


# Podstawy Teorii Informacji



Zarządzanie informacją (analiza, rozpoznawanie, interpretacja, wyszukiwanie)

Artur Przelaskowski

MiNI, p. 506, [artur.przelaskowski@pw.edu.pl](mailto:artur.przelaskowski@pw.edu.pl), tel.w. 7821

Materiały: [www.ire.pw.edu.pl/~arturp/Dydaktyka/PTI](http://www.ire.pw.edu.pl/~arturp/Dydaktyka/PTI)

---

Zarządzenie, czyli analiza, rozpoznawanie i wyszukiwanie informacji

# **METODY ANALIZY INFORMACJI (DANE OBRAZOWE)**

---

# Istotny problem analizy obrazów

---

- Trudne zadania - prawdziwe wyzwanie w przypadku analizy złożonej informacji obrazowej
    - **rozpoznawanie wzorców** określonej klasy obiektów
    - **liczenie deskryptorów** różnicujących treściowo opisywane struktury
    - obliczeniowa **interpretacja obrazów** – konieczne efekty rozumienia obrazów
  - Dominujące koncepcje
    - wydzielenie **składników treściowych** (region - segmentacja, potencjalne obiekty, czy komponenty semantyczne w dobranej dziedzinie opisu ...)
    - **opis cech** wydzielonych składników, np. z wykorzystaniem procedur generacji czy selekcji cech według ustalonych kryteriów
    - **rozpoznanie określonej klasy obiektów**, na bazie ustalonej przestrzeni cech i dobranych klasyfikatorów
    - **selekcja obiektów** ze względu na ich znaczenie, wiarygodność, ustaloną hierarchię ich właściwości
    - **rozumienie treści obrazów**: rezonans poznawczy, odniesienie zestawu cech obliczeniowych do sformalizowanej wiedzy dziedzinowej
    - **aproksymacja wymowy treści**, optymalizacja przybliżeń według wiarygodnych kryteriów jakości z regularyzacją komponentów istotnych i formowanie finalnego przekazu obrazowego
-

# Problem segmentacji (szerzej - wydzielenia komponentów, regionów, obiektów)

- **Segmentacja** - wydzielenie z obrazu **obszarów** (inaczej regionów spójnych, czyli będących w jednym kawałku), **struktur**, **obiektów** czy ogólnie podzbioru dziedziny z kryterium
  - **jednorodności** względem określonej właściwości danych (atrybutu) z kryterium dot. wewnętrznych, dominujących cech obiektu (np. kolor czerwony w sensie zdefiniowanego deskryptora koloru) lub mierzalnych granic obszarów (konturów)
  - **czytelnego znaczenia** (funkcji semantycznej), wynikającego ze specyfiki zastosowań
- Zasadniczym celem segmentacji jest **opis danych** obrazowych w ustalonej przestrzeni znaczeń (semantyka) poprzez zmniejszenie stopnia złożoności obrazu na wyższym poziomie abstrakcji
- Podstawowe metody
  - **obszarowe**, znajdujące regiony według obliczeniowego kryterium jednorodności, np. klasteryzacja, rozrost regionów, segmentacja wododziałowa
  - **krawędziowe/konturowe**, bazujące na wykrywaniu krawędzi i aproksymacji konturów rozdzielających regiony o odmiennych właściwościach, np. gradientowe, laplasjanowe, aktywnych konturów, kształtów, poziomic, przeszukiwania grafów
  - **probabilistyczne** (statystyczne), gdzie wykorzystywany jest określony model lokalnych zależności danych, statystyczne właściwości globalne, szacowanie rozkładów łańcuchów i pól losowych opisujących poszczególne regiony/cechy obrazowe itp. – np. progowanie, mieszaniny regionów, metody rozmyte (na bazie logiki rozmytej)
  - **obiektywne**, geometryczne, funkcjonalne, atlasowe .....
- Zastosowanie – klasyfikacja na bazie ekstrahowanych zestawów cech, interpretacja scen na podstawie rozkładu wydzielonych obiektów etc.







# Segmentacja, czyli obiektowo-zorientowana analiza

## Metody obrazowe

### Obszarowe

- Groupowanie (centroid, najbliższy sąsiad)
- Drzewo czwórkowe
- Wododziały (analogia map reliefowych: obraz jako powierzchnia topograficzna 3D z obszarami zlewni, piksele jako minima, punkty na zboczu i na grzbiecie, punkty graniczne przelewu do których sływa kropla na obrazie gradientowym)
- Rozrost regionów
- Metody punktowe (histogramowe) (e.g. progowanie z minimalizacją wariacji wewnątrzklasowej)

- Konturowe
- Probabilistyczne
- Transformacyjne



## Metody obiektowe

- Obrys manualny
- Aktywne kontury/kształty etc.
- Atlasy – modele z wiedzy




## Metody hybrydowe

# Segmentacja twarzy - przykłady



# Atlasy – modele realnych obiektów



Komputerowe atlasy mózgu wykorzystywane w Biomedical Imaging Laboratory, Singapur



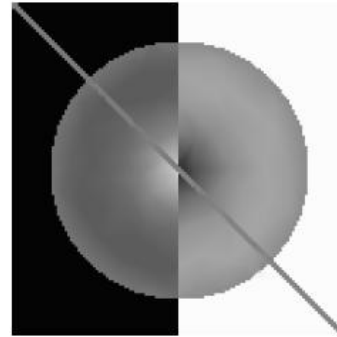


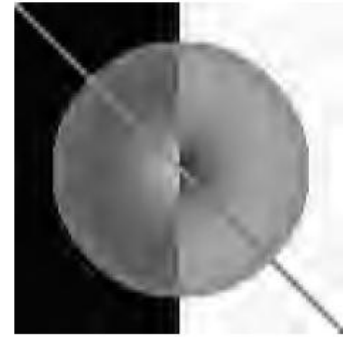




Fig. 4. Four ventricular systems and the detected landmarks from the clinical scans in WJ-30. Four columns from the left to right indicate: normal child, abnormal elder, normal male adult, and abnormal male adult. The four rows from the top to bottom indicate the 3-D views of the ventricular system, the 3-D views of the landmark 52, axial original MR slice indicating the detected landmark 54, and sagittal MR slice indicating the detected landmark 27 (and 23 if it is also detected in the slice).



# Modele geometryczne, przykłady analizy rozkładu prymitywów geometrycznych





# Modele obiektowe, czyli pasowanie wzorców (dane treningowe) – metoda aktywnych konturów



1) wpisanie modelu w obraz






2) dopasowanie



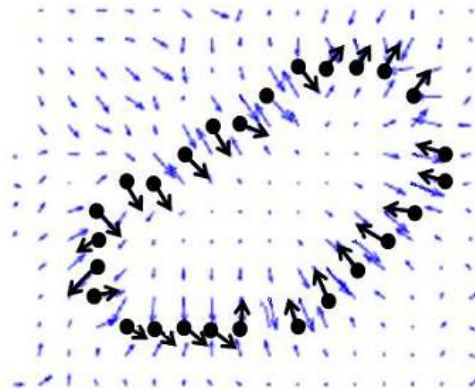
# Modelowanie konturów względem otaczających obszarów

- Obiektowe metody analizy obrazów (przede wszystkim segmentacji), obszarowo-krawędziowe (nawiązanie do obiektowych metod aktywnych konturów - **ACM** oraz aktywnych kształtów – **ASM** oraz poziomic (*level sets*) – **LSM**)
- **Ogólnie:** skalowalny, elastyczny, poruszający się wzorec, 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:** wzorec 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)



# Metoda aktywnych kształtów - ASM

- wykorzystuje **statystyczne modele kształtu obiektów** (analiza warunków pochodnych cząstkowych/krawędzi/całego konturu)
- iteracyjna deformacja kształtów, z możliwością wpasowania w krawędzie o zadanej rozkładem charakterystyce
- **mapa krawędzi**: uwzględnienie całego rozkładu lokalnych rozkładu gradientów funkcji jasności, ich kierunku oraz wartości – szacowanie **mapy krawędzi**  $\vec{M}(x, y)$  (zbiór wektorów zaczepionych w kolejnych punktach obrazu i wskazujących kierunek do znajdujących się w pobliżu krawędzi oraz ich siłę)



$$|\nabla f(x, y)| = \frac{\partial f}{\partial x} \cos \theta + \frac{\partial f}{\partial y} \sin \theta$$

- prędkość poruszania się każdego z pikseli w kierunku najistotniejszej krawędzi

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

$g$  – skalowanie,  $c$  – stopień krzywizny konturu.  $a_1, a_2$  - stałe, wpływające na dynamizm przemieszczania konturu oraz jego gładkość,  $\vec{N}$  - normalna do ściągającej krawędzi


# Aktywne kształty i rozszerzenia

- **ASM: aktywne modele kształtu** obiektów służące dopasowaniu konturów, parametryczne modele krzywej konturu  $\mathcal{K}(\mathbf{p})$ ; optymalizacja konturu za pomocą energetycznej funkcji kosztu
  - 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

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


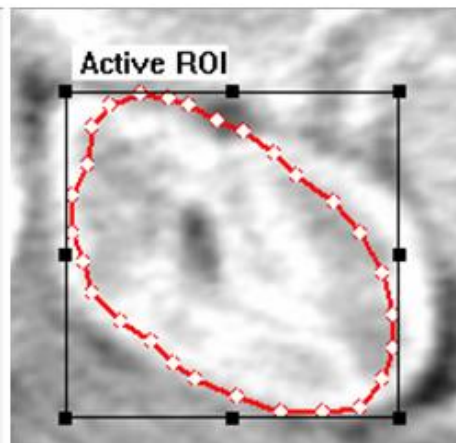

- **Rozszerzenie: pseudo-czasowy model konturu**  $\mathcal{K}(t) = v(x_{\mathcal{K}}, y_{\mathcal{K}}, t) \cdot \vec{N}$  opisanego parametrami i śledzonego za pomocą mapy gradientu i modelu hiperpowierzchni (wielowymiarowość dziedziny obrazów) (**level sets**)

# ASM - przykłady



Średni kształt modelu prawej nerki

Wpasowanie modelu prawej nerki



	Model	Parametry	Wykres funkcji celu	
Przed wpasowaniem		P1 4.19637		
		P2 -0.170415		
		P3 0.969333		
		P4 0.101694		
Po wpasowaniu		P5 -5.51414		
		P6 0.918305		
		P7 -1.03355		
		P8 0.243		
		koszt=11	Ilość iteracji = 139	Czas: poniżej sekundy

Wpasowanie lewej nerki

# 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


Kontur opisany zestawem parametrów  $\mathbf{p}$

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

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



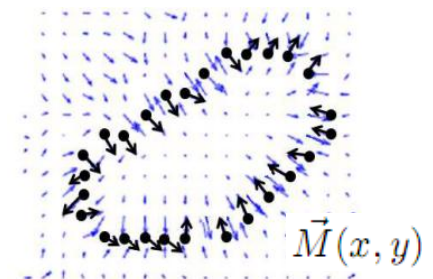
$$\mathcal{S}(\mathcal{K}(t), t) = 0 \Rightarrow \frac{\partial \mathcal{S}}{\partial \mathcal{K}} \cdot \frac{\partial \mathcal{K}}{\partial t} + \frac{\partial \mathcal{S}}{\partial t} = 0$$



- 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).

# Przykłady: wydzielone obiekty




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

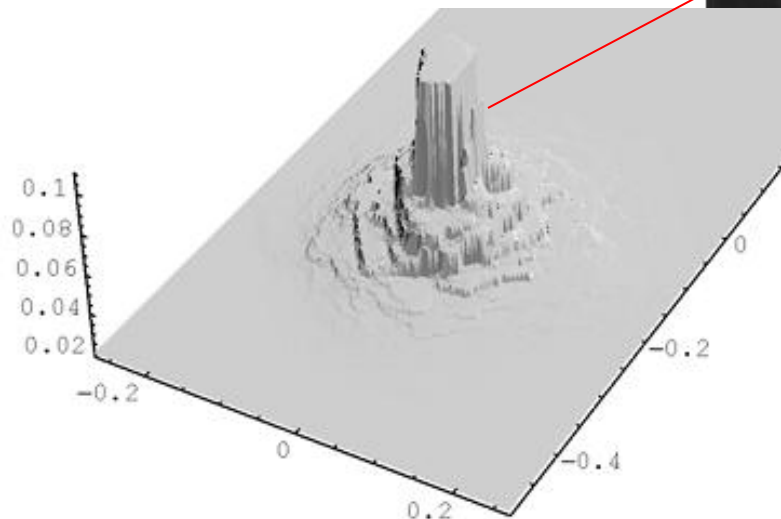



Metoda poziomicy (level sets): 'sól i pieprz', efekty odszumiania po 2 oraz 10 krokach

Metoda dyfuzyjna: wydzielenie ludzkich komórek

Koncepcja: zróżnicowany model obiektów względem nieobiektów z optymalizacją względem wybranych kryteriów

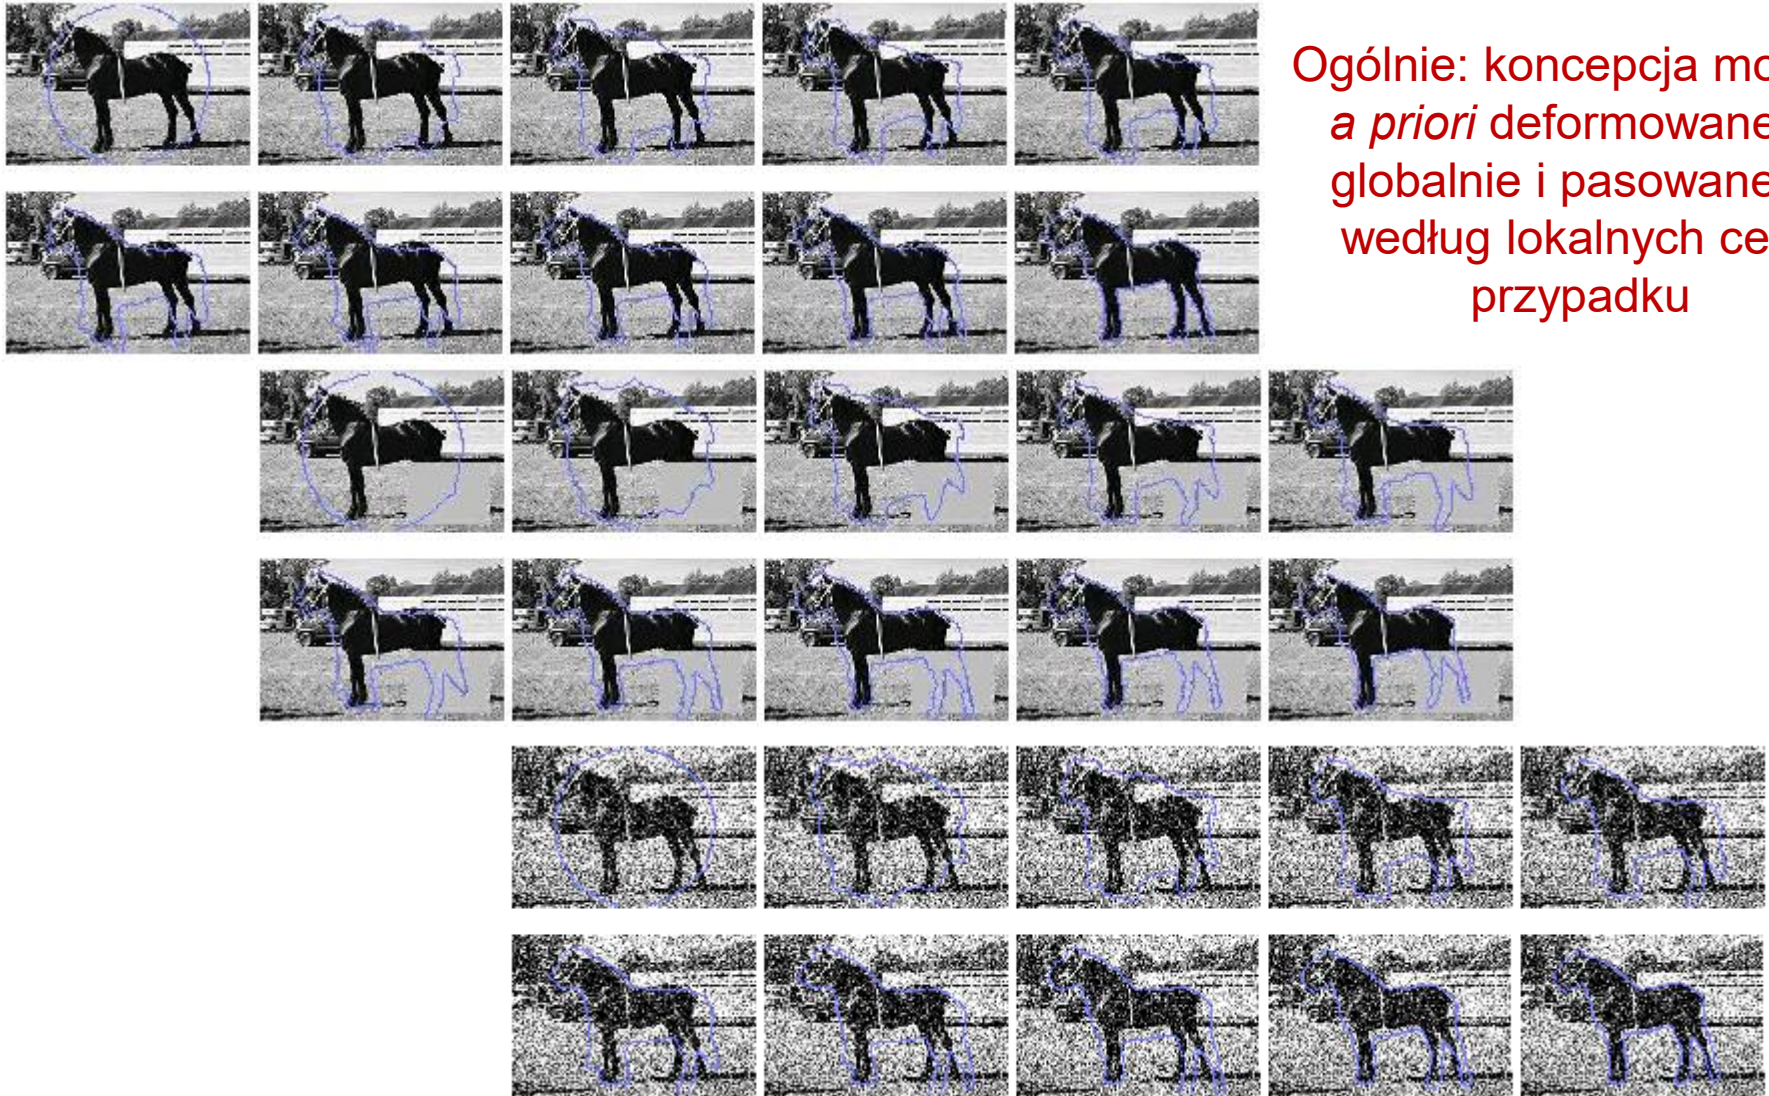


# Przykłady analizy- metoda *level setów*: segmentacja przedsionka, komory oraz guza



# Mapy krawędzi (kierunek i wartość gradientu) - efekty

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



# Model probabilistyczny: skończona mieszanina regionów

- dany jest obraz  $X$  o wymiarach  $M \times N$  oraz  $K$  regionach
- skończona mieszanina regionów opisująca obraz przyjmuje postać:

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


Modelując rozkłady warunkowe ogólnie (uogólnionym rozkładem Gaussa) mamy następującą postać funkcji gęstości prawdopodobieństwa:

$$P_k(x_i) = \frac{\alpha \beta_k}{2\Gamma(1/\alpha)} \exp[-|\beta_k(x_i - \mu_k)|^\alpha]$$


$$\alpha > 0, \quad \beta_k = \frac{1}{\sigma_k} \left[ \frac{\Gamma(3/\alpha)}{\Gamma(1/\alpha)} \right]^{1/2} \quad \Gamma(x) = \int_0^\infty u^{x-1} e^{-u} du$$

z parametrem  $\alpha$


Efekty dopasowania histogramów:




$\alpha = 1, H(P_F || P_X) = 0,0783$



$\alpha = 2, H(P_F || P_X) = 0,0369$



$\alpha = 3, H(P_F || P_X) = 0,0251$



$\alpha = 4, H(P_F || P_X) = 0,0282$



# Model całego obrazu - niezależny o identycznym rozkładzie (iid)

Obraz jest modelowany za pomocą pola losowego  $\mathbf{X}$ , statystycznie niezależnego o jednakowym rozkładzie:




$$P(\mathbf{x}) = \prod_{i=1}^{MN} \sum_{k=1}^K \pi_k P_k(x_i), \quad i = 1, \dots, M \cdot N \quad \mathbf{x} = [x_1, \dots, x_{MN}], \quad \mathbf{x} \in \mathbf{X}$$

Obraz  $X$  jest konkretną realizacją pola losowego  $\mathbf{X}$




Określa się prawdopodobieństwa  $P_k$  przynależności każdego ( $i$  – tego) z pikseli obrazu do poszczególnych regionów o wadze  $\pi_k$



*efekty  
modelowania*



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



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

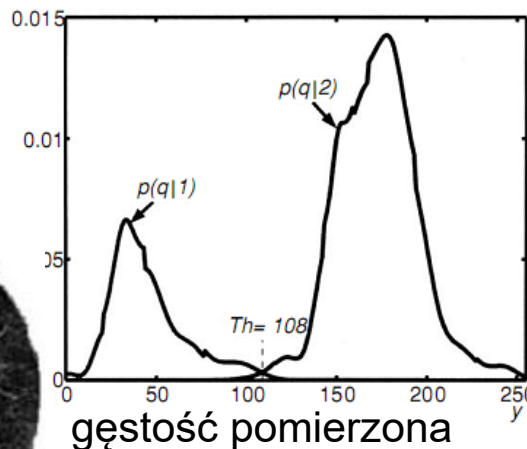
$$\sum_{k=1}^K \pi_k = 1,$$

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

gęstość estymowana

automatycznie

ręcznie przez radiologa



gęstość pomierzona

---

Ekstrakcja cech, klasteryzacja (grupowanie), klasyfikacja, czyli

# **ROZPOZNAWANIE OBIEKTÓW**

---

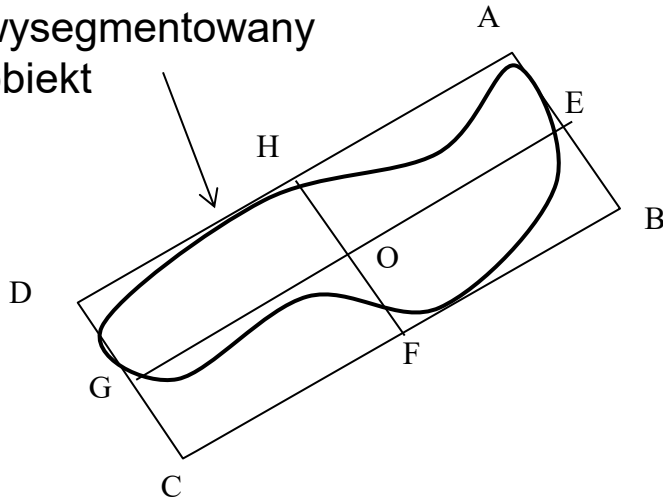
# Przykładowy zestaw cech określonych obiektów (wysegmentowanych wcześniej)

<i>Nr</i>	<i>Nazwa</i>	<i>Opis</i>
1	Powierzchnia	Rozmiar obiektu
2	Średnia	Średni poziom szarości, odchylenie standardowe poziomów szarości, poziom szarości tła obiektu
3	Odchylenie standardowe	
4	Tło	
5	Skontrastowanie obiektu i tła	$(\text{średnia pikseli obiektu} - \text{tło}) / (\text{średnia pikseli obiektu} + \text{tło})$
6	Współczynnik zwartości	$\text{obwód}^2 / \text{powierzchnia}$
7	Moment kształtu I	
8	Moment niezmienniczy I	
9	Kontrast	Cechy wyznaczone na podstawie macierzy zdarzeń
10	Entropia	
11	Moment zwykły drugiego rzędu	
12	Odwrotny moment różnicowy	
13	Korelacja	
14	Wariancja	
15	Entropia rozkładu sumacyjnego	

# Wybrane cechy

## Cechy kształtu:

wysegmentowany obiekt




- najdłuższa oś GE
- najkrótsza oś HF
- obwód i powierzchnia opisanego kwadratu ABCD
- wydłużenie:  $GE/HF$
- obwód  $p$  i powierzchnia  $A$  regionu


- kolistość  $C = \frac{4\pi A}{p^2}$

- upakowanie  $C_p = \frac{p^2}{A}$


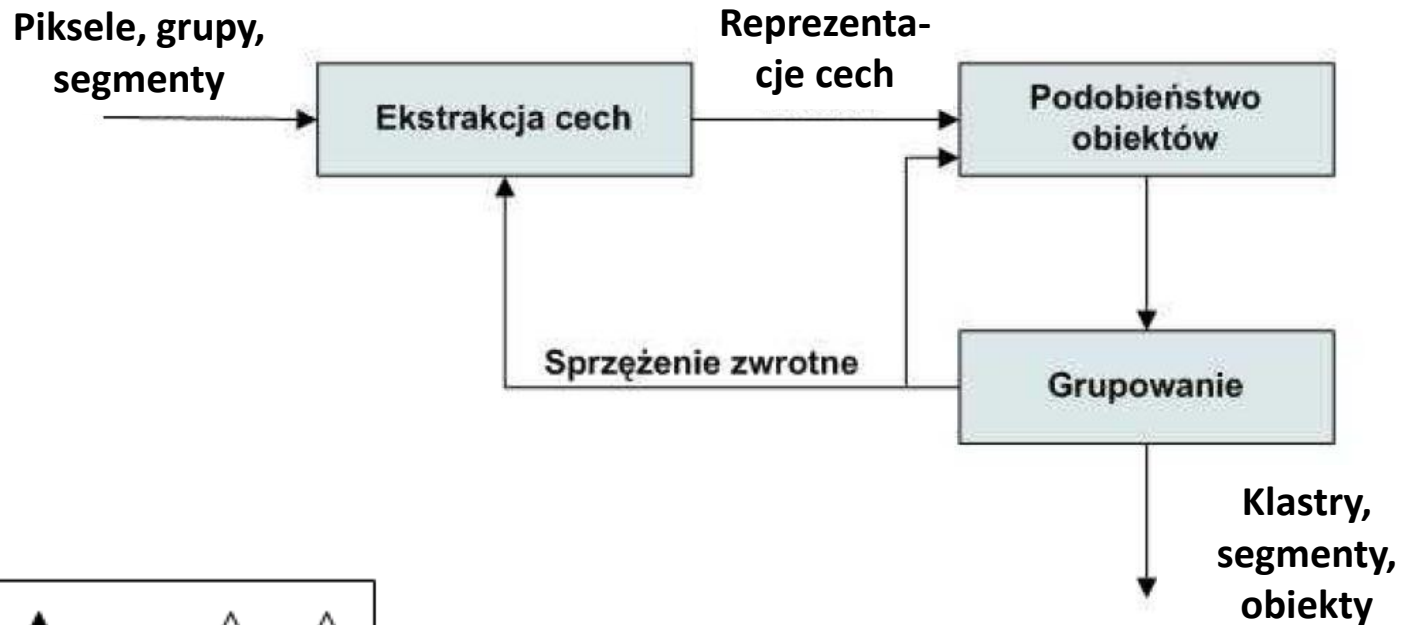
Cechy relacyjne:



I



# Metody grupowania elementów bez nadzoru (piksele-segmenty-objekty)




grupowanie twarde





grupowanie rozmyte

# Grupowanie: k-średnich (centroid, najbliższy sąsiad)

Przestrzeń cech ...



*minimalna odległość  
decyduje o wyborze grupy*



indeksy  $i=1,2,\dots$  centroidów-reprezentatów  
poszczególnych regionów/klas



Wybór regionu reprezentowanego  
przez najbliższy centroid:

$$\mathbf{f} \in C_i \Leftrightarrow D(\mathbf{f}, \mathbf{q}_i) = D_{\min}(\mathbf{f}, \mathbf{q}) = \min_{j=1, \dots, |C|} [D(\mathbf{f}, \mathbf{q}_j)]$$

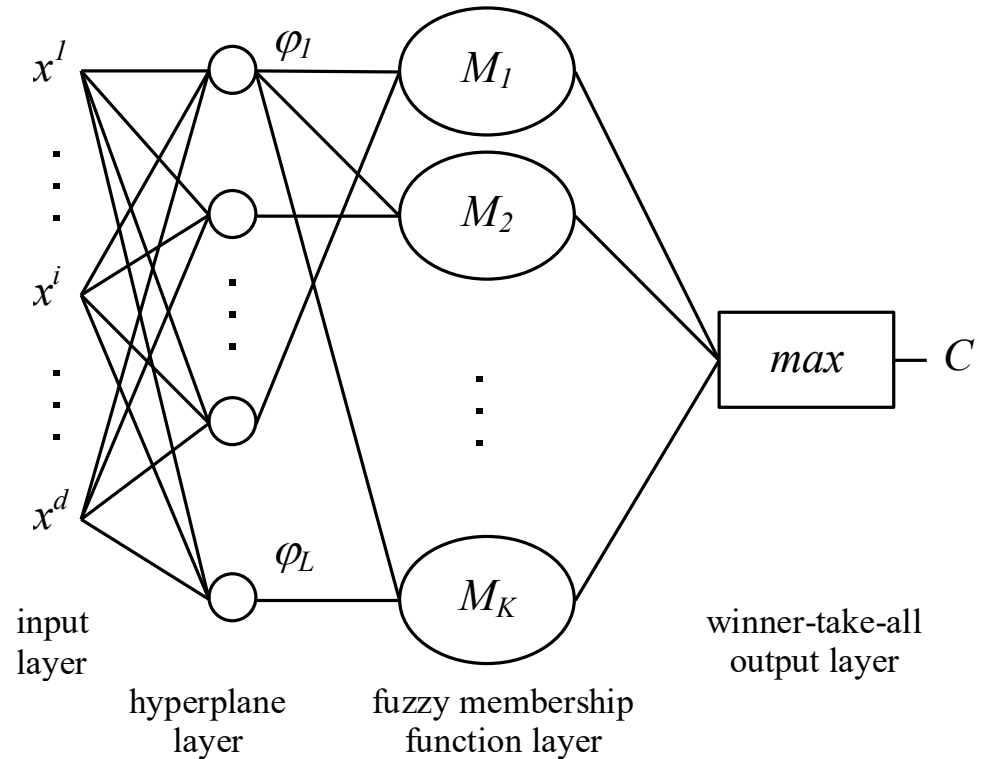
$$D(\mathbf{f}, \mathbf{q}) = \sqrt{\frac{1}{K} \sum_{k=1}^K (f_k - q_k)^2}$$

# Klasyfikacja

k-najbliższych sąsiadów (kNN), metody metryczne

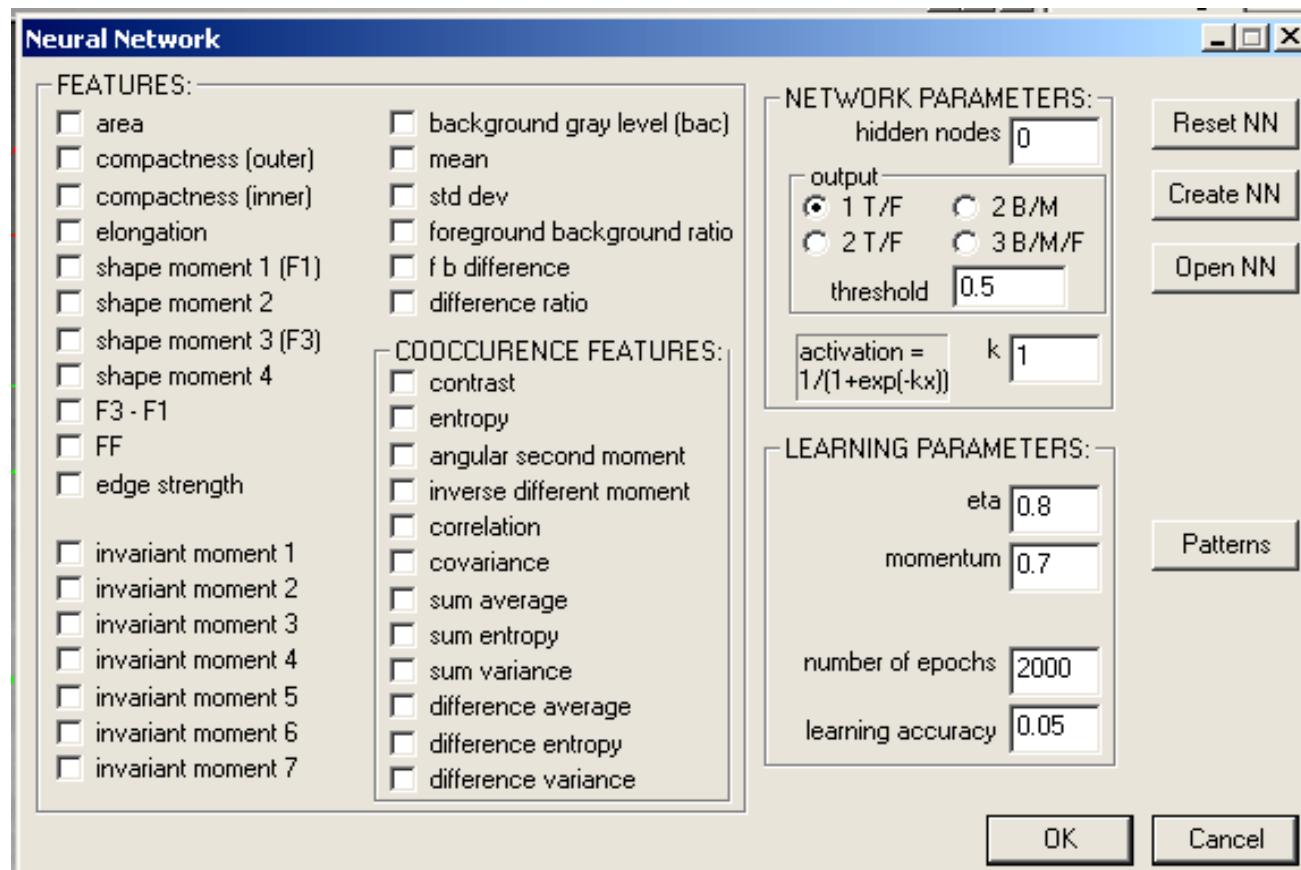


Neuronowe klasyfikatory rozmyte - przykład



Sieć neuronowa - dialog optymalizacji ...

# Prosta implementacja – przetrzeń cech z klasyfikatorem NN




Interfejs dialogowy

# Klasyfikacja statystyczna (naiwna metoda Bayesa)

$$P(\omega_j | x) = \frac{p(x | \omega_j)P(\omega_j)}{p(x)}$$

klasy  
dane


- Potrzebne są określone wzorce poszczególnych klas (ogólna wiedza o problemie, charakterystyka problemu)



Określamy prawdopodobieństwo a priori (prawdopodobieństwo zdarzenia przed obserwacją dowodów) wystąpienia obiektów poszczególnych klas (czerwonych i zielonych) metodą częstościową (na podstawie liczby obiektów danej klasy w stosunku do wszystkich obiektów) – chodzi o:

40 zielonych i 20 czerwonych, czyli  $P(z)=4/6$  oraz  $P(cz)=2/6$

- Klasyfikacja nowego obiektu (kółko białe - x), który pojawił się w przestrzeni wzorców (dziedzina problemu) – rozważamy określone jego sąsiedztwo (najbliższe wzorce)



Określamy prawdopodobieństwo a posteriori (po obserwacji dowodów, z doświadczenia) odnosząc liczbę czerwonych i zielonych w zaznaczonym sąsiedztwie (parametr) do całkowitej liczby wzorcowych reprezentantów danej klasy:

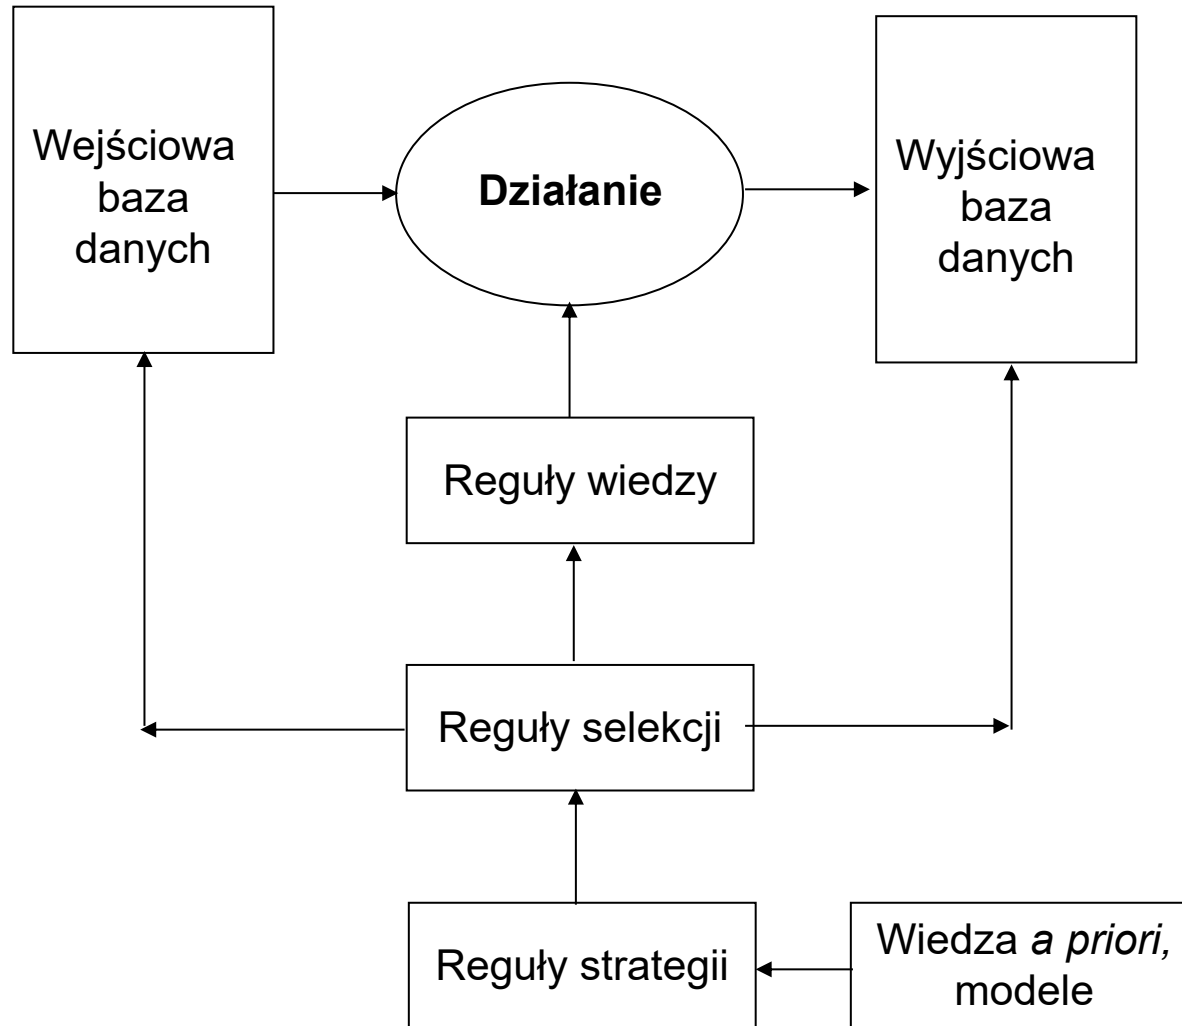
1 zielony i 3 czerwone w sąsiedztwie, czyli  $P(x/z)=1/40$  oraz  $P(x/cz)=3/20$

- Według reguły Bayesa, finalne prawdopodobieństwo liczymy jako iloczyn obu prawdopodobieństw (traktowane jako wagi, bez normalizacji)

$P(z/x)=P(z) \cdot P(x/z) = 4/6 \cdot 1/40 = \mathbf{1/60}$  oraz  $P(cz/x)=2/6 \cdot 3/20 = \mathbf{1/20}$ , czyli zdecydowanie **czerwony obiekt jest bardziej prawdopodobny**

na podstawie

# Wykorzystanie reguł semantycznych (diagnostycznych)



# Reguły strategiczne (region) - przykład

---

## Strategy Rule SR1:

If  
    NONE REGION is ACTIVE  
    NONE REGION is ANALYZED  
Then  
    ACTIVATE FOCUS in SPINAL\_CORD AREA

## Strategy Rule SR2:

If  
    ANALYZED REGION is in SPINAL\_CORD AREA  
    ALL REGIONS in SPINAL\_CORD AREA are NOT ANALYZED  
Then  
    ACTIVATE FOCUS in SPINAL\_CORD AREA

## Strategy Rule SR3:

If  
    ALL REGIONS in SPINAL\_CORD AREA are ANALYZED  
    ALL REGION in LEFT\_LUNG AREA are NOT ANALYZED  
Then  
    ACTIVATE FOCUS in LEFT\_LUNG AREA

---

# Reguły wiedzy - przykład

---

## Knowledge Rule: Merge\_Region\_KR1

If





REGION-1 is SMALL  
REGION-1 has HIGH ADJACENCY with REGION-2  
DIFFERENCE between AVERAGE VALUE of REGION-1 and  
REGION-2 is LOW or VERY LOW  
REGION-2 is LARGE or VERY LARGE

Then

MERGE REGION-1 in REGION-2  
PUT\_STATUS ANALYZED in REGION-1 and REGION-2


---

# Przykład z analizą mammogramu - wskazanie obszaru zainteresowań




# Detekcja mikrozwapnień – małych, jasnych obiektów występujących w skupiskach


---




przetworzony oryginał; uśrednienie i  
binaryzacja przez progowanie



oryginał




falkowa reprezentacja  
rzadka



lokalne maksima

---

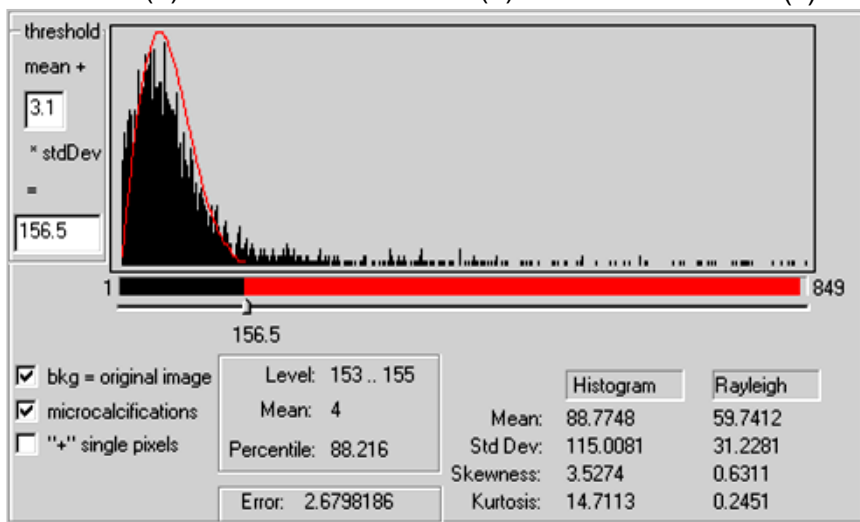
# Segmentacja progowa - przykładowe efekty detekcji mikrozwapnień




(a)

(b)

(c)



(d)






(e)

(f)




(g)

- (a) oryginalny obraz (powiększenie 250%)
- (b) obraz po filtracji 'white top-hat' (widoczne są bity 2-9 z obrazu z głębią koloru 12. bitową), element strukturalny: macierz 5x5 bez 4 punktów narożnych, 3 iteracje
- (c) obraz po filtracji 'white top-hat' z widocznymi bitami 1-8;
- (d) aproksymacja histogramu i znaleziony optymalny próg;
- (e) wynik progowania;
- (f) wynik progowania na tle obrazu oryginalnego
- (g) na czerwono zaznaczono kontury wewnętrzne wyodrębnione obiektów




# Detekcja mikrozwapnień – rekonstrukcja cech kształtu



Wynik detekcji - brak fałszywych  
wskazań.




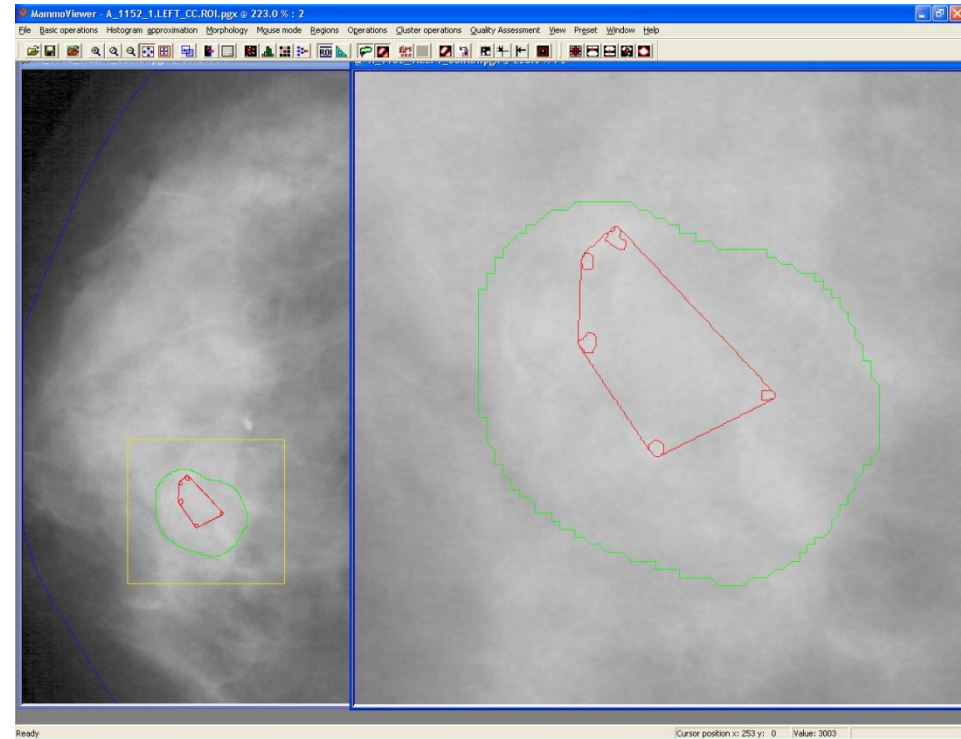
# Klasteryzacja, czyli wyznaczanie skupisk mikrozwapnień - efekty



# Uzyskana efektywność

Czułość detekcji  
mikrozwapnień na  
poziomie **90%**

klasyfikacja na  
łagodne/złośliwe: **74%**



---

# **INDEKSOWANIE I WYSZUKIWANIE OBRAZÓW**

---

# Podstawowe pojęcia

---

- Atrybut - ustalona właściwość (właściwości) obiektów multimedialnych, którymi charakteryzowane są elementy bazy danych
- Cecha - wartość danego atrybutu przypisana obiektowi:  $c=a(o)$
- Deskryptor - metoda, algorytm lub też zestaw liczb, które charakteryzują, czy wręcz identyfikują obiekty ze względu na określony atrybut (numeryczny sposób opisu atrybutów pojęciowych – tekstowych)
- Indeks – uporządkowana lista cech danego atrybutu, gdzie każdej z cech przypisana jest z kolei lista wskaźników do obiektów zawierających daną cechę

Na indeks składają się więc:

- określenie **atrybutu** (prosty, złożony)
  - **lista cech** (poszukiwanie cech reprezentatywnych)
  - przypisany każdej cesze **zestaw (lista) identyfikatorów** (wskaźników, adresów) obiektów posiadających daną cechę
  - Przykład 1: indeks książki wokół atrybutu słowa kluczowe (właściwość tekstów), gdzie na kolejnych pozycjach znajdują się zwykle w porządku alfabetycznym kolejne słowa kluczowe (cechy tekstu) z numerami stron (identyfikatorami obiektów), gdzie takie słowa występują
  - Przykład 2: indeks filmów wypożyczalni z atrybutem złożonym – kategoria opisująca charakter filmu, treść, dozwolony przedział wiekowy widzów, gwiazdkowa skala atrakcyjności według ocen ekspertów, wskaźnik popularności wypożyczeń, czas trwania filmu
-

# Podobieństwo


- Funkcja podobieństwa  $\rho_a(a(o), a(o_1))$  zależy od atrybutu oraz doboru reprezentatywnych cech
- Przykład 1: W przypadku atrybutu  $a = \text{kolor}$  w modelu RGB, podobieństwo można oprzeć np. na mierze kosinusowej. Niech wektory  $x = [r_1, g_1, b_1]^t$ ,  $y = [r_2, g_2, b_2]^t$ , reprezentują dwa kolory w przestrzeni RGB. Wtedy

$$\rho(x, y) \triangleq \cos(x, y) \triangleq \frac{x^t y}{\|x\| \|y\|} = \frac{r_1 r_2 + g_1 g_2 + b_1 b_2}{\sqrt{r_1^2 + g_1^2 + b_1^2} \sqrt{r_2^2 + g_2^2 + b_2^2}}$$

- Przykład 2: cechami są liczby nie różniące się więcej niż o  $M$

$$\rho(x, y) \triangleq 1 - \frac{|x - y|}{M}$$

- Przykład 3: cechy w kwadracie o boku 1



$$\rho(x, y) \triangleq 1 - \frac{\|x - y\|}{\sqrt{2}}$$

# Metryki

- **Przestrzeń metryczna**, liniowa (zdefiniowane dodawanie i mnożenie), unormowana (określa długość wektora) – zbiór wektorów z określonym pojęciem odległości między jego elementami, inaczej metryki (norma różnicy wektorów)

- Warunki metryki:  
$$\|x - y\| = 0 \Leftrightarrow x = y$$
$$\|x - y\| = \|y - x\|$$
$$\|x - z\| \leq \|x - y\| + \|y - z\|$$

- Przykładowe metryki

a) euklidesowa:  $\|x - y\|_e = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$

b) taksówkarza:  $\|x - y\|_t = \sum_{i=1}^n |x_i - y_i|$

c) maksimum:  $\|x - y\|_\infty = \max_{i=1, \dots, n} |x_i - y_i|$

- d) Mahalanobisa (wektorów nieskorelowanych o różnej wariancji):

$$\|x - y\|_m = \sqrt{\sum_{i=1}^n \frac{(x_i - y_i)^2}{\sigma_i^2}}$$

e) binarna:  $\|x - y\|_b = \begin{cases} 0, & \text{dla } x_i = y_i \\ 1, & \text{dla } x_i \neq y_i \end{cases}$

# Deskryptory

## ■ Deskryptorem jest

- meta-dane wyznaczone automatycznie jako charakterystyka sygnału cyfrowego (określonego zbioru danych) przenoszącego określoną treść
- słowo, fraza, znaki alfanumeryczne, zestawy liczb
- metoda czy algorytm służące charakterystyce czy wręcz identyfikacji obiektów (składników treści) sygnałów naturalnych
- numeryczny sposób opisu atrybutów pojęciowych
- dotyczy określonego atrybutu, czyli wybranej właściwości obiektów będąc **realizatorem numerycznego opisu danego atrybutu**
- zastosowanie: systemy gromadzenia i przeszukiwania informacji

## ■ Przykłady

- globalne deskryptory tekstury: wymiar fraktalny, entropia, pole losowe Markowa, macierz powinowactwa/zdarzeń/współwystąpień GLCM (*Gray Level Co-Occurrence Matrix*), filtry Gabora



# Miary selektywności – precyzja i przywołanie

---

- precyzja

$$p \triangleq \frac{1}{|Q|} \sum_{q \in Q} \frac{N(q)}{K(q)}$$

- przywołanie

$$r \triangleq \frac{1}{|Q|} \sum_{q \in Q} \frac{N(q)}{M(q)}$$

gdzie  $q$ -zapytanie,  $N(q)$  – liczba zwróconych obiektów podobnych,  $K(q)$  – liczba wszystkich zwróconych obiektów,  $M(q)$  – liczba podobnych obiektów w bazie

- stopa sukcesu

$$sr \triangleq \frac{1}{|Q|} \sum_{q \in Q} \delta(q)$$

przy czym  $\delta(q) = 1$ , jeśli na pierwszym miejscu zwracany jest obiekt podobny, zaś  $\delta(q) = 0$  - w przeciwnym razie

---

# Miary selektywności – średnia ranga

---

- Średnia ranga:

$$\bar{s} \triangleq \frac{1}{|Q|} \sum_{q \in Q} s(q)$$

gdzie

$$s(q) \triangleq \frac{1}{M(q)} \sum_{m=1}^{M(q)} \pi(m, q)$$


oraz

$$\pi(m, q) \triangleq \begin{cases} k, & \text{jeśli } m\text{-ty element podobny} \\ & \text{zajmuje } k\text{-tą pozycję na liście wyników i } k \leq K(q). \\ K(q) + 1, & \text{w przeciwnym razie} \end{cases}$$

---

# Podstawowe schematy wyszukiwania


Zapytanie: „Struś”




*obrazy adnotowane*



Zapytanie:



*deskrytory:*



# Semantyczna zgodność (dopasowanie)



luka semantyczna



Problem złego dopasowania ekstrahowanych z obrazu cech obliczeniowych z cechami mającymi znaczenie dla użytkownika





'trudna' zgodność (odmienne cechy wizualne)



różne stopnie wieloznaczności treści

# Podobieństwo treści




---

# **FORMALIZACJA I ROZSZERZENIA TEORII SEMANTYCZNEJ**

---


# Dookreślenie informacji semantycznej

- Semantyka to modelowanie znaczeń; to efekt wielu ludzkich zdolności poznawczych (umysłowych)



Luke Mastin in: <http://www.human-memory.net/types.html>


Reprezentacja powiązań pomiędzy pojęciami (w ludzkiej pamięci)



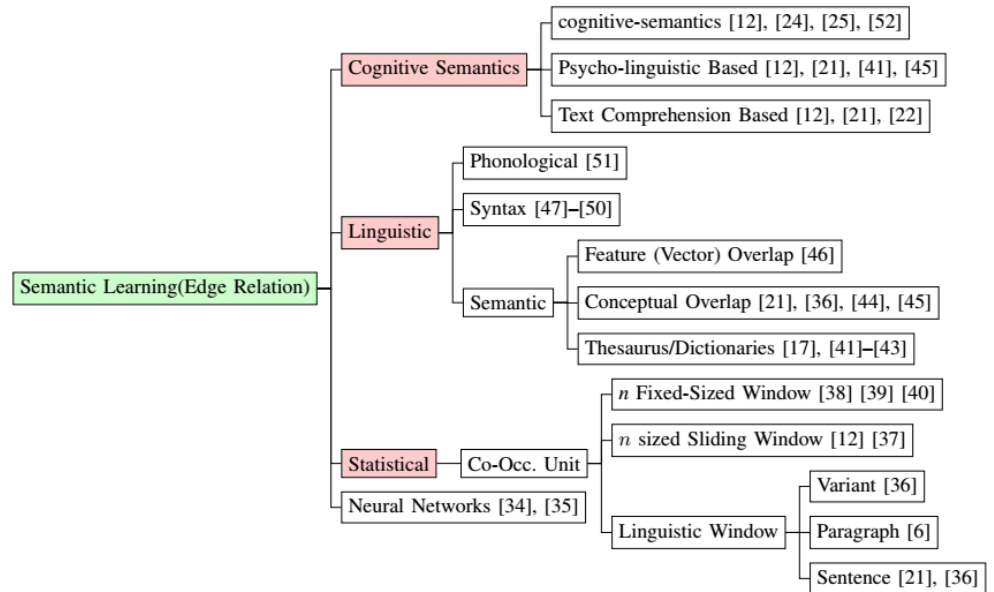
A. M. Collins and E. F. Loftus, "A spreading-activation theory of semantic processing." *Psychological review*, vol. 82, no. 6, p. 407, 1975

# Modele semantyczne

Nieukierunkowany model rosnącej sieci - odcień węzłów wskazuje krok czasowy, w którym węzły zostały po raz pierwszy wstawione



M. Steyvers and J. B. Tenenbaum, "The large-scale structure of semantic networks: Statistical analyses and a model of semantic growth," *Cognitive science*, vol. 29, no. 1, pp. 41–78, 2005



Badania taksonomiczne dotyczące semantycznego wymiaru uczenia się tekstów-grafów

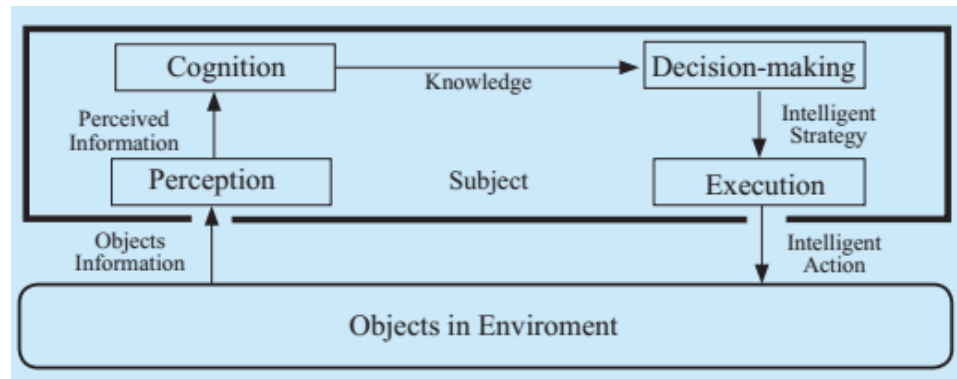
I. Ali and A. Melton, "Graph-based semantic learning, representation and growth from text: A systematic review," in *2019 IEEE 13<sup>th</sup> International Conference on Semantic Computing (ICSC)*. IEEE, 2019, pp. 118–123

# Semantyka przekazu, czyli przestrzeń działań orientowanych na informację

- Założenia: sensowne, znaczące i prawdziwe dane
- Założenie prawdy jest istotne (niekiedy budzi wątpliwości), wynika z natury zjawisk poznawanych
- Znaczenie odnosi się do konkretnych, praktycznych zastosowań


## ■ Informacja

- Tłumaczy
- Polaryzuje
- Normalizuje
- Weryfikuje i waliduje
- Koryguje



Model of information ecosystem

## Modele semantyczne



Relation of semantic information to syntactic and Pragmatic information

## A Theory of Semantic Information

(Invited Paper)

Yixin Zhong


Beijing University of Posts and Telecommunications, Haidian District, Beijing 100876, China

China Communications • January 2017

# Wykorzystanie informacji (semantycznej)


*indukcja, czyli przenoszenie treści między osobami w procesie komunikacji*

*pobudzenie, inspiracja*



*Internal Chain of Knowledge Ecology*

*Instyngt - wrodzona zdolność wykonywania pewnych czynności stereotypowych, niewyuczonych, mniej lub bardziej skomplikowanych swoistych dla danego gatunku istotnych dla jego przetrwania*



*External Chain of Knowledge Ecology*

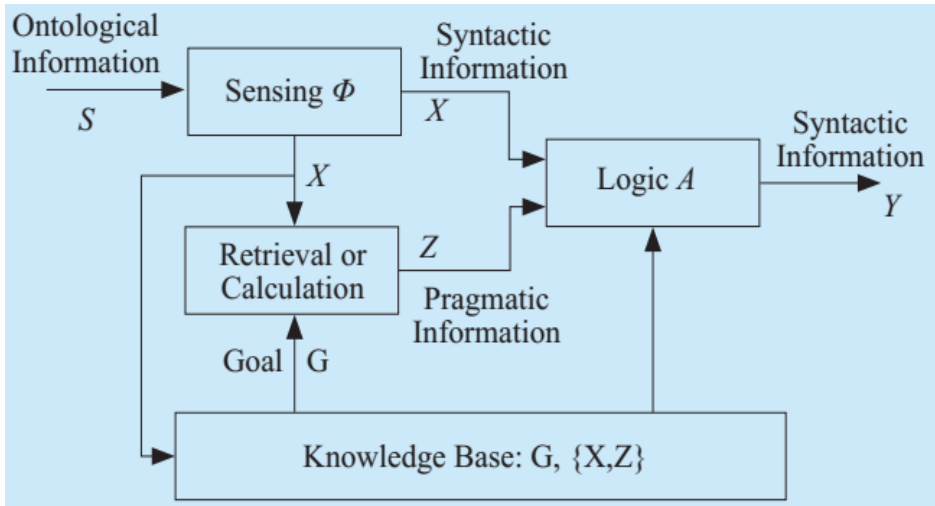
## A Theory of Semantic Information

(Invited Paper)

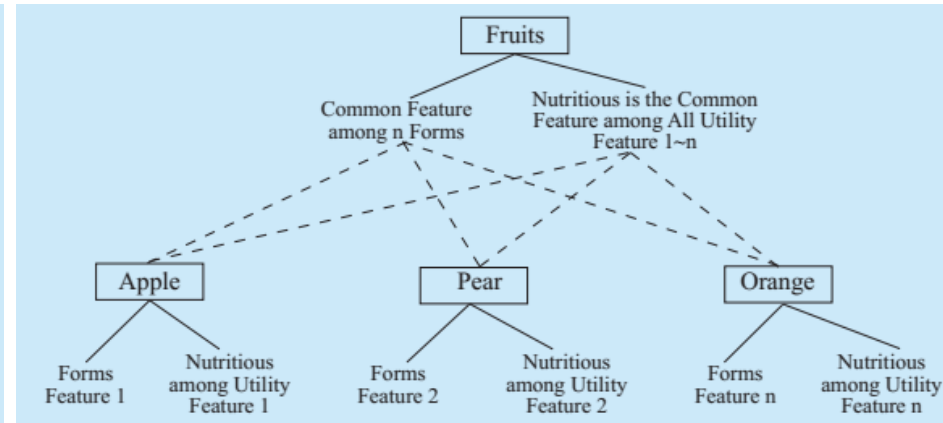
Yixin Zhong

Beijing University of Posts and Telecommunications, Haidian District, Beijing 100876, China



# Droga prosta i odwrotna: od wiedzy praktycznej do składniowego modelu informacji



*Model for semantic information generation*



*An Example of Inductive Cognition based on Semantic information*



*Strategy Producing based on Semantic Information*

*Cognition with autonomously Understanding based on Semantic Information*

# Semantyczne procesy poznawcze

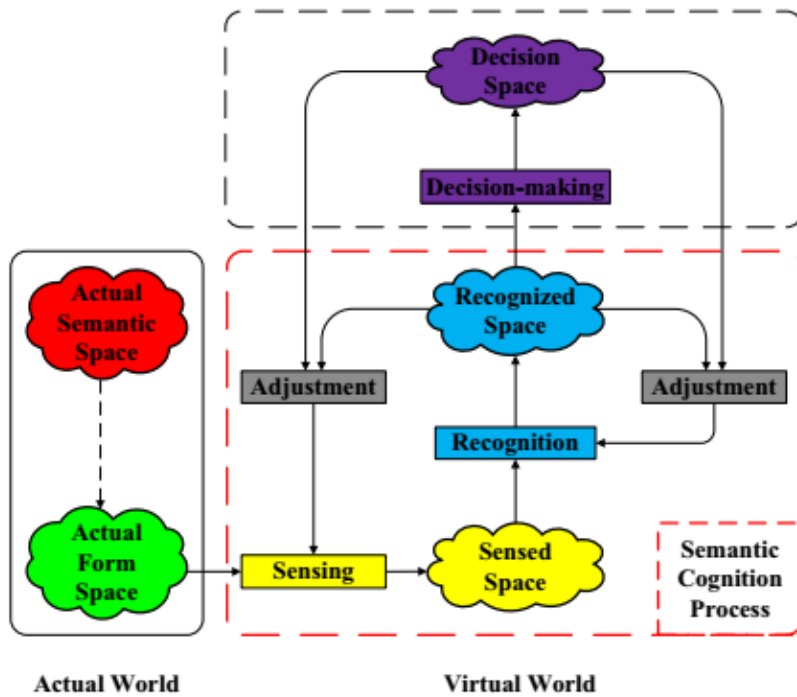


Figure 1. The natural connotation of semantic cognition process (SCP).




Figure 2. The three-layer framework of semantic cognition process (SCP).

An Introduction of Cognition Information: Form Aspect to Semantic Aspect

Shuo Feng, Qihui Wu, Jinlong Wang, Yuhua Xu, Guoru Ding

22nd Wireless and Optical Communication Conference, 2013