1,3 mln osób
- w USA 160 tys. osób rocznie umiera na raka płuc (*dane z sierpnia 2005*), w Polsce – *ponad 23 tys.*
- szansa przeżycia to **9-12%** przy wykryciu raka w bardziej zaawansowanym stadium
  - rośnie do **40-70%** przypadku wczesnej detekcji raka
- zadanie: **wspomaganie badań przesiewowych !!!**




Bram van Ginneken 'Computer-aided diagnosis in chest radiography'  
PhD thesis 2001

# Zobrazowane przypadki raka

THYMOMA





grasiczak





# Zestawienie metod


## obrazowania ze schematycznym zastosowaniem




Badanie	Charakterystyka
Zdjęcie rentgenowskie klatki piersiowej	ocena nieprawidłowości/anormalności w obrazie
	<b>duża dostępność</b>
<u>Tomografia komputerowa</u>	<b>określenie rozmiaru, kształtu i lokalizacji guza</b>
	<b>identyfikacja powiększonych węzłów chłonnych</b>
	<b>diagnoza guzów zlokalizowanych w nadnerczach, mózgu i innych narządów - przerzuty</b>
Rezonans magnetyczny	lokalizacja przerzutów
Pozytonowa Tomografia Emisyjna	ocena zajęcia węzłów chłonnych
	lokalizacja przerzutów
Biopsja cienkoigłowa	pobranie materiału do badań laboratoryjnych
<u>Bronchoskopia</u>	bezpośredni obraz guza
	możliwość pobrania próbki guza do badań

# Radiografia klatki piersiowej

prawe płuco



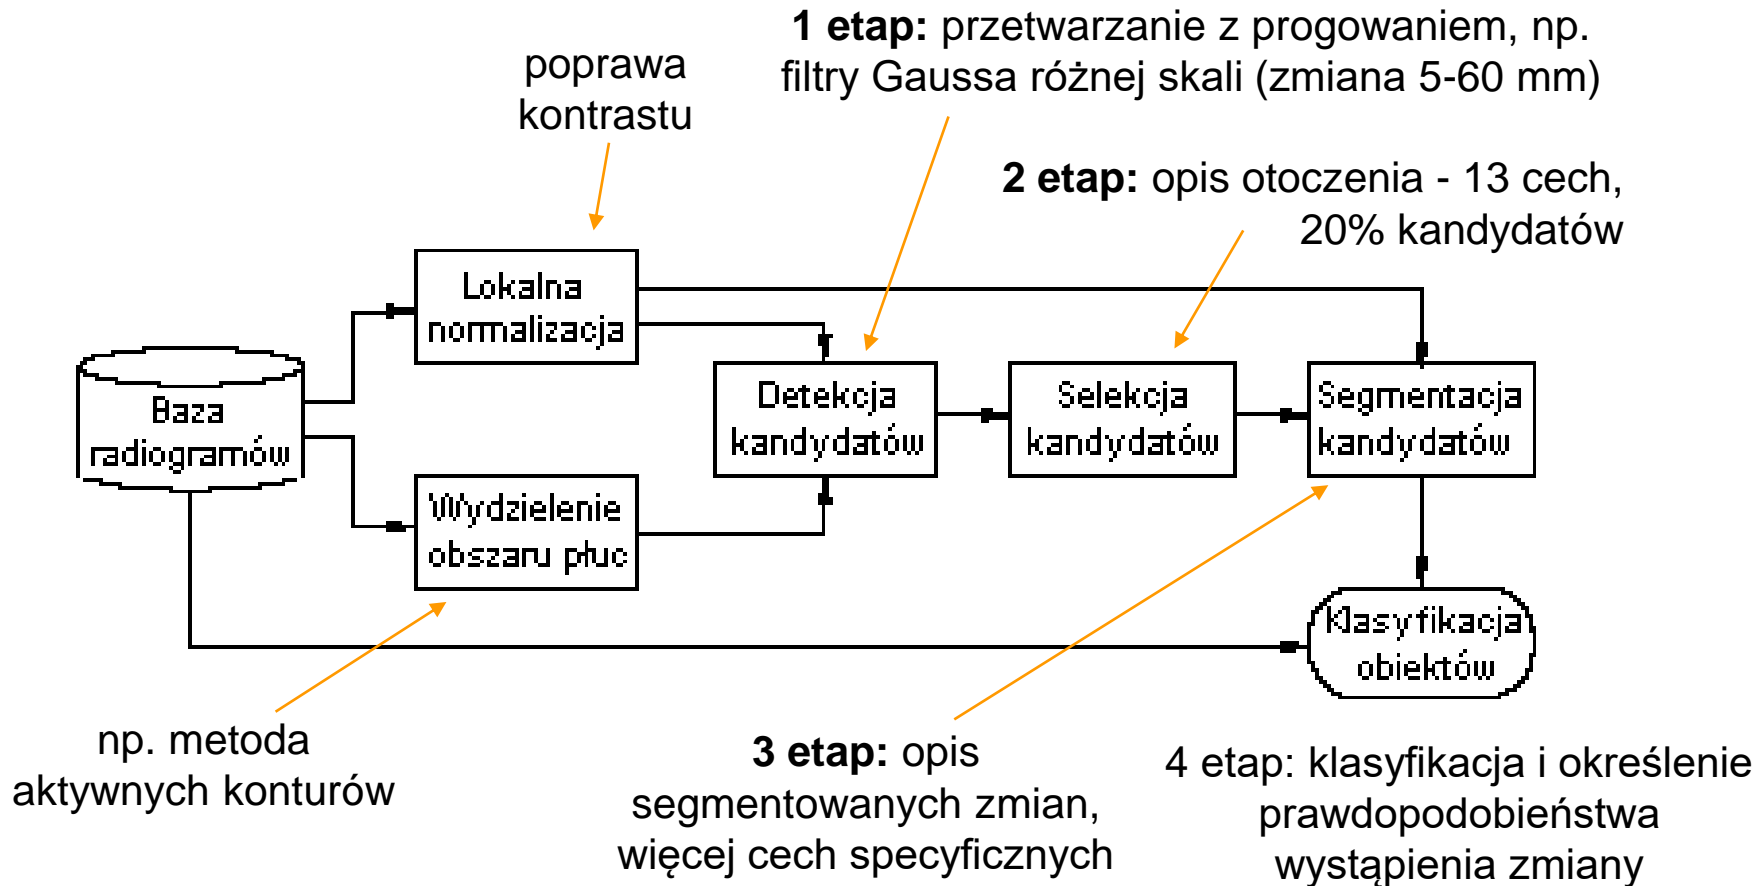
przykładowe patologie



1) serce 2) łuk aorty 3) wejście naczyń do lewego płuca  
4) tchawica 5) przepona 6) obojczyk 7) łopatką 8) gazy  
żołądkowe 9) kręgosłup 10) cień naczynia równoległego  
do wiązki

Bram van Ginneken 'Computer-aided diagnosis in  
chest radiography' PhD thesis 2001

# Detekcja raka w radiografii płuc (1/2) - przykład



# Detekcja raka w radiografii płuc (2/2) – skala trudności problemu



oryginał




poprawa kontrastu




detekcja kandydatów




selekcja kandydatów




krzywe FROC




zmiana



detekcja




segmentacja



segmentacja (z przetwarzaniem)

# Tradycyjna analiza efektów rozpoznania


		Warunki wyznaczone przez „złoty standard”		Wartości predykcyjne
		Patologia	Norma	
Wynik testu	Dodatni (+)	Prawdziwie dodatni <i>True Positive, TP</i>	Falszywie dodatni <i>False Positive, FP</i> (błąd I rodzaju)	<b>Dodatnia</b> PPV=TP/(TP+FP)
	Ujemny (-)	Falszywie ujemny <i>False Negative, FN</i> (błąd II rodzaju)	Prawdziwie ujemny <i>True negative, TN</i>	<b>Ujemna</b> NPV=TN/(TN+FN)
Współczynniki oceny jakości testu		Czułość = $TP/(TP+FN)$	Specyficzność = $TN/(TN+FP)$	



- Reprezentatywny zbiór badań testowych
- Detekcja obiektu/obiektów (np. patologii)
- Czułość, specyficzność
- Krzywa ROC, modyfikacje
- Weryfikacja hipotez statystycznych (czasochłonność, obiektywizacja ocen ekspertów, zapewnienie wiarygodnych/realnych warunków testu)

# Optymalizacja: możliwie wiarygodna baza testowa – baza JSRT

- JSRT (Japanese Society of Radiological Technology); baza ta została utworzona przez Japońskie Towarzystwo Radiologiczne (Japanese Radiological Society) w 1998
- baza cyfrowych zdjęć rentgenowskich klatki piersiowej
- otwarta do celów naukowych: [http://www.jsrt.or.jp/web\\_data/english03.php](http://www.jsrt.or.jp/web_data/english03.php)
- 93 przypadki obrazów pacjentów zdrowych oraz 154 obrazy pacjentów z udokumentowanymi wystąpieniami guzów o średnicach od 5 mm do 60 mm
- rozdzielczość 2048x2048, rozmiar piksela 0,175x0,175 mm<sup>2</sup>, 12 bitów dynamiki, format raw
- podane: wiek i płeć pacjenta, średnica oraz lokalizacja guza, diagnoza (guz złośliwy lub łagodny)
- **~subtelność: 5 - bardzo wyraźny, 4 - wyraźny, 3 - stosunkowo wyraźny, 2 – mało wyraźny, 1 - niewyraźny**
- normy (wiele niejasności)
- przykłady wczesnego stadium rozwoju nowotworu, przedstawiające jeden guz na zdjęciu



# Metoda detekcji guzów – przykładowa realizacja A.Niecieckiej



oryginał



wyrównanie histogramu



lokalna normalizacja



unsharp masking



CLAHE

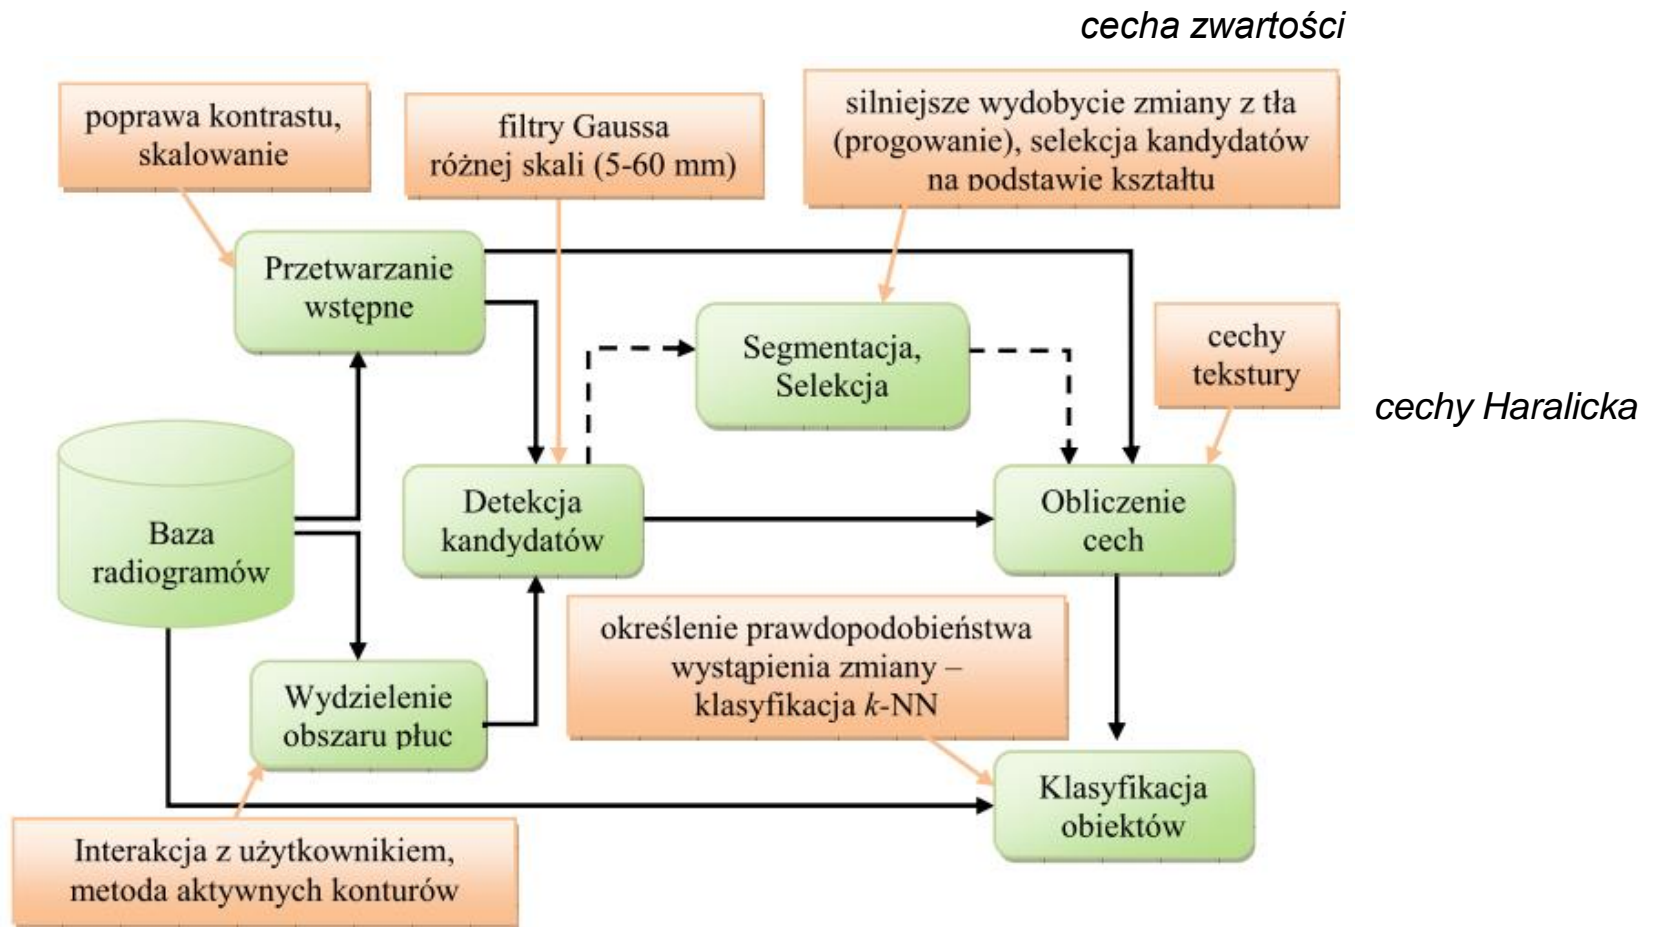


lokalna normalizacja + CLAHE

---

CLAHE - Contrast Limited Adaptive Histogram Equalization

# Schemat metody




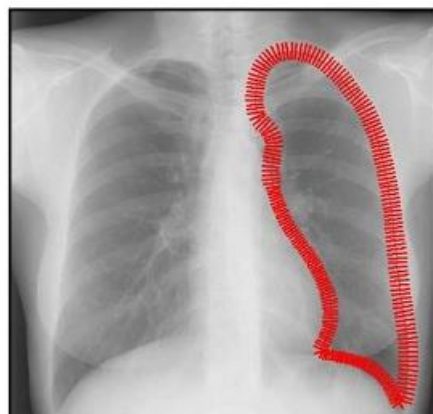







# Lokalna normalizacja kontrastu, segmentacja AC

$$g(x, y) = \frac{f(x, y) - m_f(x, y)}{\sigma_f(x, y)}$$

lokalna normalizacja (LCE – local contrast enhancement)  
segmentacja płuc



# Segmentacja kandydatów

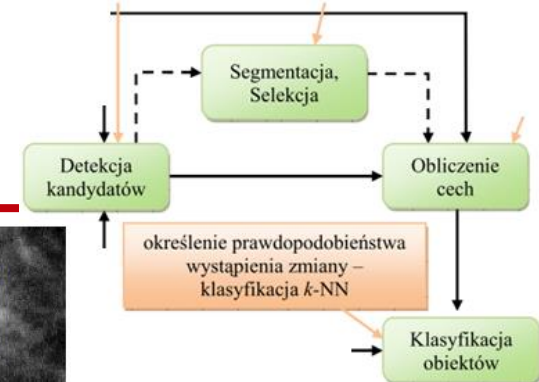


*a) wskazania detektora, b) binaryzacja obrazu znormalizowanego metodą Otsu, c) wysegmentowane obiekty, uzyskane w wyniku iloczynu wskazań detektora oraz obrazu zbinaryzowanego*






- Wybór maksimum filtracji Gaussa z różnym rozmiarem maski
- Progowanie Otsu - próg binaryzacji ustalany jest na podstawie minimalizacji wartości sumy ważonej wariancji dwóch klas zawartych w histogramie: tła i obiektu
- Iloczyn efektu binaryzacji i wskazań detektora kandydatów
- Tworzenie obiektów spójnych za pomocą operatorów morfologicznych
- Liczenie cech: m.in. współczynnik zwartości (1 dla koła, dla innych figur mniej)

$$R_Z = \frac{4\pi S}{l^2}$$

# Detekcja kandydatów (wyostrzenie f.laplasjanowym, liczenie cech, klasyfikacja)



Liczenie cech



		Wartość rzeczywista		Suma
		Guz	Obszar zdrowy	
Wynik klasyfikacji	Guz	34	8	42
	Obszar zdrowy	6	52	58
Suma		40	60	100

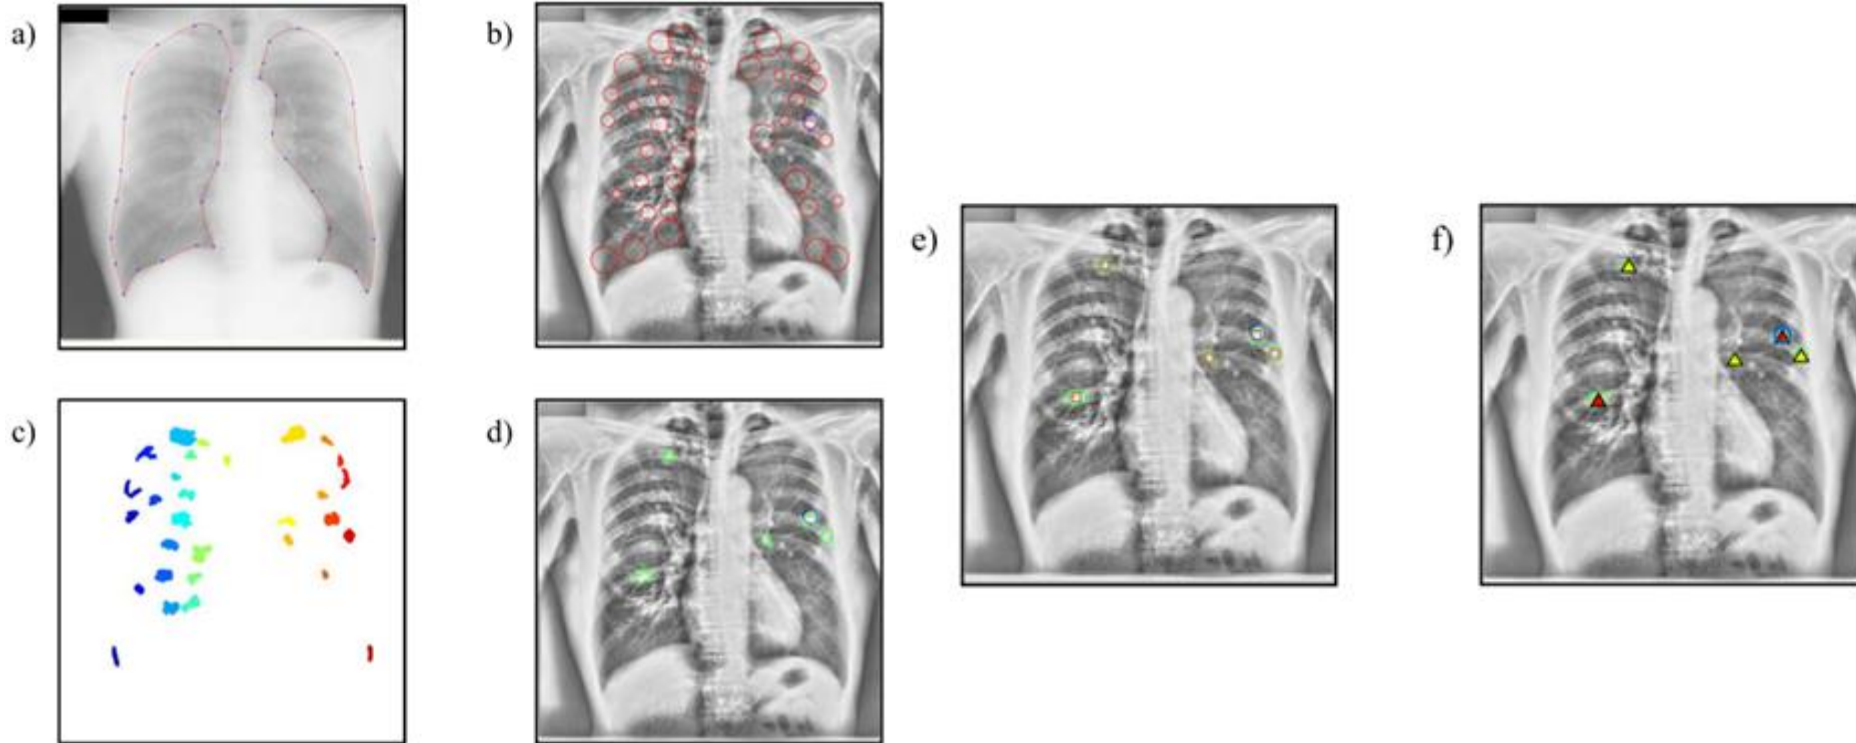
łatwiejsze (4-5)

Ilość cech	Stopień widoczności	Czułość	Specyficzność
5	dobry	0,375	0,85
19	dobry	0,85	0,87
19	słaby	0,475	0,75
19	wszystkie	0,57	0,85

trudniejsze (1-3)

		Wartość rzeczywista		Suma
		Guz	Obszar zdrowy	
Wynik klasyfikacji	Guz	19	15	34
	Obszar zdrowy	21	45	66
Suma		40	60	100


# Efekty rozpoznania - przykład




*Etapy schematu detekcji z uwzględnieniem kroku selekcji kandydatów*  
*a) wydzielenie obszaru płuc, b) detekcja kandydatów na obrazie poddanym lokalnej normalizacji, c) segmentacja obiektów, d) kandydaci po selekcji pod względem kształtu, e) obliczenie cech tekstury dla kandydatów, f) prawidłowa klasyfikacja stanu patologicznego oraz jedno wskazanie FP*

# Problem selekcji kandydatów

Ten sam przypadek bez selekcji kandydatów  
(brak oceny kształtu)



Inne przypadki z błędnymi wskazaniami



wskazanie  
fałszywe

trafił

*Etapy schematu detekcji nie uwzględniającego kroku selekcji*


- a) wydzielenie obszaru płuc, b) detekcja kandydatów na obrazie poddanym lokalnej normalizacji, c) obliczenie cech tekstury dla zdetekowanych kandydatów, d) prawidłowa klasyfikacja stanu patologicznego oraz trzy wskazania FP*

# Wspomaganie badań CT

## Dobór grubości warstwy




40 obrazów (mała rozdzielczość przestrzenna)



400 obrazów (większa rozdzielczość przestrzenna, ale zbyt dużo obrazów do ręcznego przeglądania)

# Cel

- detekcja mikroguzków  $< 5\text{mm}$  z dużą czułością
- odróżnienie mikroguzków od naczyń (zmniejszenie FP)



gdzie są 2 mikroguzki?

# Segmentacija (1/3)


---






# Segmentacja (2/3)

---




# Segmentacja (3/3)




# Detekcja obiektów (1/2)

---



## Detekcja obiektów (2/2)

---




# Metoda (dopasowanie do modelu patologii)

---


- segmentacja wielu regionów (w różnej konfiguracji podziału)
  - wyznaczenie poziomu zgodności regionów przy ustalonym zestawie cech
  - wybór regionów z najwyższym poziomem zgodności (względem siebie oraz wzorca)
  - ustalenie znaczenia tych regionów
-

# Symulacja CAD (1/16)




warstwa 1

# Symulacja CAD (2/16)



warstwa 2


# Symulacja CAD (3/16)



warstwa 3




# Symulacja CAD (4/16)




warstwa 4

# Symulacja CAD (5/16)




warstwa 5

# Symulacja CAD (6/16)




warstwa 6

# Symulacja CAD (7/16)




warstwa 7

# Symulacja CAD (8/16)




warstwa 8

# Symulacja CAD (9/16)




warstwa 1

# Symulacja CAD (10/16)



warstwa 2


# Symulacja CAD (11/16)



warstwa 3




# Symulacja CAD (12/16)




warstwa 4

# Symulacja CAD (13/16)




warstwa 5

# Symulacja CAD (14/16)




warstwa 6

# Symulacja CAD (15/16)



warstwa 7

# Symulacja CAD (16/16)



warstwa 8

# Komercyjne systemy CAD do raka płuc

- Radiografia i TK
- Guzy **2-8** mm (zanotowano więcej złośliwych przypadków dla guzków większych) - olbrzymie wyzwanie: wczesna detekcja raka!!!
- Akceptacja systemów CAD
  - radiografia - detekcja i pomiary guzków: IQQA-Chest firmy EDDA Technologies/Philips (FDA - 2004), xLNA firmy Philips Medical Systems (wykrywa guzki o średnicy od 5 mm), Rapid Screen CAD firmy Riverain Medical (pierwszy system CAD do rentgenografii płuc zatwierdzony przez FDA w 2001 roku), Lung VCAR firmy GE Healthcare
  - TK - Syngo Lung CAD firmy Siemens Medical Solutions (zatwierdzony przez FDA, wykrywa guzki poniżej 3 mm), CAD-Lung firmy Median Technologies, CADLung firmy Medicsight, ImageChecker Lung CT firmy Hologic/R2 Technology (zatwierdzony przez FDA w 2001)
- CAD z 2006 (*American Medical Association issued a Category III CPT*) - w testach (33 radiologów, 200 badań, 6 ośrodków) zanotowano **23% wzrost** czułości detekcji guzków
  - Integracja CAD z PACS (Utah Imaging Associates)
  - Śledzenie zmian wymiarów guzków, detekcja **ciemniejszych, nieregularnych** zmian (bardziej złośliwych),
  - Dobry interfejs do badań TK, **czułość regulowana przez radiologa**
- Cel: wzrost czułości i redukcja wskazań fałszywych, by dorównać efektywności wspomaganie mammografii


# Lung Image Database Consortium (LIDC)

<http://imaging.cancer.gov/programsandresources/InformationSystems/LIDC>

- Badania TK - baza danych do oceny i optymalizacji systemów CAD
- 'Złoty standard', czyli *trafna interpretacja* badań obrazowych
- Wiarygodne miary efektywności algorytmów, sposoby oceny, weryfikacji
- Standardy formatów, przetwarzania i zarządzania informacją obrazową w celach
  - utworzenia referencyjnej bazy do badań CAD
  - zapewnienia elastycznego dostępu do weryfikujących danych klinicznych, wyników ocen innych algorytmów, zestawień, porównań


The screenshot shows the National Cancer Institute website. At the top, there is a red header with the National Cancer Institute logo and the text "National Cancer Institute" and "National Institutes of Health | www.cancer.gov". Below the header, the "Cancer Imaging Program" is prominently displayed. A navigation menu on the left includes "Home", "About CIP", "Research Funding", "Programs & Resources", "Clinical Trials", "Reports & Publications", "News & Meetings", and "Imaging Information". The "Programs & Resources" section is expanded, showing "Specialized Initiatives" and "Information Systems". The "Information Systems" section is further expanded to show "Ultrasound Research Interface", "Bioinformatics & Bioengineering", "Funded Research", and "NIH Roadmap". The main content area features a banner for "Lung Image Database Consortium (LIDC)" with a background image of a person at a computer. Below the banner, there is a section titled "Lung Image Database Consortium (LIDC)" with a sub-section "Lung Image Archive at NBIA (National Biomedical Image Archive)". The text describes the purpose of the LIDC initiative: to support a consortium of institutions to develop consensus guidelines for a spiral CT lung image resource and to construct a database of spiral CT lung images. The text also mentions that the investigators funded under this initiative created a set of guidelines and metrics for database use and for developing a database as a test-bed and showcase for those methods. On the right side of the LIDC section, there is a list of links: "Introduction", "Mission & Goals", "Implementation Objectives", "LIDC Committees", "Reports, Presentations & Publications", "Cornell University", "University of California, Los Angeles", "University of Chicago", "University of Iowa", and "University of Michigan".

# Przykłady (LIDC)






guzek?







# Przykłady (LIDC)

---







# Zróżnicowanie zmian



obrysy

# Zróżnicowanie ocen – doskonalenie segmentacji




# ANODE09 - Automatic Nodule Detection 2009

<http://anode09.grand-challenge.org/>

- Realizacja paradygmatu: ewolucja przez współzawodnictwo
- Porównanie efektywności automatycznych systemów detekcji guzków nowotworowych w CT klatki piersiowej
  - Możliwość obiektywnej weryfikacji własnych algorytmów
  - Publiczna ocena skuteczności CAD, progresji w doskonaleniu metod (*state of the art*)
- Referencyjna baza 55 przypadków (University Medical Center Utrecht, NELSON study, głównie mężczyźni – palacze, 50–75 lat, skanery 16 lub 64 rzędowe)
  - 5 skanów z opisem i 50 skanów testowych bez opisu
  - opis uwzględnia zmiany istotne i nieistotne (małe prawdopodobieństwo raka, np. bardzo małe guzy czy guzy uwapnione) – zmiany nieistotne nie są wliczane do statystyk oceny
- Ocena: lista wykrytych zmian, ich lokalizacja i prawdopodobieństwo złośliwości

```
test07 108 212 254.443 0.313433
test20 228 234 106.316 0.791044
test14 94 328 316 0.432836
test41 218 298 109 561 0.238806
test04 388 156 363 0.432836
test04 182 401 238 0.865671
test08 330 306.8 148.8 0.820895
test01 116 124 45 0.373134
test15 194 208 312 0.507463
```



Przykłady zmian istotnych i nieistotnych

# ANODE09 - wyniki




## Results

Below the submitted results so far are listed. Click on the score of a method to see detailed results.


Methods that have checkboxes in front of them can be combined. Check a number of boxes and press Combine to see the results of the combined system. The combination method that is used is described in [this report](#).

<input type="checkbox"/> Team	Date	Score	Description
<input type="checkbox"/> ISICAD	December 20, 2008	<a href="#">0.632</a>	System E in <a href="#">this paper</a> .
<input type="checkbox"/> FlyerScan	September 25, 2009	<a href="#">0.552</a>	<a href="#">System description</a> .
<input type="checkbox"/> MIG Group	August 3, 2010	<a href="#">0.310</a>	Not yet publicly available.
<input type="checkbox"/> Pisa team	January 26, 2009	<a href="#">0.293</a>	System D in <a href="#">this paper</a> .
<input type="checkbox"/> RG-MAGIC-CAD	May 21, 2009	<a href="#">0.291</a>	System B in <a href="#">this paper</a> .
<input type="checkbox"/> MIG Group	August 3, 2010	<a href="#">0.289</a>	Not yet publicly available.
<input type="checkbox"/> RG-MAGIC-CAD	January 20, 2009	<a href="#">0.266</a>	<a href="#">System description</a> .
<input type="checkbox"/> MAGIC-5-ANTS	January 23, 2009	<a href="#">0.254</a>	System C in <a href="#">this paper</a> .
<input type="checkbox"/> Philips Lung Nodule CAD	May 29, 2009	<a href="#">0.231</a>	System F in <a href="#">this paper</a> .
<input type="checkbox"/> FujitaLab	August 26, 2008	<a href="#">0.212</a>	System A in <a href="#">this paper</a> .
<input type="checkbox"/> CMP Prague	December 24, 2008	<a href="#">0.065</a>	<a href="#">System description</a> .
<input type="checkbox"/> IMPS	July 30, 2008	<a href="#">0.003</a>	<a href="#">System description</a> .

# Wyniki dla zmian istotnych i nieistotnych



- A+B+C+D+E+F
- A+B+C+D+F
- C+D
- E
- D
- C
- B
- F
- A



Medical Image Analysis 14 (2010) 707–722



ELSEVIER

Contents lists available at ScienceDirect

Medical Image Analysis

journal homepage: [www.elsevier.com/locate/media](http://www.elsevier.com/locate/media)



Comparing and combining algorithms for computer-aided detection of pulmonary nodules in computed tomography scans: The ANODE09 study

Bram van Ginneken<sup>a,b,\*</sup>, Samuel G. Armato III<sup>c</sup>, Bartjan de Hoop<sup>d</sup>, Saskia van Amelsvoort-van de Vorst<sup>d</sup>, Thomas Duindam<sup>a</sup>, Meindert Niemeijer<sup>a</sup>, Keelin Murphy<sup>a</sup>, Arnold Schilham<sup>a</sup>, Alessandra Retico<sup>e</sup>, Maria Evelina Fantacci<sup>e,f</sup>, Niccolò Camarlinghi<sup>e,f</sup>, Francesco Bagagli<sup>e,f</sup>, Ilaria Gori<sup>e,g</sup>, Takeshi Hara<sup>h</sup>, Hiroshi Fujita<sup>h</sup>, Gianfranco Gargano<sup>ij</sup>, Roberto Bellotti<sup>ij</sup>, Sabina Tangaro<sup>j</sup>, Lourdes Bolaños<sup>k,l</sup>, Francesco De Carlo<sup>j</sup>, Piergiorgio Cerello<sup>k</sup>, Sorin Cristian Cheran<sup>k</sup>, Ernesto Lopez Torres<sup>l</sup>, Mathias Prokop<sup>d,b</sup>





# Wyniki szczegółowe (1 wskazanie fałszywe na obraz)





Combination	Score	Best single	$\Delta$
■□□□□□		0.212	
□■□□□□		0.291	
□□■□□□		0.254	
□□□■□□		0.293	
□□□□■□		0.632	
□□□□□■		0.231	
■■□□□□	0.371	0.291	0.080
■□■□□□	0.336	0.254	0.082
■□□■□□	0.372	0.293	0.079
■□□□■□	0.606	0.632	-0.026
■□□□□■	0.330	0.231	0.099
□■■□□□	0.437	0.291	0.146
□■□■□□	0.468	0.293	0.175
□■□□■□	0.604	0.632	-0.028
□■□□□■	0.413	0.291	0.122
□□■■□□	0.471	0.293	0.178
□□■□■□	0.659	0.632	0.027
□□■□□■	0.361	0.254	0.107
□□□■■□	0.636	0.632	0.004
□□□■□■	0.445	0.293	0.152
□□□□■■	0.634	0.632	0.002
■■■□□□	0.471	0.291	0.180
■■□■□□	0.498	0.293	0.205
■■□□■□	0.607	0.632	-0.025
■■□□□■	0.451	0.291	0.160
■□■■□□	0.477	0.293	0.184
■□■□■□	0.649	0.632	0.017
■□■□□■	0.418	0.254	0.164
■□□■■□	0.625	0.632	-0.007
■□□■□■	0.452	0.293	0.159
■□□□■■	0.640	0.632	0.008
□■■■□□	0.522	0.293	0.229
□■■□■□	0.625	0.632	-0.007
□■■□□■	0.494	0.291	0.203
□■□■■□	0.637	0.632	0.005
□■□■□■	0.560	0.293	0.267
□■□□■■	0.641	0.632	0.009

Results of all combinations that can be obtained from six systems. The filled and open squares indicate which systems have and have not been included in the combination, so for example □■□□□■ is the combination of systems B, C, and F. The score is the average sensitivity at the seven false positive levels  $2^{-3}, \dots, 2^3$ . The best score of any single system included in the combination is also given, and the difference between the combination score and the best score of a single system in the combination is listed under  $\Delta$ .


□□■■□□	0.668	0.632	0.036
□□■□□■	0.526	0.293	0.233
□□■□□■	0.678	0.632	0.046
□□□■■□	0.668	0.632	0.036
■■□□□□	0.546	0.293	0.253
■■□□□□	0.640	0.632	0.008
■■□□□■	0.518	0.291	0.227
■■□■□□	0.636	0.632	0.004
■■□□□■	0.568	0.293	0.275
■■□□□■	0.651	0.632	0.019
■□■■□□	0.664	0.632	0.032
■□■□□■	0.528	0.293	0.235
■□■□□■	0.687	0.632	0.055
■□□■□■	0.663	0.632	0.031
□■■□□□	0.659	0.632	0.027
□■■□□■	0.585	0.293	0.292
□■■□□■	0.664	0.632	0.032
□■□■□■	0.666	0.632	0.034
□□■□□■	0.689	0.632	0.057
■■□□□□	0.668	0.632	0.036
■■□□□■	0.592	0.293	0.299
■■□□□■	0.672	0.632	0.040
■■□■□■	0.677	0.632	0.045
■□■□□■	0.702	0.632	0.070
□■□□□■	0.690	0.632	0.058
■■□□□■	0.685	0.632	0.053



Wyniki – dla  
różnych guzów




# Najlepsza metoda



ISI – CAD, 2009  
University Medical Center  
Utrecht, the Netherlands

FPs/scan	1/8	1/4	1/2	1	2	4	8	average
small nodules	0.470	0.491	0.573	0.658	0.711	0.761	0.778	0.634
large nodules	0.423	0.483	0.567	0.611	0.714	0.778	0.822	0.628
isolated nodules	0.548	0.595	0.595	0.619	0.619	0.643	0.643	0.609
vascular nodules	0.570	0.573	0.616	0.686	0.757	0.802	0.849	0.693
pleural nodules	0.052	0.140	0.322	0.475	0.630	0.695	0.729	0.435
peri-fissural nodules	0.629	0.643	0.743	0.771	0.804	0.886	0.886	0.766
all nodules	0.450	0.488	0.570	0.638	0.712	0.768	0.797	0.632

# ISI-CAD







- Podpróbkiowanie do 256x256 pikseli, by uzyskać izotropowy wolumen danych, zredukować złożoność obliczeniową, zastosować interpolację do uzupełnienia przestrzeni
- Segmentacja obszaru płuc – dopasowanie, atlasy probabilistyczne, interaktywny rozrost regionu
- Początkowa detekcja kandydatów – progowanie cech kształtu i krzywizny w 3D

$$SI = \frac{2}{\pi} \arctan \left( \frac{k_1 + k_2}{k_1 - k_2} \right)$$

$$CV = \sqrt{k_1^2 + k_2^2}$$


$k_1, k_2$  – parametry krzywizny (pierwsza i druga pochodna liczona dla każdego woksela w obszarze płuc z wolumenu wygładzonego filtrem Gaussa z jednostkowym od. std.) oraz dołączanie sąsiednich obszarów o określonych cechach spójności

# ISI – początkowa detekcja kandydatów



Łączone obszary - po lewej wskazanie prawdziwe, po prawej - fałszywe


# Początkowy zbiór cech



- Pierwsza klasyfikacja kNN 18 cech geometrycznych kandydatów oraz opisujących funkcję jasności w ich sąsiedztwie – redukcja nadmiaru wskazań fałszywych

ID	Description	Notes
<i>Features of the voxel cluster</i>		
a1	Cluster size (number of voxels)	
a2	Compactness1, $\frac{ClusterSize}{(dim_x)(dim_y)(dim_z)}$	$dim_i = \text{width in dim. } i$
a3	Compactness2, $\frac{ClusterSize}{max\_dim^3}$	$max\_dim = \max(dim_i)$
a4	Ratio $max\_dim:min\_dim$	$min\_dim = \min_i(dim_i)$
a5	Ratio $max\_dim:med\_dim$	$med\_dim = \text{median}_i(dim_i)$
a6	Ratio $A_{med}:A_{max}$ where $A_{max}$ , $A_{med}$ and $A_{min}$ are the eigenvalues for the eigenvectors of the cluster data by principal component analysis	
a7	Ratio $A_{min}:A_{max}$	as for a6 above
a8	Sphericity, $\frac{num\_cluster\_voxels\_in\_sphere\_S}{vol\_sphere\_S}$ where $sphere\_S$ is a sphere at the candidate location with radius $r$	
a9	Ratio Sphericity: $r$	
<i>Features of voxels in spherical kernels at the candidate location</i>		
a10-a18	On grey-values over spherical kernels $K$ : Average, Median, Standard-Deviation	Halfsizes of $K$ : 1 (a10-a12), 3 (a13-a15), $r$ (a16-a18)

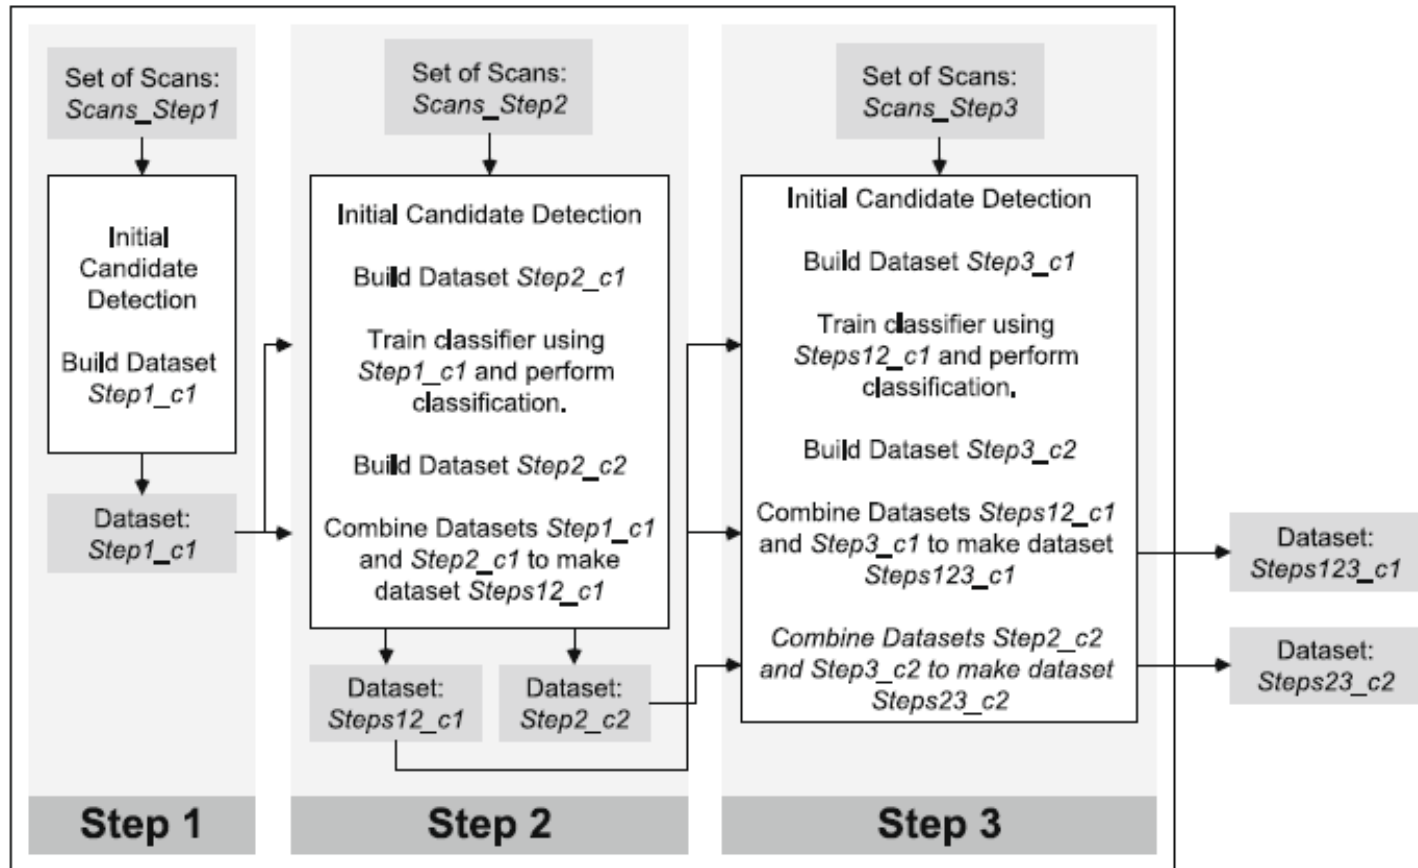
# ISI-cd



## Finalna klasifikacia kNN dla 135 cech:

ID	Description	Notes
<i>Features of the voxel cluster</i>		
b1-b9	Features a1-a9 as described in Table 4	
b19	$min\_dim = \min_i(dim_i)$	$dim_i = \text{width in dim. } i$
b20	$max\_dim = \max_i(dim_i)$	$dim_i = \text{width in dim. } i$
<i>Features of voxels in spherical kernels at the candidate location</i>		
b10-b18	Features a10-a18 as described in Table 4	
b21-b26	On grey-values over spherical kernels $K$ : Min, Max	Halfsizes of $K$ : 1 (b21-b22), 3 (b23-b24), $r$ (b25-b26)
b27-b36	On SI over spherical kernels $K$ : Average, Median, Std-Dev, Min, Max	Halfsizes of $K$ : 3 (b27-b31), $r$ (b32-b36)
b37-b46	On CV over spherical kernels $K$ : Average, Median, Std-Dev, Min, Max	Halfsizes of $K$ : 3 (b37-b41), $r$ (b42-b46)
<i>Features calculated on randomly chosen points on a spherical surface around the candidate location.</i>		
b47-b76	Features of Gradient orientation values: Average(Avg), Median, Max, Min, Std-Dev, Coefficient of Variation, Ratio Max:Min, Ratio Std-Dev:Median, Ratio Median:Avg, Ratio Median:Max	30 points on sphere rad = 3 (b47-b56), 50 points on sphere rad = $r$ (b57-b66), 50 points on sphere rad = $r_{seg}$ (b67-b76)
b77-b106	Features of Gradient magnitude values: Average(Avg), Median, Max, Min, Std-Dev, Coefficient of Variation, Ratio Max:Min, Ratio Std-Dev:Median, Ratio Median:Avg, Ratio Median:Max	30 points on sphere rad = 3 (b77-b86), 50 points on sphere rad= $r$ (b87-b96), 50 points on sphere rad = $r_{seg}$ (b97-b106)
<i>Features of voxels in the candidate segmentation</i>		
b107-b115	Features a1-a9 as described in Table 4 but calculated this time over the segmented voxels NOT the cluster voxels	
b116	$min\_dim = \min_i(dim_i)$	
b117	$max\_dim = \max_i(dim_i)$	
b118-b122	On grey-values over segmented voxels: Average, Median, Std-Dev, Min, Max	
b123-b127	On SI of segmented voxels: Average, Median, Std-Dev, Min, Max	
b128-b132	On CV of segmented voxels: Average, Median, Std-Dev, Min, Max	
b133	Ratio Num segmented voxels: Num ROI voxels	
b134	Ratio {Distance from candidate location to the farthest point in the segmentation}; {Number of voxels in the segmentation}	
<i>Other features</i>		
b135	Posterior probability of being a true nodule from the first classification step	


# Generacja zbiorów uczących





# ISI - wyniki

## Przypadki trudne



odrzucone na etapie segmentacji płuc



Niewykryte przez klasyfikatory przy 4FP







Number of Scans	813		
Number of annotations	1525		
	Sensitivity		FP per scan
After initial candidate detection	97.2%		649.0
After first classification	92.3%		77.3
After final classification			
– At around 4 FP per scan	80.0%		4.2

541			
1688			
	Sensitivity		FP per scan
	97.7%		750.5
	91.9%		69.0
	72.4%		4.0

wyniki dla trzech różnych baz

541			
768			
	Sensitivity		FP per scan
	98.2%		752.1
	92.2%		51.2
	77.7%		4.2

# Inne przykłady wyników



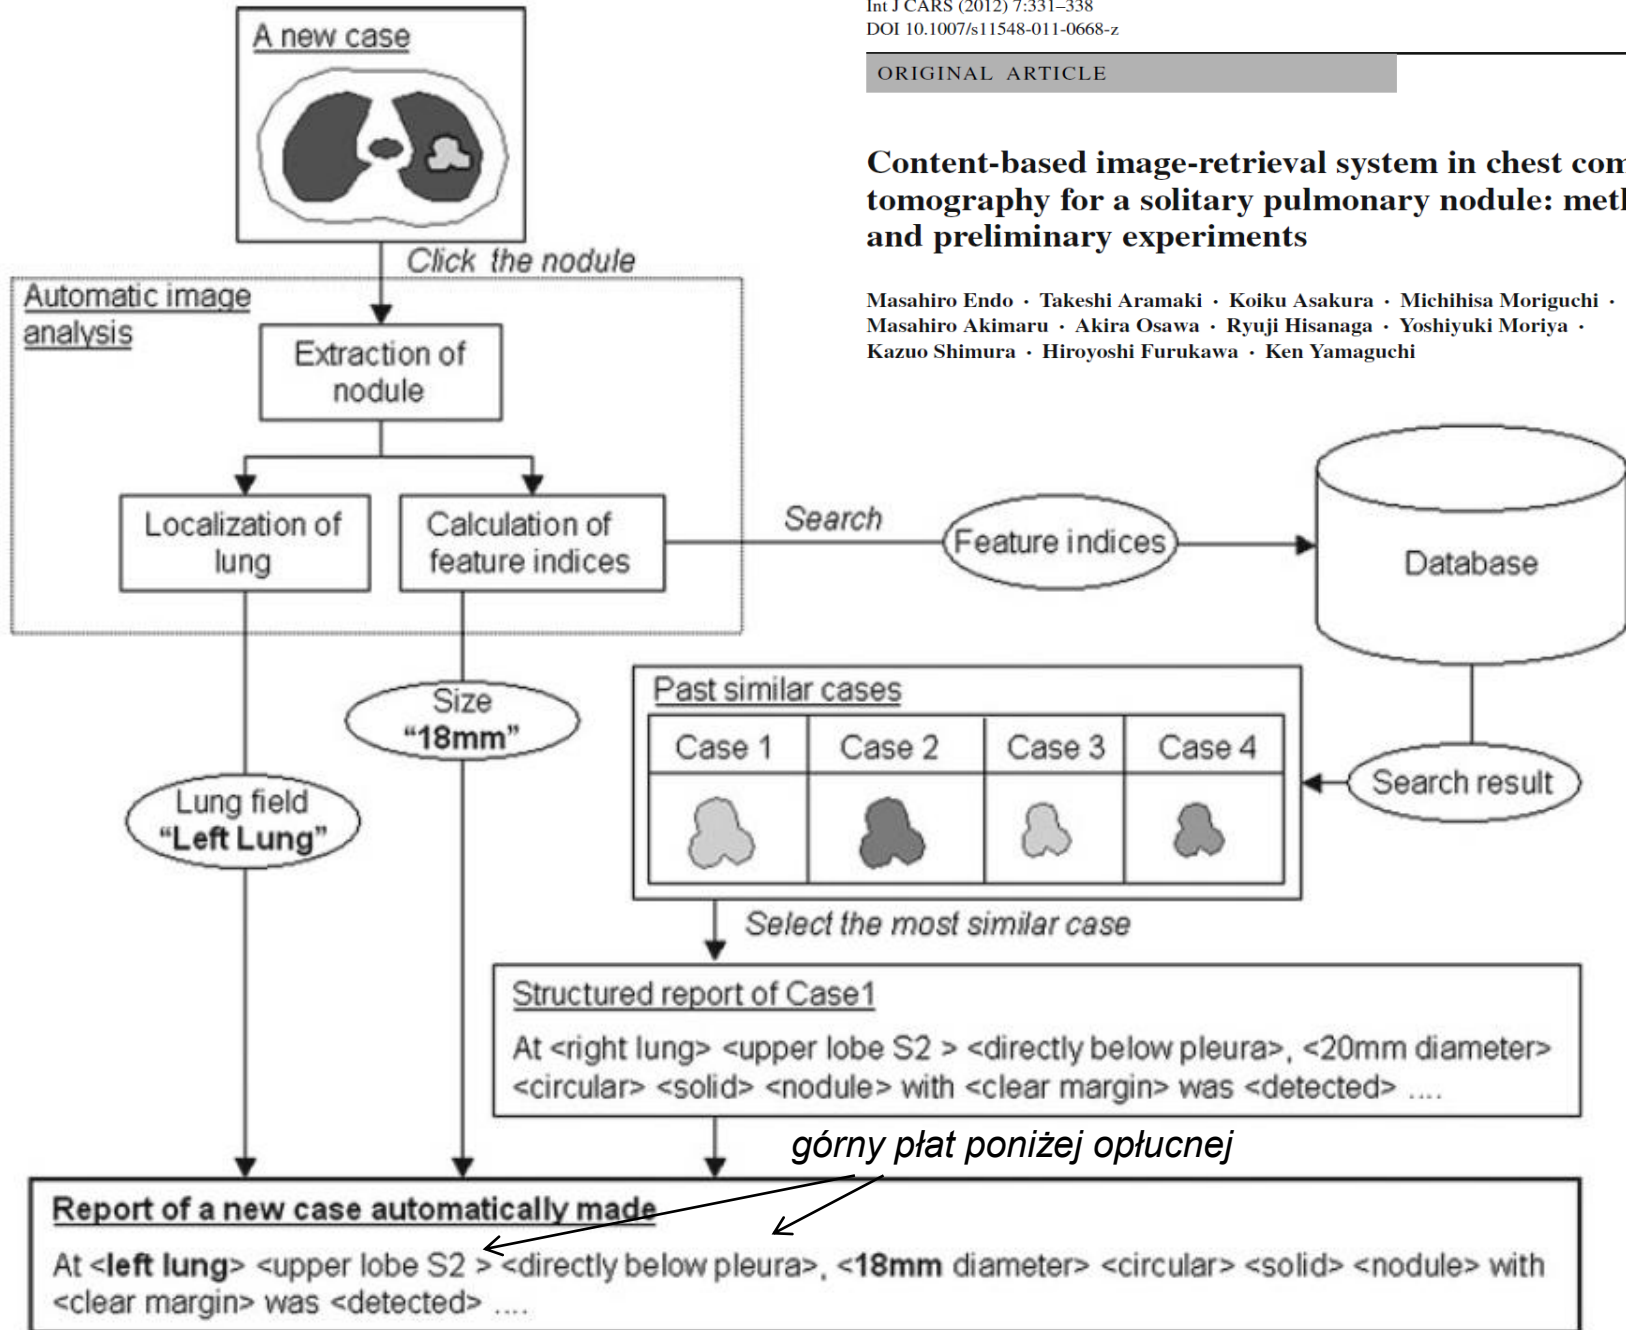
# CAD-CBIR: wyszukiwanie pojedynczych guzków płuc w CT


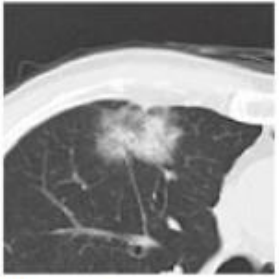
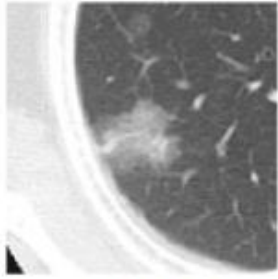
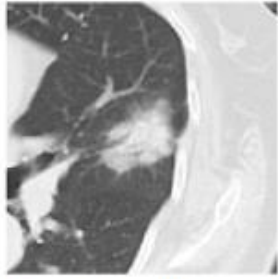
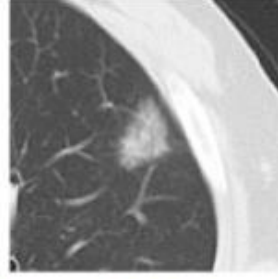

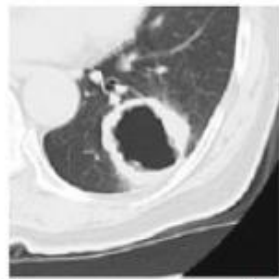
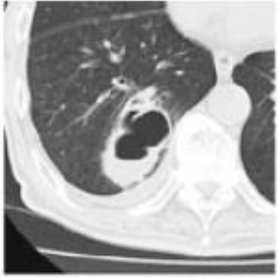
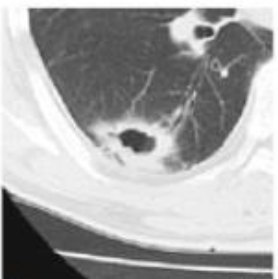
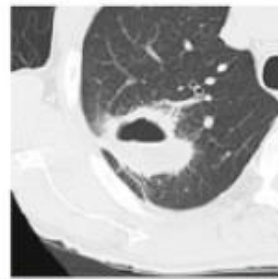
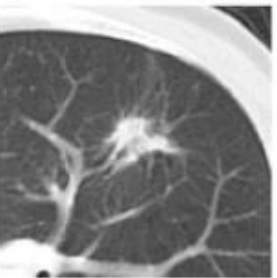
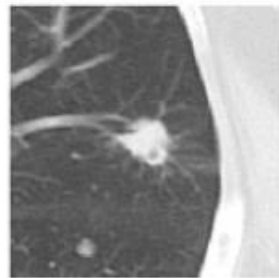
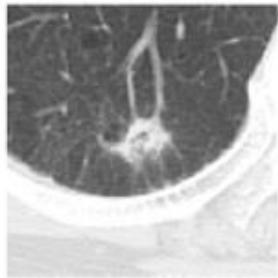
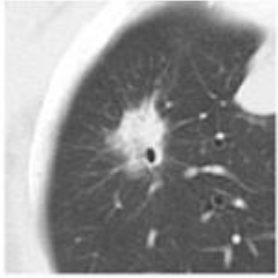
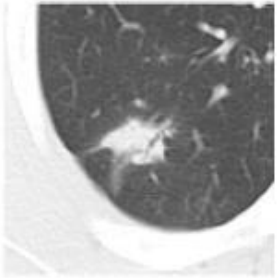
Int J CARS (2012) 7:331–338  
DOI 10.1007/s11548-011-0668-z

ORIGINAL ARTICLE

## Content-based image-retrieval system in chest computed tomography for a solitary pulmonary nodule: method and preliminary experiments

Masahiro Endo · Takeshi Aramaki · Koiku Asakura · Michihisa Moriguchi · Masahiro Akimaru · Akira Osawa · Ryuji Hisanaga · Yoshiyuki Moriya · Kazuo Shimura · Hiroyoshi Furukawa · Ken Yamaguchi



Query	Similar cases			
	No.1	No.2	No.3	No.4
<p><i>gruczolakorak</i></p>  <p><b>(a)</b> Adenocarcinoma</p>	 <p>Adenocarcinoma</p>	 <p>Adenocarcinoma</p>	 <p>Adenocarcinoma</p>	 <p>Adenocarcinoma</p>
<p><i>rak płaskonabłonkowy</i></p>  <p><b>(b)</b> Squamous cell carcinoma</p>	 <p>Squamous cell carcinoma</p>	 <p>Squamous cell carcinoma</p>	 <p>Squamous cell carcinoma</p>	 <p>Squamous cell carcinoma</p>
 <p><b>(c)</b> Adenocarcinoma</p>	 <p>Adenocarcinoma</p>	 <p>Inflammation <i>zapalenie</i></p>	 <p>Adenocarcinoma</p>	 <p>Adenocarcinoma</p>

---

# **CAD-MAMMOGRAFIA**

---


# Wspomaganie mammografii

- Badania
- Charakterystyka zmian
- Komercyjne CAD




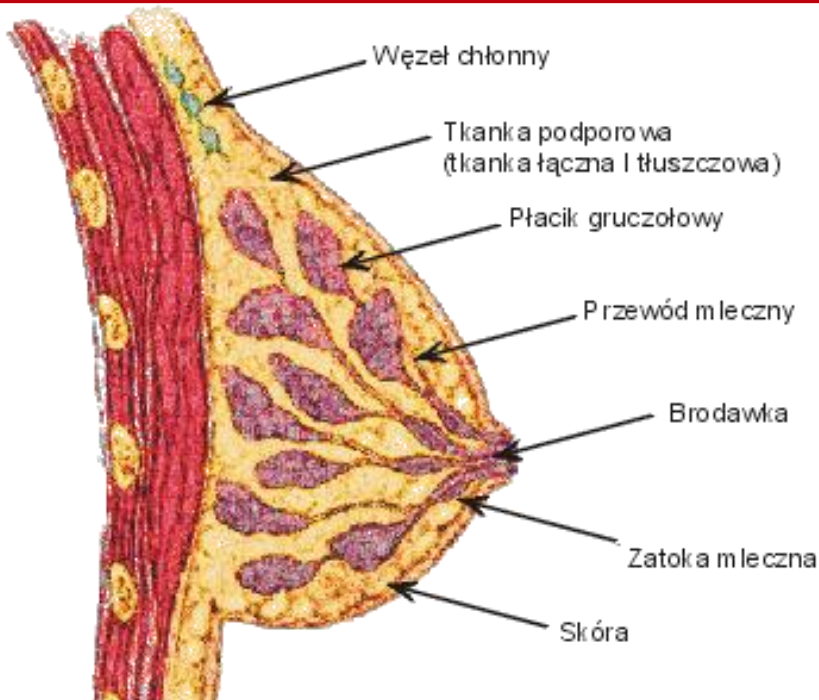
wśród mężczyzn rak sutka stanowi ok. 1% wszystkich zachorowań na nowotwory złośliwe

W. Zatoński, J. Didkowska, U. Wojciechowska,  
„Nowotwory złośliwe w Polsce w 2006 roku”  
Centrum Onkologii, Warszawa 2008


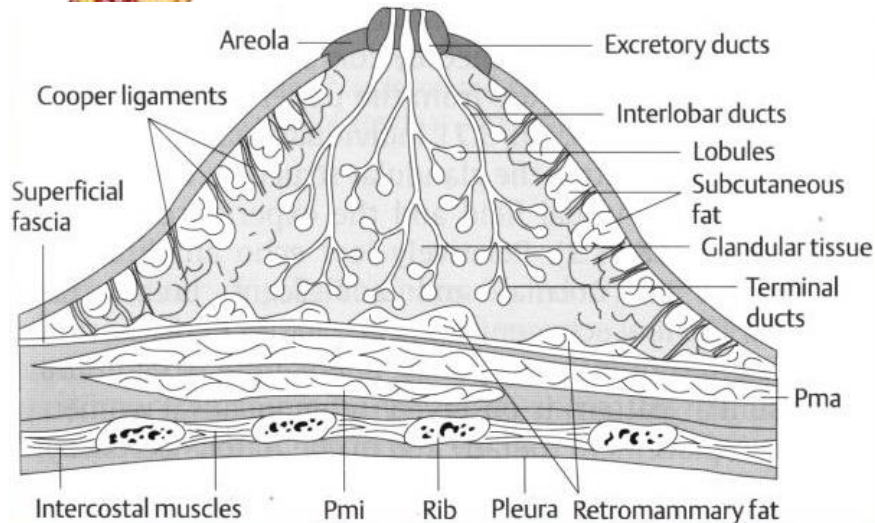


Struktura zarejestrowanych zachorowań na nowotwory złośliwe u kobiet w Polsce w 2006 roku

# Opis sutka




KGP: kwadrant górny- przyśrodkowy  
 KGB: kwadrant górny-boczny  
 KDP: kwadrant dolny-przyśrodkowy  
 KDB: kwadrant dolny-boczny  
 OZ: okolica zabrodawkowa



# Mammografia

- Prześwietlenie sutka miękkim promieniowaniem rentgenowskim (ok. 20 keV)
- Obecnie najbardziej czuła metoda (we wczesnej detekcji raka u kobiet starszych)
- Możliwość wykrycia zmian bezobjawowych – mammografia skriningowa
- Dokładniejsza ocena charakteru zmian

*typowe badanie w dwóch projekcjach*





# Badanie mammograficzne












podstawowa projekcja MLO: skośna  
(kąąt lampy 40-60%)




uzupełniająca projekcja CC:  
kranio-kaudalna

# Rodzaje patologii: guzki


Kształt		Brzegi (kontury)	
okrągły		dobrze odgraniczony	
owalny		mikropłatkowe	
płatka		częściowo zatarty	
nieregularny		źle określony	
		spikularny	

według leksykonu BI-RADS (Breast Imaging Reporting and Data System)

# Guzki




*nieregularny kształt ze źle określonym konturem*



*zmiana łagodna (fibroadenomas )*



*łagodna cysta*



*nieregularny kształt ze spikulami*


# Mikrozwapnienia (złogi wapnia o rozmiarach poniżej 1 mm)

## Zwykle łagodne

obrączkowe



naczyniowe



zgrubne



duże,  
wydłużone



okrągłe  
(punkcikowate)



skorupa  
jajka



mleczko  
wapnia



## Interpretacja pośrednia


bezpостaciowy,  
niewyraźny

## Bardziej prawdopodobna złośliwość zmiany

nieregularne






cienkie, linearne,  
rozgałęziające się  
(robaczkowate)



według leksykonu BI-RADS

# Detekcja mikrozwapnień



Klastry mikrozwapnień  
(ponad 5 w  $P < 2\text{cm}^2$ )

# ZABURZENIA ARCHITEKTURY

---

## **DEFINICJA „MEDYCZNA”:**

- według BI-RADS (*Breast Imaging Reporting and Data System*):

„zaburzenie architektury to architektura gruczołu sutkowego zniekształcona przez nieokreśloną (niedostrzegalną) masę, która obejmuje spikularne promieniowanie z jednego punktu i ogniskowe zniekształcenie na brzegach gruczołu”

- według J. Dziukowej i innych:




- zaburzenia architektury pod postacią struktury promienistej
- zaburzenia architektury pod postacią wciągania stożka gruczołowego

## **DEFINICJA „TECHNICZNA”:**

- skupisko struktur quasi-liniowych ułożonych w różnych kierunkach, potencjalnie zogniskowanych w jednym środku

---

# ZABURZENIA ARCHITEKTURY



# Ocena w skali BI-RADS

The American College of Radiology (ACR) Breast Imaging Reporting and Data System

---


## ACR-BIRADS

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

---



# CAD do mammografii



Mammogram cyfrowy

Segmentacja granicy sutka

Przetwarzanie wstępne

Detekcja zmian podejrzanych  
(anormalności)

Ekstrakcja cech

Klasyfikacja

Wynik wspomagania

Poprawa percepcji

- Usunięcie informacji diagnostycznie nieistotnej
- Uwypuklenie cech istotnych dla diagnozy
- Wzmocnienie lokalnego kontrastu
- Selekcja ROI
- Usunięcie lub redukcja szumu i artefaktów

- Filtracja plus progowanie, 'Region growing'
- Segmentacja zmian podejrzanych

- Guzy: kształt, spikularność, asymetria, gęstość
- Zwapnienia: rozmiar, kontrast, cechy klastrów


- Analiza dyskryminacyjna
- Wektory nośne, sieci neuronowe
- Klasyfikatory hybrydowe

- Lokalizacja zmiany
- Prawdopodobieństwo złośliwości


Deskryptory  
matematyczne

# Poprawa percepcji


---




oryginalny mammogram



krawędzie



wyrównanie histogramu




wyrównanie histogramu w dziedzinie falkowej

*A.F. Laine, S. Schuler, J. Fan, W. Huda 'Mammographic Feature Enhancement by Multiscale Analysis' IEEE Tran Medical Imag 13(4), 1994*





---

# Prezentacja 'inaczej' w dziedzinie falkowej





---



# Poprawa percepcji (lokalna poprawa kontrastu)





klastry mikrozwapnień



zmiana spikulama

okrągłe zwapnienie




dobrze odgraniczony guzek

- Oryginalny mammogram
- - - Lokalna poprawa histogramu za pomocą analizy wielorozdzielczej

*przykładowe profile*



# Detekcja ROI z potencjalnymi zmianami



ROle według  
nierosnącego porządku  
ekstremów jasności


R.M. Rangayyan i inni, Detection of architectural distortion in prior screening mammograms using **Gabor filters, phase portraits, fractal dimension, and texture analysis**, Int J CARS (2008) 2:347–361

badanie późniejsze z  
patologią (zaburzenie  
architektury)

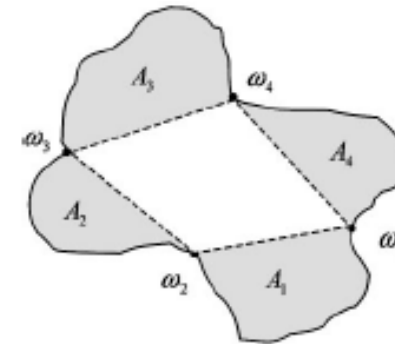


badanie  
wcześniejsze


# Budowa przestrzeni cech i klasyfikacja



opisy zmian



charakterystyka wypustek




szkieletyzacja zmiany  
złośliwej

C-M. Chen, Y-H. Chou et al. , 'Breast Lesions on Sonograms: Computer-aided Diagnosis with Nearly Setting-Independent Features and Artificial Neural Networks', Radiology, 226:504-514, 2003

# Prototyp systemu CAD, 1994, University of Chicago

---

## Detekcja guzków i klastrów mikrozwapnień




# Systemy CADD



- **ImageChecker** firmy R2 Technology (zatwierdzony przez FDA w 1998)
- **SecondLook** firmy CADx Medical Systems (FDA – 2002)
- **MammoReader** firmy iCAD (FDA – 2002)
- **KODAK Mammography Computer-Aided Detection System** proponowany przez Carestream Health do mammografii analogowej (2004)
- **B-CAD** firmy Medipattern do sonomammografii (FDA-2005)
- **Mammex MammoCAD** firmy Scanis (FDA – 2007, wcześniej akceptacja w Europie)
- Eastman Kodak, Ficher Imaging iCAD, Hologic, GE, VuCOMP, ...
- **MRI-CAD**: CADstream firmy Confirma, AuroraCAD firmy Aurora Imaging Technology, SpectraLook firmy iCAD
- .....
- Przy danej czułości różna jest liczba fałszywych wskazań
- Sposób prezentacji, integracja z systemami cyfrowej mammografii, z PACS




# Popularność systemów CAD



Według Frost & sprzedaz CAD  
osiagnie US\$600 milionow w  
2009

Miliony



# Image Checker, czyli lepsze okulary!

---

- Pierwotna wersja ImageCheckerM1000 – *premarket application*
  - Wnioski z dyskusji wokół procesu akceptacji
    - CAD nie zwiększa skuteczności /wydajności diagnostycznej
    - CAD poprawnie zaznacza wysoki procent mikrozwapnień oraz guzów minimalizując liczbę wskazań fałszywie negatywnych (poprawia czułość)
    - narzędzie daje powtarzalne wyniki w zakresie wysokiej czułości identyfikacji mikrozwapnień i mas towarzyszących nowotworom
  - Warunek: po akceptacji i dopuszczeniu na rynek ma być wykonane studium w zakresie bardziej wiarygodnej oceny wpływu narzędzia na liczbę decyzji prawdziwie dodatnich oraz fałszywie ujemnych
  - Bardzo ciekawy zapis w raporcie przy okazji tej decyzji
    - czy proces zatwierdzania powinien koncentrować się w takich przypadkach (urządzenie i człowiek *work in concert*) jedynie na fizycznych aspektach narzędzia/urządzenia czy też dodatkowo powinien dotyczyć interpretacji oraz potencjalnych konsekwencji interpretacji?
-

# Image Checker, SecondLook

---


- Image Checker - zastosowania
    - początkowo w skryningu
    - od 2001 roku także w diagnostyce
  - Image Checker - ponawiane testy efektywności
    - na każde 100 000 przypadków raka wcześniej wykrytych w badaniach skryningowych ImageChecker pozwala średnio wykryć 30 500 dodatkowych przypadków raka sutka
    - 23,4% przypadków wcześniejszej (w stosunku do procedur klasycznych) detekcji raka w badaniach przesiewowych
  - SecondLook – akceptacja
    - **zaznaczanie regionów zainteresowania wymagających szczególnej uwagi radiologa** po zakończeniu wstępnej oceny mammogramu
    - prowadzi do redukcji czasu analizy wtórnej
  - Algorytmy, implementacje oprogramowanie – FDA opracowało specjalne GUI (przeglądarka, sterowanie CAD) do podpinania i testowania poszczególnych rozwiązań CAD
-

# R2 ImageChecker




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

Zwiększa czułość  
radiologa o **23.4%**



(Burhenne LJ, et al. Radiology 2000; 215: 554-562;  
Castellino, et al. Radiology 2000; 217: 400)


# Przykłady (ImageChecker)




**R2**

A "▲" marks calcifications

A "\*" marks masses or distortions.




Can be stored in DICOM fields or printed for patient folder



Less Important



bardziej wyraziste cechy




**PeerView Software**

Standard R2 CAD Marks →


Optional R2 PeerView →

Calc	Mass	Malc
▲	*	+
⬢	◻	⬢




# iCAD SecondLook

- Czulość całkowita = 92% - 96%
- FP/normalny przypadek = 1.6 – 2.8  
(Dane z października 2003)



- Zwiększa czulość radiologa o 21.2%

(Brem RF, et al. Improvement in sensitivity of screening mammography with computer-aided detection: A multiinstitutional trial. *AJR Am J Roentgenol*, 181, 687-693, Sept. 2003)



# Przykładowe działanie SecondLook

ID #: **SL000418047**

Saturday, December 14, 2002 17:06:59

Location:

CADx Systems  
2689 Commons Blvd. Suite 100  
Beavercreek, OH 45431  
www.cadxsystems.com

Film size : 24 cm x 30 cm

CalcMark : 0

MassMark : 1

Film size : 24 cm x 30 cm

CalcMark : 0

MassMark : 1


Film size : 24 cm x 30 cm

CalcMark : 0

MassMark : 1

Film size : 24 cm x 30 cm

No detections found



**SECOND**<sup>TM</sup>  
**LOOK**  
Ver. 5.01

□ : CalcMark<sup>TM</sup>

○ : MassMark<sup>TM</sup>


Page 1 of 2

Mammagraph<sup>TM</sup>

# Mała efektywność CADD ...

Czułość komercyjnych systemów w detekcji  
złośliwych zaburzeń architektury

CZUŁOŚĆ	R2 ImageChecker	iCAD SecondLook
Przypadek (n=27)	48 %	19 %
Obraz (n=51)	31 %	10 %
FP / obraz	0.7	1.27



(Baker et al., AJR 2003; 181, 1083-1088)



# DECYZYJNOŚĆ

## RADIOLOG ↔ RADIOLOG + CAD

Poprawa czułości radiologa wspomaganego się wskazaniami CAD:

**guzki i mikrozwapnienia** – średnio o ok. **20%**

Image Checker firmy R2 Technology - zwiększa czułość radiologa o 23.4%

Second Look firmy CADx - zwiększa czułość radiologa o 21.2%

**zaburzenia architektury** - tylko o ok. **6%**.

	Liczba wykrytych zmian patologicznych			
	Radiolog	CAD	Radiolog + CAD	
Guzki	274	36	273	583
Mikrozwapnienia	72	29	244	345
Zaburzenia	11	8	13	32
	357	73	530	960

# Przykładowe metody detekcji ZA

## □ Z WYKORZYST. CECH OBRAZOWYCH, OPERATORÓW MORFOLOG. (T. Ichikawa i inni)

Miara średniej krzywizny → współczynnik koncentracji → eliminacja przypadków FP

Czułość detekcji – **56% przy FPI = 0.96**

Ograniczenia: podobieństwo przypadków FP do PP, niska czułość detekcji

## □ Z WYKORZYST. FRAKTALI , WEKTORÓW NOŚNYCH I SIECI RADIALNYCH (Q. Guo i inni)

Wymiar fraktalny → klasyfikacja za pomocą wektorów nośnych lub sieci radialnych

Dla SVM – **72%** prawidłowych odpowiedzi, dla RBF (funkcje radialne) – **65%**

Ograniczenia: wyniki zależne od doboru parametrów klasyfikatorów

## □ Z WYKORZYSTANIEM TRANSFORMACJI RADONA (M.P. Sampat i inni)

Zmiana reprezentacji mammogramu → filtracja → odwrotna transformata Radona

Czułość detekcji – **80% przy FPI = 14**

ograniczenia: dobór parametrów filtrów w zależności od rozmiaru badanej patologii,  
duża liczba fałszywych wskazań


## □ Z WYKORZYSTANIEM FILTRACJI GABORA (R.M. Rangayyan i inni)

Filtracja zespołem filtrów Gabora → selekcja struktur krzywoliniowych  
→ filtracja → analiza mapy fazowej



Czułość detekcji – **84% przy FPI = 7.8**

Ograniczenia: duża złożoność obliczeniowa algorytmu, duża liczba fałszywych wskazań.

Zalety: **wysoki współczynnik ekstrakcji tekstury dla filtrów Gabora – ok. 74%**



# Przykładowy algorytm detekcji ZA



OBRAZ  
MAMMOGRAFICZNY

WSTĘPNE  
PRZETWARZANIE OBRAZU

FILTRACJA ZESPOŁEM  
FILTRÓW GABORA







OBRAZ MACIERZY  
MAKSYMALNYCH  
KĄTÓW

OBRAZ MACIERZY  
MAKSYMALNYCH  
AMPLITUD

ANALIZA  
HISTOGRAMOWA

TWORZENIE  
„MAPY  
PRAWDOPODOBIENSTW”

OBRAZ WYNIKOWY



# Systemy MammoCAD w praktyce klinicznej

---

- W USA działa ponad 1.200 stacji wspomaganie detekcji (liczba stale rośnie)
  - 2003 USA - ok. 8 mln mammogramów skriningowych było diagnozowanych za pomocą komputerowego systemu detekcji
  - CAD stosowano w 74% wszystkich mammografi przesiewowych w 2008 roku oraz w 92% wszystkich mammografi przesiewowych w 2016 roku w USA
  - Pierwsze systemy CAD MRI (3TP ImagingSciences, CADimas, Confirma) oraz CAD USG (Cedara B-CAD) w ostatnich latach
  - Standardowe wyposażenie mammografów cyfrowych w CAD (Senographe 2000D z R2)
  - Efektywność systemów stale rośnie ...
-

# MammoCAD – wyzwania

---


- Więcej studiów klinicznych (różne populacje pacjentek i radiologów)
  - Detekcja guzów – zwiększenie czułości z zachowaniem stosunku FP/obraz
  - Detekcja zaburzeń architektury!
  - Komputerowa detekcja klastrów mikrozwapnień jako podstawowy wskaźnik diagnostyczny
  - Komputerowa detekcja przypadków normalnych (bez potrzeby weryfikacji przez radiologa) – *'prescreener'*
  - Detekcja skojarzona z badaniami innych modalności, przede wszystkim USG i MRI (analiza łączona)
  - Klasyfikatory wykorzystujące dane z badań ogólnych i specjalistycznych, wywiadu itp..
  - Wykorzystanie modeli sieci głębokich, ogólniej – rosnącego potencjału obliczeń analitycznych ...
  - ...
-

# Jak uzyskać realizację celu





---

- Informacje z dodatkowych projekcji, tomosynteza
  - Informacje z wcześniejszych badań, wykorzystanie kompleksowych zbiorów danych (PACS-RIS-HIS)
  - Rozległe bazy wiedzy (przypadki zdiagnozowane, indeksowanie, ontologie)
  - Metody wykorzystania wskazań systemów CAD (na różnym poziomie), interakcji w ocenie (ICAD)
  - Integracja CAD z FFDM
  - Nowy sposób diagnozowania - obiektywizowane protokoły, edukacja w obszarze integracji medyczno-technicznej
  - CAD do badań obrazowych innych modalności (tomosyntezy, USG, MRI, optycznych ...)
  - Inne ...
-

# Nowe koncepcje: projekcje specjalne





*zdjęcie celowane*



*rozdzielenie zmian łagodnych i złośliwych*

Z. Huo, ML Giger, CJ Vyborny "Comparison of computer analysis special view mammography to conventional view mammography", IEEE Trans Medical Imag 20:1285-1292, 2001

# Korelacje czasowe (długaczosowa progresja zmiany)




krzywe ROC



# Otwarte wyzwania ....

- Znacząca poprawa mocy obliczeniowej i szybkie pojawienie się zaawansowanych algorytmów głębokiego uczenia



Overview of multiview deep convolutional network (DCN) [19]. DCN refers to series of convolutional and pooling layers applied separately to each mammographic view. It is described in detail in Figure 3. Arrow indicates direction of information flow. L = left, R = right, CC = craniocaudal, MLO = mediolateral oblique.

Description of subnetwork processing single view. It transforms one mammographic view into fixed size vector that can be concatenated with other vectors for remaining views. For convolutional layers, kernel size denotes size of pattern that layer is extracting. For pooling layers, it denotes size of area over which average or maximum is computed. Stride denotes what is space between applications of convolution or pooling. Number of feature maps indicates how many different patterns network is extracting within each layer. Global average pooling is also type of pooling layer but it acts on entire image. Its purpose is to reduce size of feature maps into single vector.


## New Frontiers: An Update on Computer-Aided Diagnosis for Breast Imaging in the Age of Artificial Intelligence

Yiming Gao<sup>1</sup>, Krzysztof J. Geras<sup>2</sup>, Alana A. Lewin<sup>1</sup>, Linda Moy<sup>1,3</sup>

*AJR Am J Roentgenol.* 2019 February ; 212(2): 300–307


Layer	Kernel size	Stride	No. of feature maps	Repetition
Global average pooling			256	
Convolution	3 × 3	1 × 1	256	× 3
Maximum pooling	2 × 2	2 × 2	128	
Convolution	3 × 3	1 × 1	128	× 3
Maximum pooling	2 × 2	2 × 2	128	
Convolution	3 × 3	1 × 1	128	× 3
Maximum pooling	2 × 2	2 × 2	64	
Convolution	3 × 3	1 × 1	64	× 2
Convolution	3 × 3	2 × 2	64	
Maximum pooling	3 × 3	3 × 3	32	
Convolution	3 × 3	2 × 2	32	

# Efekty ... ograniczone ...





Examples of visualization of decisions made by network. **A** and **B**, 42-year-old woman (BI-RADS category 0, **A**) and 51-year-old woman (BI-RADS category 2, **B**). Both left-hand images show breast with possible suspicious findings (*red arrows, A*; *blue arrows, B*). Both right-hand images are corresponding images of same breast with regions of images (highlighted in *red*) that influence confidence of predictions of neural network. Dashed lines in **B** denote scar markers overlying left breast.


# Inne modalności: kompleksowa analiza




*korekcja zniekształceń  
(USG)*



*charakterystyka kształtu zmian złośliwych*




*sekwencje czasowe  
i przestrzenne (MR)*




# MRI-CAD sutka

---


- Cel: realne przeglądanie olbrzymiej liczby obrazów (2000 przy jednym badaniu)
- Działanie: interakcja, segmentacja i doskonalona wizualizacja
- Zintegrowanie z mammoCAD
- W opracowaniu jest nowy MRI-CAD, uwzględniający morfologię i kinetykę



# Przykładowa koncepcja MRI-CAD



badanie kontrastowe



złośliwe




Figure 1: (a) Enhancement scatterplot with brushed points in red, (b) Two-Level volume rendering of a breast highlighting a tumor in red, (c) Importance-driven volume rendering highlighting a tumor in red, (d) 2D slice with red False Color Map.







Figure 13: Two-level volume rendering showing two brushed tumors on a patient's breast.

*E. Coto , S. Grimm , S. Bruckner et al., MammoExplorer: an advanced CAD application for breast DCE-MRI, technical report*

# Interfejs wspomagania (MRI-CAD sutka)




# B-CAD, czyli ultradźwiękowe wspomaganie badań sutka

- Pierwszy system otrzymał FDA 510(k) clearance w roku 2005
- Detekcja zmian (np. mikropłatków w obrysie zmiany): segmentacja, charakterystyka, klasyfikacja, oznaczenie, przygotowanie raportu
- Propozycja ustandaryzowania raportu badań (wykorzystuje m.in. BIRADS)
- Integracja z mammoCAD




*Cedara Software Corp.*

# Przykłady patologii w USG






łagodne



złośliwe




# USG B-CAD (*Cedara Software*)



# B-CAD



1/4 B-CAD Report 


November 11, 2005 Patient Name: -  
 Generated At: Patient ID: -  
 Study ID: -  
 Series #: 1  
 File: D:\Frederic\CAD\DATA4\LUMINARIES\BUS Medipattern\AIUM-2\Validation\case 14\_1\_anon.dcm

Application & Algorithms Settings

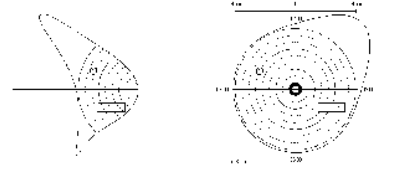
User Mode  
 Basic  Administrator

Annotations  
 ACR BI-RADS®

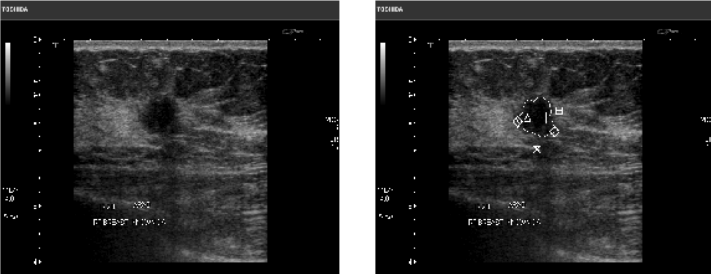
Segmentation  
 B-CAD Optima

Image Goodness of Fit  


Lesion Locator



Outcomes - Image #: 5



Sonographic Characteristics

Irregular  Angular  Abrupt Interface  Shadowing


Not Parallel  Microlobulated  Hypochoic  Duct Changes

Findings - flachmann

Findings: ULTRASOUND OF THE Left BREAST

Color Flow ultrasound was performed on the Left breast.

Powered by 

2/2 B-CAD Report 

Date Patient ID  
 Institution Name Study ID  
 Institution Address Series ID

ACR BI-RADS US Classification Form  
 from ACRN 6666, July 8, 2004 Form 4-03 Draft

Masses

Shape  
 Oval  
 Round  
 Irregular

Orientation  
 Parallel  
 Not Parallel

Posterior Acoustic Features  
 No Posterior Acoustic Features  
 Enhancement  
 Shadowing  
 Combined Pattern

Echo Pattern  
 Anechoic  
 Hyperechoic  
 Complex  
 Hypochoic  
 Isoechoic  
 Mixed Hyper/Hypoechoic

Margin  
 Circumscribed  
 Not Circumscribed  
 Indistinct  
 Angular  
 Microlobulated  
 Spiculated

Surrounding Tissue  
 Duct Changes  
 Cooper's Ligament Changes  
 Edema  
 Architectural Distortion  
 Skin Thickening  
 Skin Retraction/Irregularity

Lesion Boundary  
 Abrupt Interface  
 Echogenic Halo


Calcifications  
 Microcalcifications  
 Microcalcifications out of Mass  
 Microcalcifications in Mass

Background Echotexture  
 Homogeneous  
 Heterogeneous


Other Findings

Special Cases  
 Clustered Microcysts  
 Complicated Cysts  
 Mass in or on Skin  
 Foreign Body  
 Lymph Nodes - Intramammary  
 Lymph Nodes - Axillary  
 Post Surgical Scar

Vascularity  
 Cannot Assess Vascularity  
 None  
 Present in Lesion  
 Present Immediately Adjacent to Lesion  
 Increased in Surrounding Tissue

BIRADS Assessment  
**Category 4a - Suspicious Abnormality / Low** 

# Efektywność B-CAD



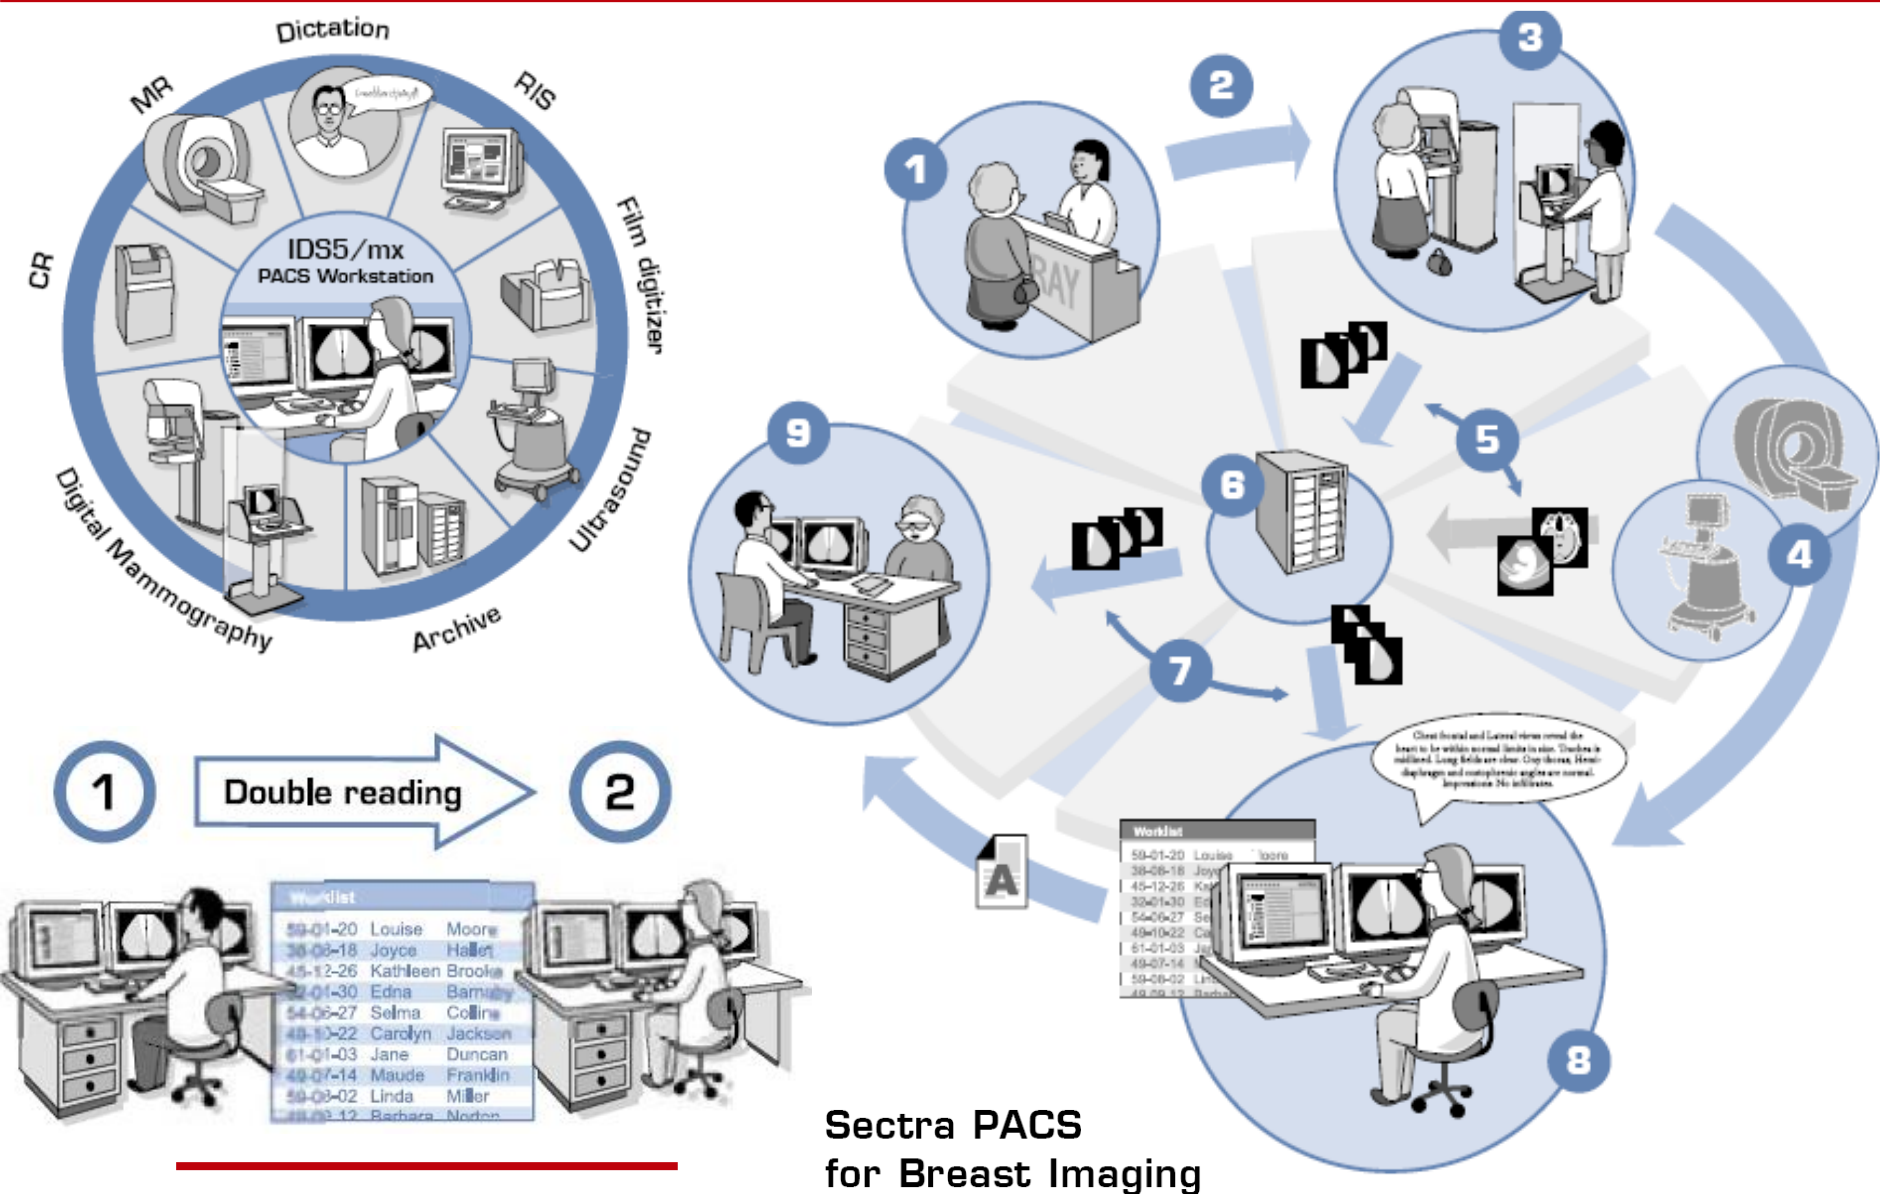
	Scored Lesion Correctly	Misclassified Lesion
Average Radiologist	20% <sup>1</sup>	7.5% <sup>1</sup>
Stavros et al.	38% <sup>2</sup>	0.5% <sup>2</sup>
B-CAD	99.51% <sup>2</sup>	1.4% <sup>2</sup>

<sup>1</sup> Based on an average of various clinical studies on reader variability in ultrasound

<sup>2</sup> Based on Validation Data Set for benchmarking by re-running Stavros 1995 pivotal paper

CAD zintegrowany z 3W skanerem USG

# Cyfrowa integracja diagnostyki raka sutka




Sectra PACS  
for Breast Imaging


# Różne formy wspomagania



## The right tools





Predefined windows for e.g. soft tissue, "normal" and dense tissue, as well as inverted images.



Magnifying glass


Q-Zoom, zoom in full resolution

## CAD





# Multimodalne obrazowanie sutka

- Rentgenowska mammografia i MRI (dyn. bad. kontrast.)
- Mammografia - 50% ucisk sutka, płaski obraz prześwietleniowy
- MRI – pełny zapis 3W
- Biomechaniczny model deformacji sutka zastosowany do badań wolumetrycznych
- Pokrycie regionu zainteresowania w dwóch modalnościach (nakładanie się płaszczyzny zobrazowań i wybranych lokalizacji)
- Obszar wysycony kontrastem zestawiany jest z zaznaczonym w mmg regionem
- Wizualizacja – problem fuzji dwóch zobrazowań




wolumen MRI




mammogram

# Schemat metody



- W obu obrazowaniach wstępnie:
    - przetwarzanie wstępne
    - referencyjny układ współrzędnych (wspólna przestrzeń obrazowań), rotacja
  - MRI
    - interpolacja - izotropowy obraz wolumenu, segmentacja sutka
  - Mammogram
    - segmentacja sutka, redukcja rozdzielczości do poziomemu MRI (interpolowana)
  - Globalne dopasowanie
    - dopasowanie ilości tkanki sutka z obu obrazowań
    - liczba wokseli pomierzonego wolumenu MRI jest porównywana z wolumenem sutka symulowanym na podstawie mammogramu (ekstrapolowany model pół-elipsoidy obrotowej)
-

# Dopasowanie obrazów





- Deformowalny model przestrzenny sutka - metoda elementów skończonych (MES, dyskretyzacja dziedziny na skończone elementy)
- Dopasowanie grubości warstwy modelowanej do grubości znanej z mammogramu






# Wizualizacja


- Krzywe kontrastu (MRI)
- Półprzezroczysta fuzja kolorowych obszarów wysycenia kontrastem oraz mammogramu
- Efekty



# Efekty




# Obrazowanie sutka – metody, efektywność i koszty



Mammografia

48% - 77% - 98%




USG

gęsty sutek=94%






Biopsja

95-98%



Sectra PACS for Breast Imaging



CAD

60% - 90% - 100%

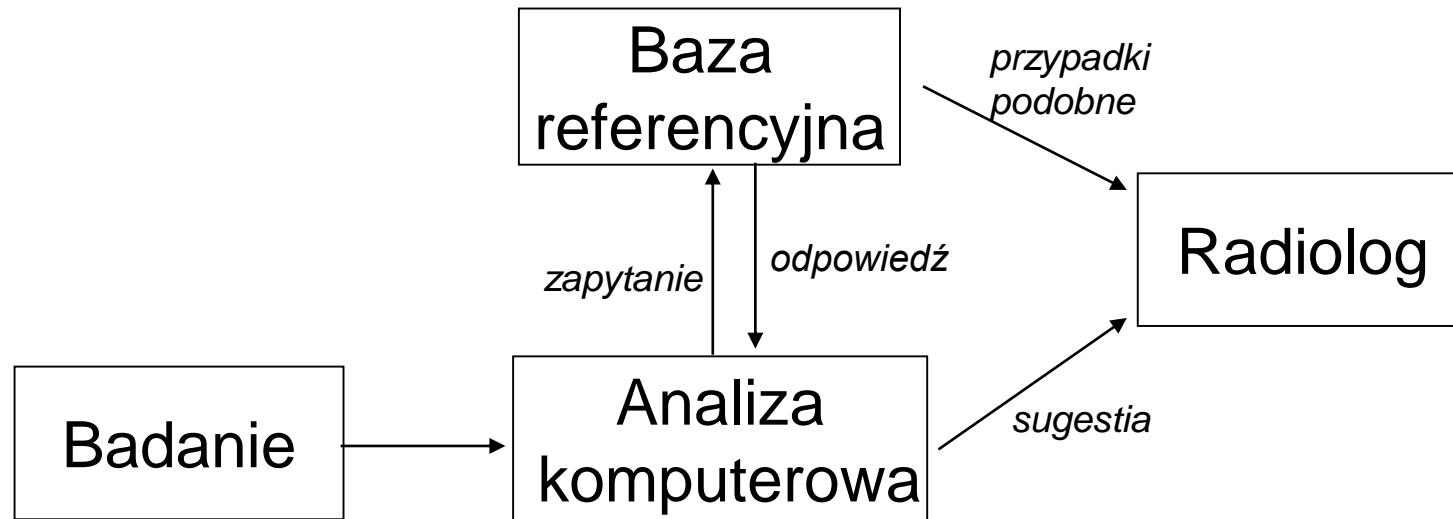
CAD

99%

Wzrost czułości,  
redukcja liczby biopsji

# Bazy referencyjne: zintegrowane środowisko wspomaganie

---





# Przykładowy interfejs

Spiculation: 8.05% (ARI by case)

Reference Library:

Case Relative to Reference Library

Occurrences

Estimated Probability of Malignancy

Legend: Cyst (green), Benign (red), Malignant (blue)

Training case: 4/11

Re-Input probability of malignancy (with AID): 0% to 100%

Re-Select Assessment Category (with AID):



- Benign Finding
- Probably Benign Finding
- Suspicious Abnormality
- Highly Suggestive of Malignancy

Re-Input patient management (with AID):

- biopsy
- follow-up
- challenge

przypadek guza  
łagodnego, zapytanie  
usg

# Przeszukiwanie bazy - podobieństwo struktur



# Złożony opis zawartości

Select parameters for retrieval process.

Classifier options:

Metric: SIMILARITY =  $(1 - \text{distance})^{1/\sqrt{g}}$  Results no.: 10


Euclidean     Linear (g=1)  
 Manhattan     Increased selectivity (g=0.5)  
 Correlation     High selectivity (g=0.1)  
 Tanimoto     Paranoid selectivity (g=0.01)

Indexing parameters:

Decomposition levels (resolution):	Wavelet bands:	Statistics:
<input checked="" type="checkbox"/> All	<input checked="" type="checkbox"/> All	<input checked="" type="checkbox"/> All
<input checked="" type="checkbox"/> 0 (low)	<input checked="" type="checkbox"/> Approximation	<input checked="" type="checkbox"/> MEAN
<input type="checkbox"/> 1 (worse)	<input type="checkbox"/> Vertical details	<input checked="" type="checkbox"/> VAR
<input type="checkbox"/> 2 (medium)	<input type="checkbox"/> Horizontal details	<input type="checkbox"/> STDDEV
<input type="checkbox"/> 3 (better)	<input type="checkbox"/> Both direction details	<input type="checkbox"/> AVGDEV
<input type="checkbox"/> 4 (high)		<input type="checkbox"/> SKEW
		<input type="checkbox"/> KURT
		<input type="checkbox"/> ENTR

Exclude current patient's images from retrieval

SEARCH



Similarity: 62.35%

PJ Patient, age:81. MMG Mammography:


Utkanie sutków: tłuszczowe  
 Inne:  
 USG  
 Echogeniczność (cień / cienie boczne): niejednorodny +/-  
 Wielkość (centrum / odczyn): 30 / 45  
 Morfologia: lity nieregularny policykliczny  
 Powięź: + +skóra  
 MMG  
 Kwadrant: KGZ (9 odległości od brodawki 9)  
 Wielkość (centrum / wypustki) [mm]: 22 / 50  
 Morfologia: spikularny  
 Mikrozwapnienia: -  
 Skóra / brodawka: +/-  
 Węzły: -  
 451 / 98 T2 N0 M0  
 BAC: cell ca  
 Histopatologia: ca ductale invasium B-II  
 Szaro-krem, nieregularny 2.5 x 1.5 x 2  
 1.5 od skóry, 1 cm od powięzi, 18 węzłów 1 do 3 cm - bz  
 Klinicznie: sr 3 słabo ograniczony, ruchomy skóra bz, w pasze węzeł śr 1

W bazie od: 04/03/2004 14:33:34, pochodzenie: rois  
[Find similar in Mammography collection...](#)

Similarity: 60.82%

PB Patient, age:71. MMG Mammography:

Utkanie sutków: tłuszczowe  
 Inne: 2 ogniska ?  
 Kwadrant: KGZ  
 Wielkość (centrum / wypustki) [mm]: 7 x 9 / 15



ZU Patient,45 MMG Mammography


LMLO\_P  
 Utkanie sutków: gruczołowo - tłuszczowe  
 Kwadrant: KGZ  
 Wielkość (centrum / wypustki): 24 x 17  
 Morfologia: zaburzenie architektury ? + gruczk ?  
 Mikrozwapnienia: -  
 Skóra / brodawka: +/-  
 Węzły: -  
 Klinicznie: T2 N1 M0  
 Histopatologia: 3 x 2 x 2,5 cm prawdopodobnie nacieka mięsień  
**Carcinoma** ductale invasium BII  
 Węzły 12/12 sr 0,3-1,0

W bazie od: 03/31/2004 02:13:13, pochodzenie: ROIS  
[Find similar in this collection...](#)

ZU Patient,45 MMG Mammography

LMLO  
 Utkanie sutków: gruczołowo - tłuszczowe  
 Kwadrant: KGZ  
 Wielkość (centrum / wypustki): 24 x 17  
 Morfologia: zaburzenie architektury ? + gruczk ?  
 Mikrozwapnienia: -  
 Skóra / brodawka: +/-  
 Węzły: -  
 Klinicznie: T2 N1 M0  
 Histopatologia: 3 x 2 x 2,5 cm prawdopodobnie nacieka mięsień  
**Carcinoma** ductale invasium BII  
 Węzły 12/12 sr 0,3-1,0

W bazie od: 03/31/2004 02:15:17, pochodzenie: ROIS  
[Find similar in this collection...](#)



ZU Patient,45 MMG Mammography

LMLO\_P  
 Utkanie sutków: gruczołowo - tłuszczowe  
 Kwadrant: KGZ  
 Wielkość (centrum / wypustki): 24 x 17  
 Morfologia: zaburzenie architektury ? + gruczk ?  
 Mikrozwapnienia: -  
 Skóra / brodawka: +/-  
 Węzły: -  
 Klinicznie: T2 N1 M0  
 Histopatologia: 3 x 2 x 2,5 cm prawdopodobnie nacieka mięsień  
**Carcinoma** ductale invasium BII  
 Węzły 12/12 sr 0,3-1,0

W bazie od: 03/31/2004 02:13:13, pochodzenie: ROIS  
[Find similar in this collection...](#)

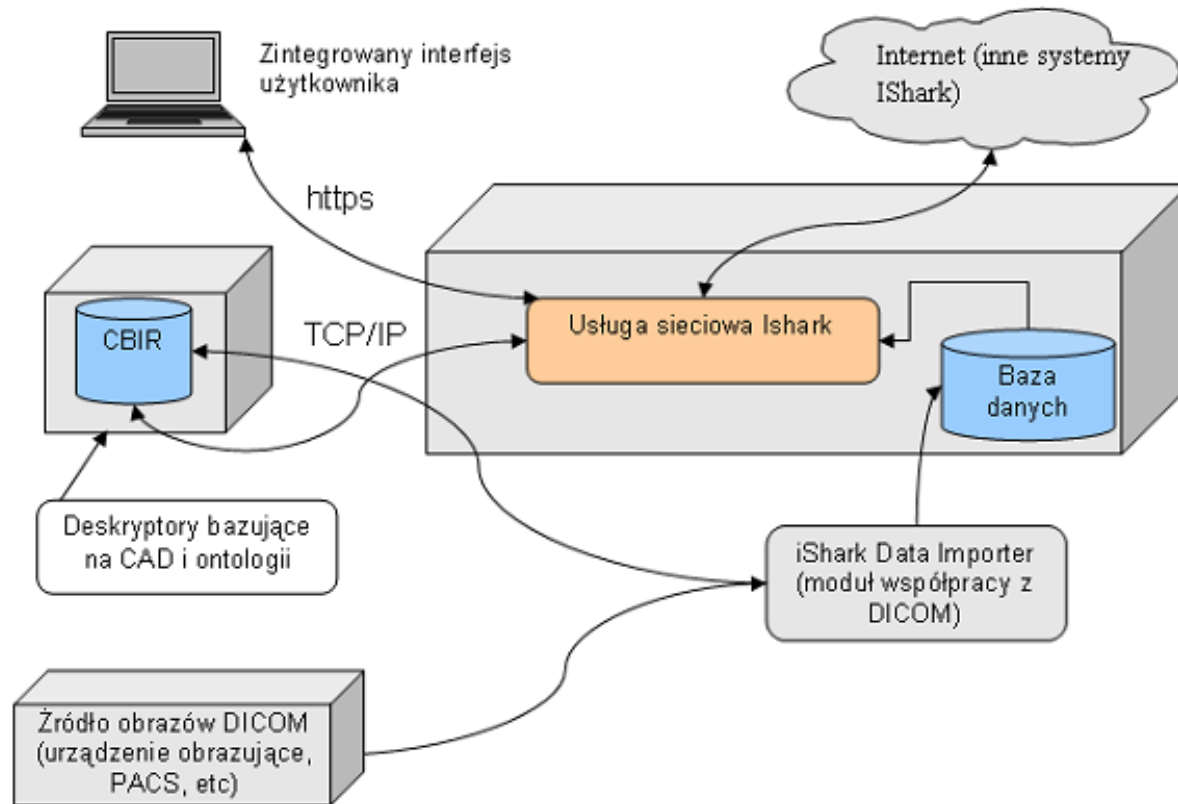
ZU Patient,45 MMG Mammography

LMLO  
 Utkanie sutków: gruczołowo - tłuszczowe  
 Kwadrant: KGZ  
 Wielkość (centrum / wypustki): 24 x 17  
 Morfologia: zaburzenie architektury ? + gruczk ?  
 Mikrozwapnienia: -  
 Skóra / brodawka: +/-  
 Węzły: -  
 Klinicznie: T2 N1 M0  
 Histopatologia: 3 x 2 x 2,5 cm prawdopodobnie nacieka mięsień  
**Carcinoma** ductale invasium BII  
 Węzły 12/12 sr 0,3-1,0

W bazie od: 03/31/2004 02:15:17, pochodzenie: ROIS  
[Find similar in this collection...](#)





# Przykład – system IShark (P. Boniński)



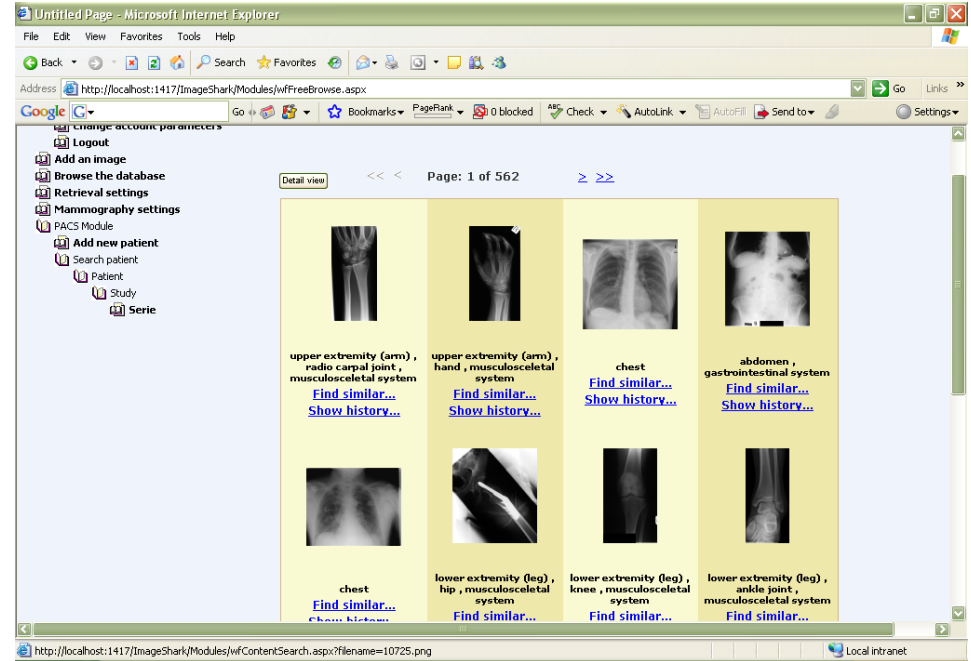

- Środowisko bazodanowe wraz z interfejsem użytkownika
- Moduł wyszukiwania obrazów po zawartości
- Interaktywny kodek standardu JPEG 2000
- Usługa sieciowa (ang. webservice) zapewniająca wyszukiwanie rozproszone

# Interfejsy




okno ustawień indeksowania obrazów różnych modalności

# Zapytania z interakcją



*relevance feedback*



# Wyszukiwanie mammogramów – interfejs użytkownika

*IShark*

Home

- Account options
  - Add a new account
  - Change account parameters
  - Logout
- Add an image
- Browse the database
- Upload and look for
- Retrieval settings
- Mammographic retrieval
- PACS Module
  - Add new patient
  - Search patient
    - Patient
      - Study
        - Serie

## Retrieval settings for mammography

Density weight

Calcifications weight

Masses weight

### Calcifications

Localization weight

Area weight

Brightness weight

Shape weight

Border irreg. weight  Clusters number

Layout uniform. weight

### Masses

Localization weight

Area weight

Brightness weight



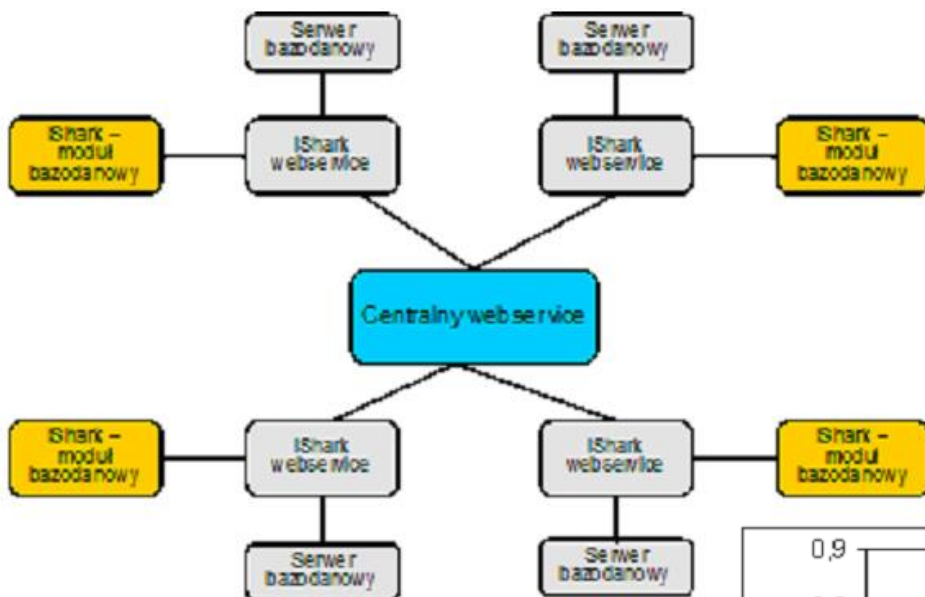
Shape weight  Objects number


Border irreg. weight

Save

Cancel

# Wyszukiwanie rozproszone





Nowa

Image processing. File: 0985.png Scale:1:1

File Edit View Image Process Analyze Help

Administacja Dokumentacja Koniec pracy



### Telemedyczny

Chat wejście

 NIPRE 9026 0.914181	 NIPRE 9063 0.898658	 NIPRE 9026 0.914181	 NIPRE 9016 0.957734
 NIPRE 8882 0.898465	 NIPRE 9138 0.890467	 NIPRE 9129 0.876805	 NIPRE 9066 0.997492
 NIPRE 9029	 NIPRE 9085	 NIPRE 9138	 NIPRE 8882

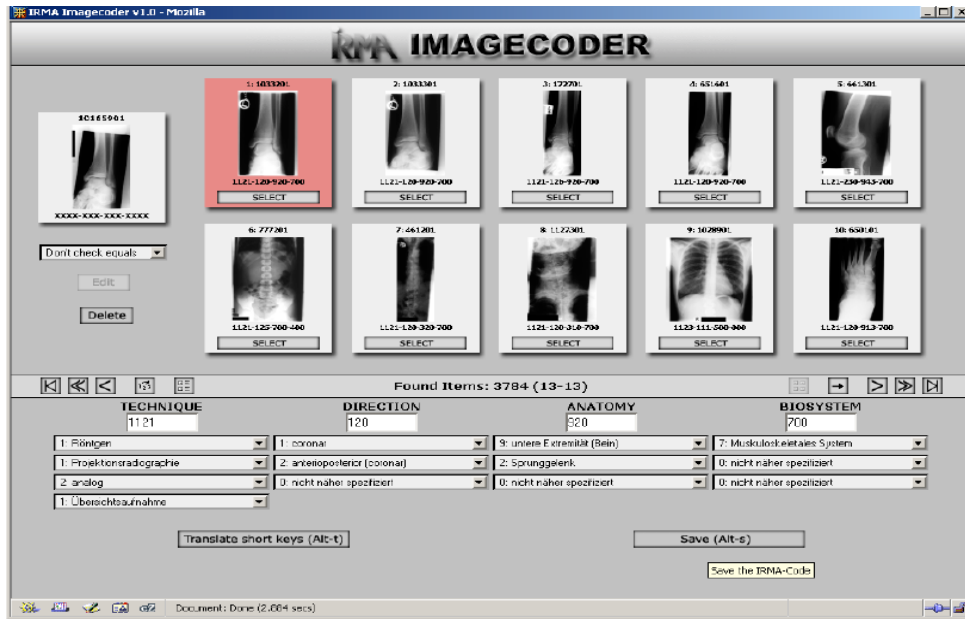
clean-caud  
audes

NIPRE 0.898  
NIPRE 1  
NIPRE 0.910  
NIPRE 0.801  
Tempo  
NIPRE 1




# Przykład - projekt IRMA

## Automatyczne oznaczanie obrazów



## Strukturalna analiza obrazu



## Referencyjna baza 10000 obrazów



## Kategoryzacja obrazów medycznych

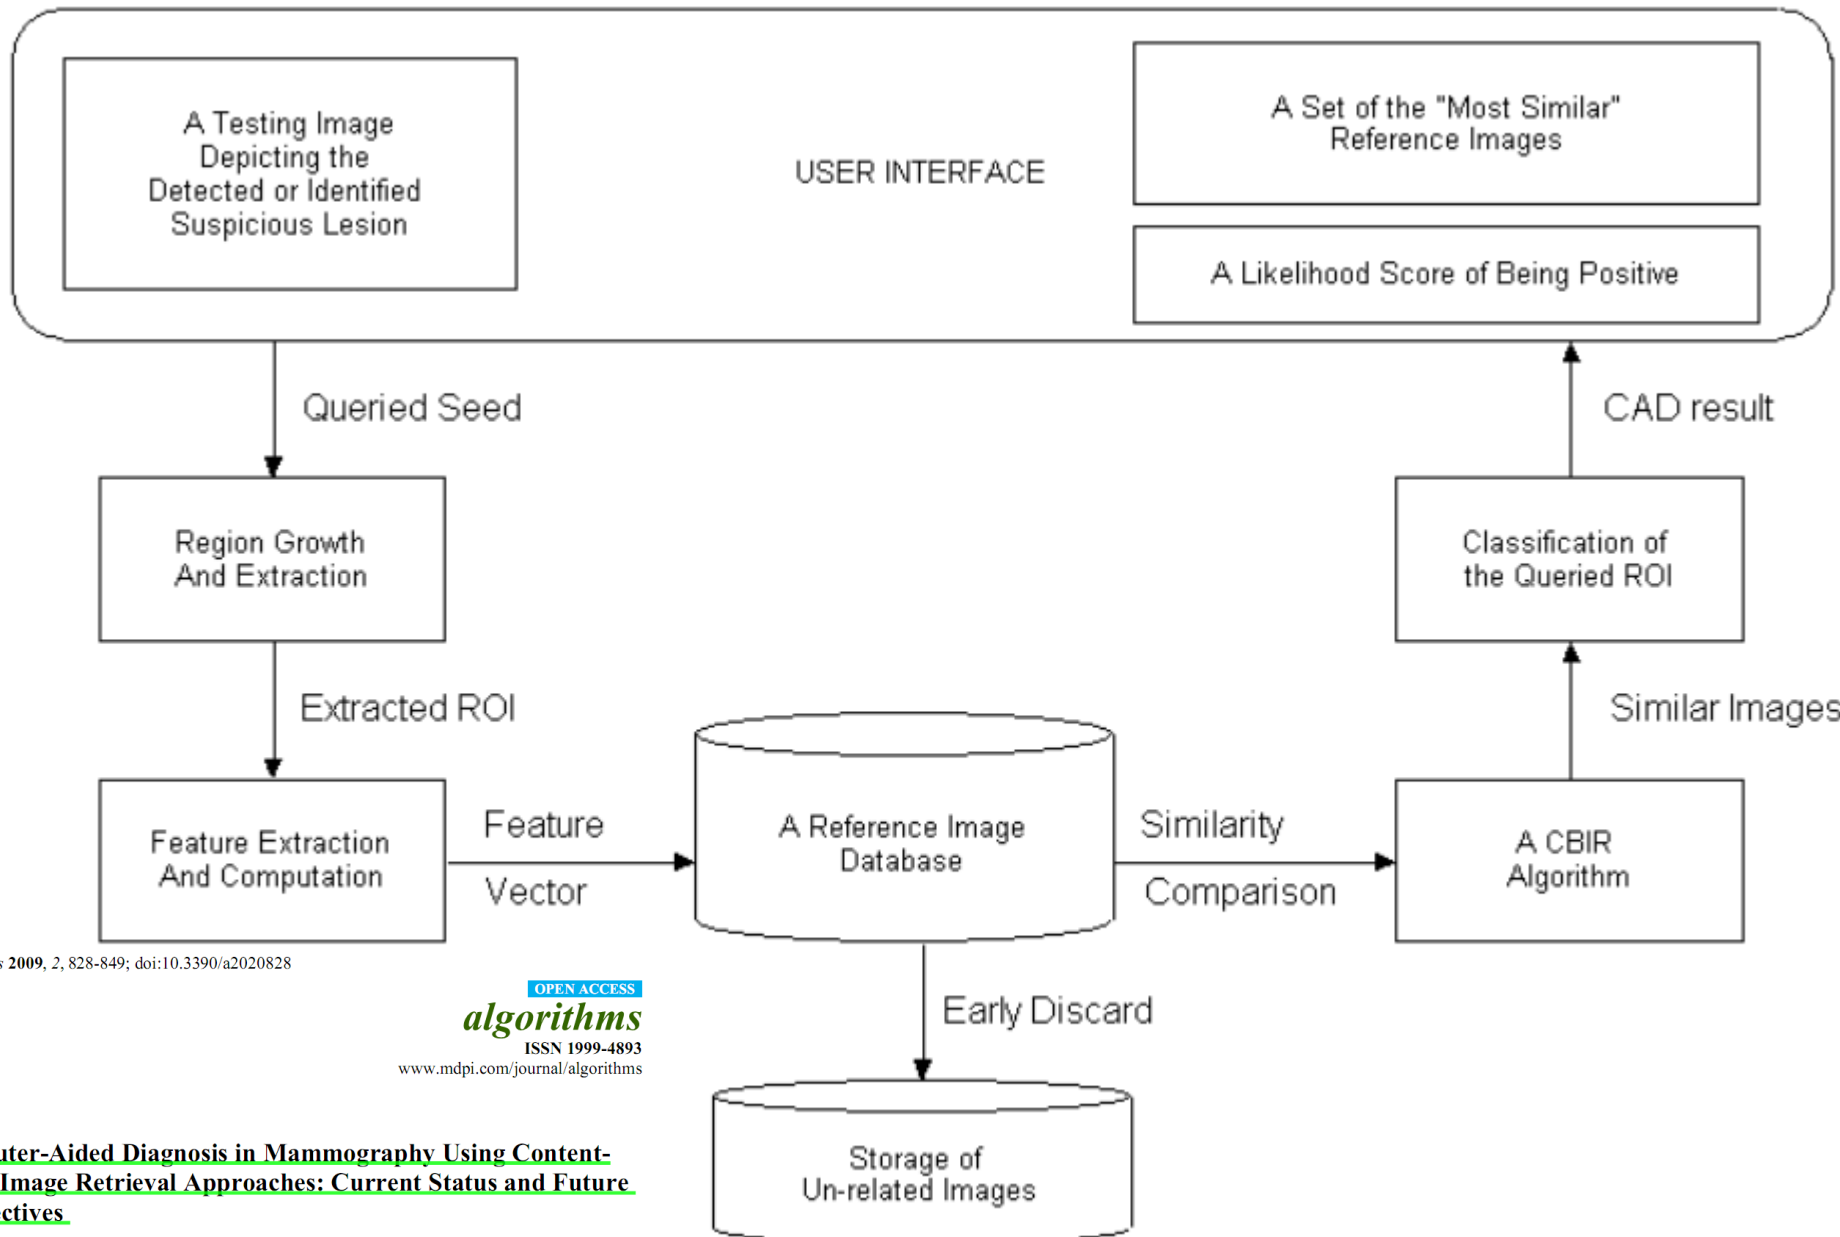
IRMA code

- Technique, Direction, Anatomy, Biosystem (TTTT-DDD-AAA-BBB)

Example: 1121-127-720-500

radiography, plain, analog, overview  
coronal, AP, supine  
abdomen, middle  
uropoetic system

# CAD-CBIR



Algorithms 2009, 2, 828-849; doi:10.3390/a2020828



OPEN ACCESS  
**algorithms**  
ISSN 1999-4893  
www.mdpi.com/journal/algorithms

Review

Computer-Aided Diagnosis in Mammography Using Content-Based Image Retrieval Approaches: Current Status and Future Perspectives

Bin Zheng





Detection Score: 0.96

Classification Score: 0.74

# Miary klasyfikacji zmian złośliwych

$$P_{TP} = \frac{\sum_{i=1}^N w_i^{TP}}{\sum_{i=1}^N w_i^{TP} + \sum_{j=1}^M w_j^{FP}}, \quad N + M = K,$$

- $N$  – liczba zmian złośliwych,  $M$  – liczba regionów bez raka w zbiorze,  $K$  – liczba regionów referencyjnych

- $w$  oznacza wartość podobieństwa zmian patologicznych TP lub łagodnych FP (w tym fałszywych wskazań CAD)

$$P_{TP} = \frac{1}{N} \sum_{i=1}^N w_i^{TP} - \frac{1}{M} \sum_{j=1}^M w_j^{FP}, \quad N = M = \frac{K}{2},$$

- optymalizacja bazy

Reference Database	Originally (randomly) Selected Database					“Optimized” Database
Number of ROIs	630	1262	1591	2523	3153	2979
Area under ROC Curve	0.715	0.794	0.874	0.875	0.872	0.914
Standard Deviation	0.026	0.023	0.017	0.017	0.017	0.012

# Inne zastosowanie - ocena wieku kostnego

- Ocena dojrzałości układu kostnego u dzieci
- Porównanie kości dłoni (nasady kości) ze standardowymi atlasami – tradycyjna ocena
- Rozwiązanie:
  - CBIR, opisana baza danych USC (1101 przypadków, wiek 0-18),
  - ocena podobieństwa (metoda korelacji wzajemnej)
  - szacunek wieku na podstawie 10 najlepszych odpowiedzi
  - skuteczność: błąd 0,99 roku, odchyl. stand. 0,76



2.5y, male



7y, male



10y, male





Int J CARS (2012) 7:389–399  
DOI 10.1007/s11548-011-0627-8

ORIGINAL ARTICLE

Web-based bone age assessment by content-based image retrieval  
for case-based reasoning

Benedikt Fischer · Petra Welter · Rolf W. Günther ·  
Thomas M. Deserno

# Procedura




wynik

# Narzędzie








**Bone Age Assessment 4.0**

901934



predicted Age: 7.06  
actual Age: 7.44





























All EROIs:

E1	E2	E3	E5	E6	E7	E9
 ID: 919534	 ID: 919535	 ID: 919536	 ID: 919537	 ID: 919538	 ID: 919539	 ID: 919540


next >>

Restart      EROIs to be processed: 0      Update      Possible values: 6, 7 (best six/seven) or 0 (for all).      Show corresponding Hands

corresponding EROIs used for the calculation:

E1	E2	E3	E5	E6	E7	E9
 ID: 921306 Score: 0.980 Age: 5.66	 ID: 931223 Score: 0.993 Age: 8.5	 ID: 925408 Score: 0.988 Age: 8.59	 ID: 932819 Score: 0.979 Age: 4.84	 ID: 932987 Score: 0.992 Age: 6.58	 ID: 923560 Score: 0.977 Age: 9.14	 ID: 919836 Score: 0.991 Age: 11.87
 ID: 925450 Score: 0.989 Age: 9.56	 ID: 925296 Score: 0.993 Age: 6.72	 ID: 919472 Score: 0.987 Age: 6.62	 ID: 923280 Score: 0.989 Age: 5.97	 ID: 932959 Score: 0.991 Age: 6.72	 ID: 919836 Score: 0.991 Age: 11.87	 ID: 919882 Score: 0.987 Age: 9.64
 ID: 919332 Score: 0.988 Age: 4.4	 ID: 931391 Score: 0.991 Age: 10.0	 ID: 929220 Score: 0.988 Age: 7.23	 ID: 923644 Score: 0.989 Age: 10.83	 ID: 933001 Score: 0.993 Age: 6.0	 ID: 919682 Score: 0.987 Age: 9.64	 ID: 919584 Score: 0.988 Age: 8.81
 ID: 925352	 ID: 932819	 ID: 923364	 ID: 925114	 ID: 919584	 ID: 923448	 ID: 927195

# Inny przykład - przeszukiwanie przestrzeni cech deskryptora



J Digit Imaging (2012) 25:708-719

**Content-Based Retrieval of Focal Liver Lesions Using Bag-of-Visual-Words Representations of Single- and Multiphase Contrast-Enhanced CT Images**

Wei Yang · Zhentai Lu · Mei Yu · Meiyuan Huang ·  
Qianjin Feng · Wufan Chen