
**PODSTAWY INŻYNIERII DIAGNOSTYKI OBRAZOWEJ
W MEDYCYNIE (PIDOM)**

KOMPUTEROWA INŻYNIERIA OBRAZÓW

Artur Przelaskowski
materiały do wykładu
(rysunki w dużej części ze źródeł internetowych oraz własnych)

Wybrane zasady i metody


Komputerowa inżynieria obrazów

Trzy zasadnicze obszary


- **wsparcie systemów obrazowania (technologia – obraz)**
 - zasada akwizycji
 - zasada rekonstrukcji
 - zasada wizualizacji
 - zasada kryteriów jakości
 - **środowisko systemów teleinformatycznych (radiologia cyfrowa)**
 - zasada integracji
 - zasada standaryzacji
 - zasada komunikacji
 - **metody inteligencji komputerowej (diagnostyka-weryfikacja-metody)**
 - zasada symptomów patologii
 - zasada błędów
 - zasada trafności
 - zasada weryfikacji
 - zasada modelu, czyli rozwiązywanie problemów dużych
 - zasada dowodu, czyli rozwiązywanie problemów małych
-

Narzędzia wspomagania - aplikacje

- Detekcja mammografii (MammoViewer)
- Semantyczna percepcja – detekcja zawału mózgu (MonitorUdaru)
- Przykładowe metody przetwarzania obrazów
- Zastosowania



Detekcja mikrozwapnień - *MammoViewer*




Wstępne przetwarzanie –
digitalizacja obrazu

Detekcja

Klasyfikacja


Normalizacja mammogramu



oryginał







rozkład energii dochodzącej
do okładek wzmacniających





obraz promieniowania
rozproszonego

Wyznaczenie obszaru zainteresowań



Metody uwydatnienia mikrozwapnień (*MammoViewer*)



- Filtracja w przestrzeni obrazu
- Korekcja histogramu
- Eliminacja tła poprzez **odejmowanie** obrazu wygładzonego od oryginalnego
- Modelowanie zdrowej tkanki poprzez techniki **fraktalne**
- **Operatory morfologiczne** – ‘white top-hat’, który uwypukla szczegóły obrazu
- **Wieloskalowe** metody usuwania szumu
 - Usuwanie niskoczęstotliwościowych informacji
 - Progowanie podpasów zawierających wysokoczęstotliwościowe współczynniki falkowe (HH,HL,LH); następnie rekonstrukcja obrazu
- Wzmacnianie **oparte na sąsiedztwie** - zasięg i kształt regionu dostosowuje się do lokalnej zmienności funkcji jasności



Operacje histogramowe

- Rozciąganie histogramu

$$\bar{f}(k,l) = \frac{f(k,l) - \min_f\{f(k,l)\}}{\max_f\{f(k,l)\} - \min_f\{f(k,l)\}} \cdot a_{M-1}$$



Metody przetwarzania obrazów



- rejestracja danych
 - kodowanie danych cyfrowych
 - ulepszanie danych
 - analiza danych, w tym:
 - rozpoznanie wzorców
 - rozumienie danych
 - opis danych za pomocą numerycznych deskryptorów
 - interpretację danych
 - synteza danych na podstawie:
 - modeli elementarnych (strukturalnych)
 - modeli złożonych (obiektowych)
 - modeli probabilistycznych
 - modeli fizycznych i pseudofizycznych (empirycznych)
 - wyszukiwanie poindeksowanych danych podobnych
-

Metody ulepszania obrazów



- operacje histogramowe: a) adaptacyjne - na bazie relacji histogramu źródłowego do docelowego w skali globalnej bądź lokalnej; b) według ustalonego przyporządkowania punkt źródłowy - punkt docelowy;
- filtracje splotowe: a) kontekstowe w przestrzeni źródłowej; b) skalowalne (połączone ze zmianą skali sygnału źródłowego);
- filtracje częstotliwościowe, wykorzystujące transformacje Fouriera sygnałów źródłowych oraz częstotliwościowe charakterystyki filtrów (mnożone przez widmo sygnału);
- operacje morfologii matematycznej, wykorzystujące oddziaływanie określonego elementu strukturującego (inaczej strukturalnego) na geometryczne właściwości obiektów;
- przekształcenia geometryczne źródłowych przestrzeni dyskretnych, przede wszystkim afiniczne (obróć, skalowanie, przesunięcie) w rzeczywistych przestrzeniach euklidesowych (celem np. korekty źle ustawionego obiektywu kamery czy dopasowania obrazów tej samej rzeczywistości wykonanych różnymi technikami);
- aproksymacje z wykorzystaniem liniowych rozwinięć sygnałów: a) interpolacja (np. w celu zwiększania rozdzielczości danych źródłowych - superresolution); b) ekstrapolacja (np. w celu wypełniania dziur, czyli ogólniej - brakujących fragmentów w sygnale źródłowym - inpainting);

Uwydatnienie zmian



oryginał



po rozciągnięciu
histogramu



po lokalnie
sterowanej
binaryzacji
histogramu



Operacje histogramowe

■ Wyrównywanie (przekształcanie) histogramu

- Alfabet

$$f(k, l) \in A_f = \{a_0, \dots, a_{M-1}\}$$

- Histogram - pary wartości $(a_m, h(m))$

$$h(m) = \#\{f(k, l) | f(k, l) = a_m\}$$

- Znormalizowany histogram $\{p(m)\}_0^{M-1}$

$$p(m) = h(m)/H_f, \text{ gdzie } p(m) = p(a_m) = Pr(a_m) = Pr(f = a_m) \quad H_f = \sum_{m=0}^{M-1} h(m)$$

- Przekształcenie $S : f \rightarrow g$ takie że $\{p_f(m)\} \rightarrow$ równomierne (lub inne) $\{p_g(n)\}$
- Wykorzystujemy skumulowany histogram i równoważymy

$$P_g(b_n) = P_f(a_m) \qquad P(f \leq a_m) = P_f(a_m) = \sum_{k=0}^m p_f(k)$$
$$\sum_{l=0}^n p_g(b_l) \cong \sum_{k=0}^m p_f(a_k)$$

co przy normalizacji

$$g \in [0, 1], \text{ co daje } P(g \leq 1) = 1, \text{ a } P(g \leq b_n) = P_g(b_n) = b_n$$

daje

$$b_n = P_f(a_m)$$

Algorytm wyrównania histogramu

1. Wyznacz histogram obrazu źródłowego $\mathbf{f}$, taki że
 $f(k, l) = a_m \Rightarrow h_f(m) = h_f(m) + 1$ na podstawie wartości wszystkich H_f pikseli obrazu, takich że $f(k, l) \in A_f$;
2. Wyznacz źródłowy histogram skumulowany, taki że
 $P_f(a_m) = P_f(a_{m-1}) + h_f(m)$;
3. Oblicz wartości funkcji jasności obrazu docelowego, przyporządkowane poszczególnym a_m według zależności

$$b_n = \left\lceil P_f(a_m) \cdot b_{N-1} \right\rceil \quad (1.15)$$


gdzie operator $\lceil \cdot \rceil$ oznacza przybliżenie do najbliższego symbolu alfabetu A_g ;

4. Wyznacz postać obrazu przetworzonego $\mathbf{g}$, tak że $\forall_{(k,l)} f(k, l) = a_m \Rightarrow g(k, l) = b_n$ według (1.15). Zakończ.

Uwydatnianie guzków (korekcja histogramu)




(a)



(b)





(c)



(d)

Obraz radiologiczny guza spikularnego. (a) Obraz oryginalny; (b) Histogram obrazu (a); (c) Obraz po wyrównaniu histogramu; (d) Histogram obrazu (c).

Poprawa kontrastu



Przykładowo:

$$f_p = a \cdot \log(1 + f)$$

Efekty (gamma, negatyw, solaryzacja, okno)

$$g(k, l) = f(k, l)^\gamma \qquad g(k, l) = 1 - f(k, l)$$

$$g(k, l) = \begin{cases} 2 \cdot f(k, l) & \text{dla } 0 \leq f(k, l) \leq 0,5 \\ 2(1 - f(k, l)) & \text{dla } 0,5 < f(k, l) \leq 1 \end{cases}$$



$$g(k, l) = \begin{cases} 0 & \text{dla } 0 \leq f(k, l) \leq d \\ \frac{1}{g-d}(f(k, l) - d) & \text{dla } d < f(k, l) < g \\ 1 & \text{dla } g \leq f(k, l) \leq 1 \end{cases}$$

w porządku od lewej do prawej, góra-
dół mamy kolejno:

- obraz źródłowy
- korekcja gamma $\gamma = 2, 2$
- korekcja gamma $\gamma = 1/2, 2,$
- negatyw
- solaryzacja
- funkcja okna ustawioną na zakres $d = 0,4,$
 $g = 0,9$ znormalizowanej dynamiki (okno tak
dobrano, by uwidocznić szczegóły twarzy
poprzez poprawę kontrastu)

Efekt poprawy kontrastu

$p=0,6$




$p=0,3$


kawałkami liniowe
przekształcenie

$$f_p = a \cdot f^p$$


Lokalne wyrównanie histogramu





oryginał



globalne wyrównanie
histogramu





lokalne wyrównanie
histogramu










lokalne wyrównanie histogramu z
klasyfikacją (zmieniamy tylko
ciemne obszary nie ruszając
jaśniejszych)


Uwydatnianie (wyrównanie histogramu)



Efekty: poprawa percepcji



Przykład poprawy percepcji



Guz spikularny z mikrozwapnieniami

Wyostrzanie

- Filtry na bazie laplasjanów

$$h_{m,n} = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

$$h_{m,n} = \begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & -2 & -1 & 0 \\ -1 & -2 & 17 & -2 & -1 \\ 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$$


- Unsharp masking

$$f_{kraw}(i,j) = f - f_{mask}(i,j) = f - [f * h](i,j)$$

$$f_{ostry}(i,j) = f + \alpha \cdot f_{kraw}(i,j)$$

$$g(i,j) = f + \alpha \cdot [f * g](i,j) = f + \alpha \cdot f_g(i,j)$$

Mediana 9x9



Mediana 3x3






Selektywny modalny



Modalny plus Mediana

Uwydatnianie (operacje morfologiczne)



$D(S)$ - dyłacja obrazu Źródłowego przy elemencie strukturującym S (max),

$E(S)$ - erozja (min),

Otwarcie: $O(S) = D(E(S), S)$,

Zamknięcie: $C(S) = E(D(S), S)$,

White top-hat: $Obraz - O(S)$, gdzie $Obraz$ oznacza obraz Źródłowy,

Black top-hat: $C(S) - Obraz$,

oraz stosowane do wykrywania krawędzi:


Gradient morfologiczny: $D(S) - E(S)$,

Gradient wewnętrzny: $Obraz - E(S)$,

Gradient zewnętrzny: $D(S) - Obraz$.

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


Przykłady (operatory morfologiczne)



oryginał




dylacja



erozja




otwarcie




zamknięcie


Przykłady (operatory morfologiczne 2)




oryginał




white top-hat




black top-hat



gradient



gradient wewnętrzny






gradient zewnętrzny

Poprawa percepcji zmian – przetwarzanie w dziedzinie falkowej

■ Odszumianie

6 poziomów dekompozycji,
falka: Taswell Biortogonal
Symmetric Most-Regular (10)


- wycinanie podpasm
- współczynniki nie są zmieniane
- zastosowanie krzywej



■ Poprawa kontrastu

kontrast6

kontrast7



Wavelet decomposition

Set Source Document

Wavelet Filter: Antonini

Levels: 6

☐ undecimated transform

Subbands grid <<

Reconstruction

Src - Reconstruction

|Wav coeff|

Wav coeffs visualization

Histogram equalization

All

Subbands

Subband thresholding

function type

☐ hard☒ piecewise linear☐ sigmoidal

T1=mean+1 *stdDev

fi 1 0.2

fi 2 0.35

Sigmoidal

b 0.25

c 40


Threshold coefficients

Threshold around LMs

Curve

From file

Save



splines

3

 $|coeff|^{(p)}$

0.00

OK

Cancel

Subbands grid

- ☒ Level 1
- ☒ Level 2
- ☒ Level 3
- ☒ Level 4
- ☒ Level 5
- ☒ Level 6


Threshold

Mean:







Std Dev:

T=mean+ *stdDev



Falkowe mikrozwapnienia




Ekstrakcja informacji




Ekstrakcja informacji




Przetwarzanie (metody falkowe)




oryginał



przetworzony





detekcja kandydatów z oryginału




detekcja kandydatów z obrazu przetworzonego

Falki heksagonalne – konwersja siatki pikseli





selekcja pasm

falki heksagonalne – konwersja siatki pikseli




forma kwadratowa





forma heksagonalna



Dekompozycja 2W z liftingiem



Detekcja: środki kandydatów (filtracja w wielu skalach i progowanie)















mikrozwapnienia



Filtr LoG

Zastosowania: poprawa percepcji








Przetworzenie wstępne w celu poprawy efektywności detekcji





oryginał



po przetworzeniu






dokładniejsze zarysy





redukcja liczby wskazań fałszywych

Segmentacja progowa





Przykładowy algorytm detekcji mikrozwapnień. (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 jak w punkcie (b) z widocznymi bitami 1-8; (d) Aproksymacja histogramu i znaleziony optymalny próg; (e) Wynik progowania; (f) Wynik progowania na tle obrazu oryginalnego; (g) Na czerwona są zaznaczone kontury wewnętrzne wyodrębnione obiektów.

Progowanie - reguła





Obraz mammograficzny z łagodnymi mikrozwapnieniami i jego histogram poziomów szarości.




Obraz po filtracji WTH oraz jego histogram. Część pikseli o wyższej intensywności stanowi około 3 % całego obrazu. Czerwoną linią zaznaczony jest dobrany model statystyczny histogramu. 145 – próg dobrany za pomocą algorytmu progowania z modelowaniem histogramu rozkładem statystycznym.

$$t = \bar{f} + n\sigma_f ,$$

Progowanie – przykładowe wyniki



$n = 2.5$ w regule (1)



$n = 3.3$ w regule (1)



Wykryte obiekty – potencjalne mikrozwapnienia



Fałszywe wskazania






Mikrozwapnienia lub ich grupy, które nie zostały wykryte




Przy niższym progu algorytm wykrywa więcej mikrozwapnień, ale za to znacznie zwiększa się liczba fałszywych wskazań.

Przy wyższym progu bardzo małe, słabo widoczne mikrozwapnienia nie zostają wykryte.


Progowanie – rekonstrukcja kształtu



Wynik detekcji. Brak fałszywych wskazań.




Detekcja punktów




oryginał, uśrednienie i binaryzacja
przez progowanie



oryginał



WTH




lokalne maksima




Klasteryzacja - algorytm

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

Detekcja potencjalnych klastrów mikrozwapnień



Klasteryzacja - efekt



Klasyfikacja

- Statystyczne rozpoznawanie wzorców (Bayesa)


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

- Metryczne z wzorcami (met. najbliższego sąsiada)
 - Sieciowe rozpoznawanie wzorców (sieci neuronowe)
 - Syntaktyczne rozpoznawanie wzorców (reguły językowe)
 - Pasowanie modeli
 - Reguły semantyczne
-

Ekstrakcja cech (*MammoViewer*)

- Cechy pojedynczych mikrozwapnień
Powierzchnia, zwartość, momenty kształtu, wyrazistość krawędzi, średni poziom jasności, lokalny kontrast, momenty geometryczne
 - Statystyczne cechy tekstury
Macierz powinowactwa (zdarzeń); *'Gray-level run-length'*; *'Surrounding region-dependence'*; *'Gray-level difference'*
 - Wielorozdzielcze cechy tekstury
Cechy falkowe, filtry Gabora
 - Cechy klastrów mikrozwapnień
Grupowanie w klastry na podstawie rozłożenia przestrzennego, morfologii;
Powierzchnia, liczba mikrozwapnień, średni poziom jasności
-


Wybrane cechy kształtu



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

SRDM (Surrounding Region - Dependence Method)

- Analiza tekstury skupiska mikrozwapnień
- Stworzenie macierzy dla regionu oceny



$$M(q) = [\alpha(i, j)], \quad 0 \leq i \leq \overline{\overline{R_1}}, 0 \leq j \leq \overline{\overline{R_2}}$$

$$\alpha(i, j) = \# \left\{ (x, y) \mid C_{R_1}(x, y) = i \quad \text{oraz} \quad C_{R_2}(x, y) = j \right\}$$

$$C_{R_i}(x, y) = \# \left\{ (k, l) \mid (k, l) \in R_i \quad \text{oraz} \quad f(k, l) < f(x, y) - q \right\}$$

$M(q)$ – macierz SRDM w funkcji progu

Wybrane cechy tekstur

- pozioma suma ważona (*HWS horizontal-weighted sum*)

$$HWS = \frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n j^2 r(i, j)$$

gdzie N - suma wszystkich elementów w SRDM: $r(i, j) = \begin{cases} \frac{1}{\alpha(i, j)} & \text{dla } \alpha(i, j) > 0 \\ 0 & \text{wpp} \end{cases}$

- pionowa suma ważona (*VWS vertical-weighted sum*)

$$VWS = \frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n i^2 r(i, j)$$

- diagonalna suma ważona (*DWS*)

$$DWS = \frac{1}{N} \sum_{k=0}^{m+n} k^2 \left(\sum_{\substack{i, j: i+j=k, \\ i=0, \dots, m \\ j=0, \dots, n}} r(i, j) \right)$$



- suma ważona siatki (*GWS grid-weighted sum*)

$$GWS = \frac{1}{N} \sum_{i=0}^m \sum_{j=0}^n ijr(i, j)$$


Przykładowy zestaw cech

<i>N</i> <i>r</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	$(\text{średnia} - \text{tło}) / (\text{średnia} + \text{tło})$
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	



Cechy relacyjne (przykład)




Klasyfikator najbliższego sąsiada (także kNN)



$$\mathbf{f} \in C_i \Leftrightarrow D_i(\mathbf{f}) = D_{\min}(\mathbf{f}) = \min_{j=1, \dots, |C|} [D_j(\mathbf{f})]$$



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 selekcji (regiony) - przykład

Focus of Attention Rule FR1:

If
 REGION-X is in FOCUS AREA
 REGION-X is LARGEST
 REGION-X is NOT ANALYZED

Then
 ACTIVATE REGION-X

Focus of Attention Rule FR2:

If
 REGION-X is in ACTIVE
 MODEL is NOT ACTIVE

Then
 ACTIVATE KNOWLEDGE_MERGE rules

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

Rozmyte klasyfikatory neuronowe - przykład



Klasyfikator

Neural Network

FEATURES:

☐ area	☐ background gray level (bac)
☐ compactness (outer)	☐ mean
☐ compactness (inner)	☐ std dev
☐ elongation	☐ foreground background ratio
☐ shape moment 1 (F1)	☐ f b difference
☐ shape moment 2	☐ difference ratio
☐ shape moment 3 (F3)	
☐ shape moment 4	
☐ F3 - F1	
☐ FF	
☐ edge strength	
☐ invariant moment 1	
☐ invariant moment 2	
☐ invariant moment 3	
☐ invariant moment 4	
☐ invariant moment 5	
☐ invariant moment 6	
☐ invariant moment 7	

COOCCURENCE FEATURES:

☐ contrast
☐ entropy
☐ angular second moment
☐ inverse different moment
☐ correlation
☐ covariance
☐ sum average
☐ sum entropy
☐ sum variance
☐ difference average
☐ difference entropy
☐ difference variance

NETWORK PARAMETERS:

hidden nodes

output

☒ 1 T/F	☐ 2 B/M
☐ 2 T/F	☐ 3 B/M/F

threshold

activation = $1/(1+\exp(-kx))$ k

LEARNING PARAMETERS:

eta

momentum

number of epochs

learning accuracy

Reset NN



Create NN

Open NN




Patterns

OK Cancel

Sieć neuronowa - dialog





Diagnoza




Uzyskana efektywność


Czułość detekcji
mikrozwapnień
na poziomie
90%

klasyfikacja na
łagodne/złośliwe:
74%





Interfejs dla radiologa: obrazy oryginalne




Interfejs dla radiologa: obrazy przetworzone + automatyczne wskazania potencjalnych klastrow mikrozwapniei

Diagnostyka wczesnego udaru niedokrwiennego mózgu


- Przedmiot: wczesne badanie CT
 - Duże znaczenie medyczne
 - Cel: ekstrakcja cech niewidocznych udaru
 - Koncepcja: poprawa semantycznej percepcji zmian
 - Narzędzia: segmentacja, przekształcenia w dziedzinie falkowe, wizualizacja
 - Faza badawcza
-

Przedmiot badań: anatomiczne badanie CT

Badanie wczesne (po-objawowe):









Badanie późne (po 4 dniach) z widocznym udarem:




Wydobywanie informacji (nieliniowe przekształcenia rozkładu wartości)

Metody korekcji histogramu







Korekcja histogramu (nieskuteczna detekcja)



Okno histogramowe (poprawa percepcji)




Okno 40/30




Okno histogramowe

Monitor Udaru


1. Segmentacja obrazu:




2. Ekstrakcja obszarów hypodensyjnych i redukcja szumu:



3. Wizualizacja:



Monitor udaru: efekty



obecna, tylko ukryta

Wydobycie informacji
użytecznej


Monitor udaru: segmentacja

- **Wstępna:** progowanie tkanki miękkiej z przedziału -5 – 30 HU (cel: odrzucenie struktur kostnych)
 - **Zasadnicza:** wydzielenie struktur wewnątrzczaszkowych narażonych na udar (odrzucenie bruzd, struktur pozaczaszkowych, artefaktów itp.), np. met. rozrostu i klasyfikacji regionów, prowadzenia promieni, progowania na podstawie histogramu.
 - **Subtelna:** segmentacja poszczególnych struktur istotnych w diagnostyce udaru, ocena ich kształtu, symetrii półkul, dodatkowa selekcja obszarów poszukiwań
-


Monitor udaru: przetwarzanie w celu wydobywania ukrytej informacji o udarze

- Działania na ROI
 - Lokalizacja cech udaru (selektywność, wiarygodność)
 - Uwypuklenie cech, podbicie stosunku sygnał/szum
 - Nieliniowa korekta rozkładu współczynników (punktowa, kontekstowa, adaptacyjna)
 - Ważenie modyfikacji względem skal, podpasm, orientacji
 - Optymalizacja, uniwersalność modelu
-


Dobór falek




Projektowanie filtrów - falek





filtry




falka



*funkcja
skalująca*





Wzmocnienie informacji ukrytej:



selektywne wzmocnianie małych współczynników
wybranej skali, pasma i kierunku

Odszumianie i poprawa kontrastu lokalnego




$$y(x) = \begin{cases} x \cdot \left(\frac{m}{n}\right)^p & \text{if } |x| < n, \\ x \cdot \left(\frac{m}{|x|}\right)^p & \text{if } n \leq |x| < m, \\ x & \text{if } |x| \geq m, \end{cases}$$

*parametry zależne od skali,
pasma, kierunku*


Wyrównanie histogramu w dziedzinie wielorozdzielczej



okno 40/30








wyrównanie histogramu




wyrównanie histogramu
w dziedzinie falkowej

Próby wydobywania udaru



Rezultaty: detekcja w kolejnych warstwach




Odkrywanie tajemnic ...



Badanie wczesne




Segmentacja




Badanie późne




Curvelets
z waveshrink



Curvelets
z waveshrink
+TSpline2








TSpline2+Atrail
(wcześniejsza
wersja Monitora)










TSpline2
+ Curvelets
z waveshrink

Badanie wczesne



Badanie późne

Falkowe czary



Inne rozwiązanie: mapy różnic gęstości obu półkul

