

Andrzej Materka

Wstęp do komputerowej analizy obrazów (4)

Zadanie nr 13 – Studia podyplomowe „Przetwarzanie i analiza
obrazów biomedycznych”



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Prezentacja multimedialna
współfinansowana przez Unię Europejską
w ramach Europejskiego Funduszu Społecznego
w projekcie

*„Innowacyjna dydaktyka bez ograniczeń
– zintegrowany rozwój Politechniki Łódzkiej –
zarządzanie Uczelnią,
nowoczesna oferta edukacyjna
i wzmacniania zdolności do zatrudniania
osób niepełnosprawnych”*



Politechnika Łódzka
Instytut Elektroniki

90-924 Łódź, ul. Żeromskiego 116,
tel. 042 631 28 83
www.kapitalludzki.p.lodz.pl



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Cele i etapy analizy obrazów

- Pomiar parametrów sceny z wykorzystaniem segmentacji
- Pomiar parametrów sceny przez dopasowanie modelu
- Automatyczna interpretacja obrazu




Politechnika Łódzka
Instytut Elektroniki

A. Materka, Wstęp do komputerowej analizy obrazów (4)




Pomiar parametrów sceny z wykorzystaniem segmentacji







Przykład: analiza przekrojów włókien nerwowych



<http://pl.wikipedia.org/wiki/Kolimator>




Akwizycja obrazu

- preparat tkankowy,
- oświetlenie,
- mikroskop,
- cyfrowy aparat fotograficzny,
- identyfikacja zniekształceń geometrycznych,
- kalibracja.





Przykład: analiza przekrojów włókien nerwowych



Wstępne przetwarzanie

- korekcja zniekształceń geometrycznych,
- wyrównanie średniej jasności.



Progowanie





KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Przykład: analiza przekrojów włókien nerwowych



Postprocessing

- usuwanie obszarów stykających się z brzegiem obrazu,
- wypełnianie „dziur”,
- wygładzanie konturów,
- usuwanie obszarów zbyt małych.






Politechnika Łódzka
Instytut Elektroniki

A. Materka, Wstęp do komputerowej analizy obrazów (4)

Przykład: analiza przekrojów włókien nerwowych

Nu- mer	A [μm^2]	P [μm]	F_x [μm]	F_y [μm]
1	858	117	38	36
2	2063	179	61	
3	649	110	23	
4	1034	133	37	
5	405	81	24	
6	1353	144	45	
7	928	118	34	
8	938	139	37	
9	497	102	19	
10	951	119	38	
11	1298	148	38	51
12	1215	142	36	51
13	195	57	16	20
14	1489	227	66	58
15	974	127	41	37



Ekstrakcja cech

- identyfikacja obiektów w obrazie, etykietowanie,
- wyznaczanie linii brzegowej (konturu),
- obliczanie parametrów geometrycznych (cech),
- dopasowanie modeli.



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI


UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY




Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Przykład: pomiar szerokości wzorca

Obraz wzorca




Rzut aksonometryczny






Przykład: pomiar szerokości wzorca

Obraz binarny po progowaniu



Przykład: pomiar szerokości wzorca




Wzorzec (oświetlony
pas na ciemnym tle)

Profil jasności wzorca
(wzdłuż linii AB)

Profil jasności obrazu
analogowego (bez szumu)

Profil jasności obrazu
analogowego (z szumem)

Przykład: pomiar szerokości wzorca – błąd dyskretyzacji



- punkty oświetlonego wzorca
- punkty nieoświetlonego tła

x_L, x_R : rozkład równomierny, między P^-, P^+ oraz Q^-, Q^+

Dla każdego $|P^+Q^-| < w < |P^-Q^+|$ wynik jest taki sam!

Estymator
szerokości wzorca


$$\hat{w}_1 = |P^+Q^-| + \Delta x$$

Odchylenie standardowe
estymatora


$$\sigma_1 = \frac{\Delta x}{\sqrt{6}} \cong 0,4\Delta x$$

Estymator jest
nieobciążony,
ale nie jest zgodny.


Błędy związane z segmentacją



Próg lokalny



Próg globalny




- Progowanie (stała wartość progu – „próg globalny” – przy zmieniającej się jasności tła i obiektów prowadzi do zmian kształtu obiektów)
- Dyskretyzacja (szczegóły obrazu analogowego są nierozróżnialne wewnątrz pikseli)
- Binaryzacja (sprowadzenie jasności obrazu do jednej z dwóch wartości)

Segmentacja prowadzi do nieodwracalnych strat informacji zawartej w obrazie.




Pomiar parametrów sceny przez dopasowanie modelu




Przykład: pomiar szerokości wzorca

Obraz wzorca




Rzut aksonometryczny



Model - profil jasności
wzdłuż linii obrazu

$$v = \varphi(x; \delta) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{x/\delta} \exp\left(-\frac{\xi^2}{2}\right) d\xi$$


Sparymetryzowany profil jasności



Model profilu jasności brzegów wzorca

$$\hat{v}_L(i) = V_B + \Delta_V \varphi(i\Delta_x - x_L; \delta)$$

$$\hat{v}_R(i) = V_B + \Delta_V \varphi(x_R - i\Delta_x; \delta)$$





Dopasowanie modeli do profilu brzegów wzorca

Błędy
dopasowania

$$e_L(V_B, \Delta_V, x_L, \delta) = \sum_{i=m_L-K}^{m_L+K} [g(i, j) - \hat{v}_L(i)]^2$$

$$e_R(V_B, \Delta_V, x_R, \delta) = \sum_{i=m_R-K}^{m_R+K} [g(i, j) - \hat{v}_R(i)]^2$$

Dopasowanie: numeryczna minimalizacja błędów przez dobór parametrów dla lewego $(V_B, \Delta_V, x_L, \delta)$ i prawego $(V_B, \Delta_V, x_R, \delta)$ brzegu.


Estymator
szerokości wzorca

$$\hat{W}_2 = \hat{x}_R - \hat{x}_L$$





Przykład: dopasowanie modeli do profilu brzegów wzorca




Estymator
szerokości wzorca

$$\hat{W}_2 = \hat{X}_R - \hat{X}_L$$

„Subpixel accuracy”


Przykład: dopasowanie modeli do profilu brzegów wzorca



Odchylenie standardowe estymatora zależy od stosunku sygnału do szumu.

Błąd wartości średniej $< 0,1 \Delta x$

Dopasowanie modelu: aktywny kontur (snake)



© dr P. Szczypiński


$$E_s = \int_0^{s_m} [E_i(\mathbf{v}(s)) + E_e(\mathbf{v}(s)) + E_p(\mathbf{v}(s))] ds$$

- wewnętrzne naprężenia krzywej konturu
- składowa oddziaływania obrazu,
- składowa oddziaływań zewnętrznych,




A. Materka, Wstęp do komputerowej analizy obrazów (4)

Dopasowanie modelu: deformowalna siatka



© dr P. Szczypiński







KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Dopasowanie siatki oraz aktywnego konturu



© dr P. Szczypiński



Politechnika Łódzka
Instytut Elektroniki

A. Materka, Wstęp do komputerowej analizy obrazów (4)



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY




Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego


Model trójwymiarowy mięśnia sercowego do wizualizacji

Ewolucja serca

Przekroje MRI



Przepływ krwi



© dr P. Makowski



Politechnika Łódzka
Instytut Elektroniki

A. Materka, Wstęp do komputerowej analizy obrazów (4)




KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY




Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Model trójwymiarowy mięśnia sercowego do wizualizacji



Triangulacja przekrojów




Model siatkowy 3W

© dr P. Makowski



Holobench® 3D visualization workstation



Zrekonstruowane serce

A. Materka, Wstęp do komputerowej analizy obrazów (4)



Politechnika Łódzka
Instytut Elektroniki




KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Model trójwymiarowy mięśnia sercowego do wizualizacji



© dr P. Makowski




Politechnika Łódzka
Instytut Elektroniki

A. Materka, Wstęp do komputerowej analizy obrazów (4)




Automatyczna interpretacja obrazu





Przykład: automatyczna segmentacja tekstury obrazu

Mozaika



Obraz po segmentacji



<http://www-dbv.informatik.uni-bonn.de/image>





KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI


UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY




Prezentacja multimedialna współfinansowana przez Unię Europejską w ramach Europejskiego Funduszu Społecznego

Rozpoznawanie obrazów

„Trawa”, klasa ω_1



„Kora”, klasa ω_2




Politechnika Łódzka
Instytut Elektroniki

A. Materka, Wstęp do komputerowej analizy obrazów (4)



Rozpoznawanie obrazów



Cechy próbek

$$y_1 = S(2,0) \text{SumEntrp}$$


$$y_2 = S(1,1) \text{SumEntrp}$$

64 wektory cech: 32 klasy ω_1 + 32 klasy ω_2





Rozpoznawanie obrazów



64 punkty w przestrzeni cech: 32 klasy ω_1 + 32 klasy ω_2




Rozpoznawanie obrazów (ang. *pattern recognition*)

Obraz (wzorec, ang. *pattern*): $Y|\omega$ $\omega \in \Omega$, $\Omega = \{\omega_1, \omega_2, \dots, \omega_K\}$

Wektor cech
(obserwacji)

Indykator
klasy

Zbiór K klas






Rozpoznawanie obrazów

Funkcje dyskryminacyjne: $D_k(Y)$, $k=1,2,\dots,K$

Jeśli $Y \sim \omega_j$, to $D_j(Y) > D_k(Y)$, $k = 1, 2, \dots, K$ $k \neq j$


Granica między klasami ω_j oraz ω_k : $D_j(Y) - D_k(Y) = 0$ (hiperpowierzchnia)

Przykład: $D(Y) = D_1(Y) - D_2(Y) = 0$ (prosta)



Nadzorowane uczenie klasyfikatora



- zbiór uczący
- „przeuczenie”
- zbiór testowy



Przykład: *Klasyfikator „liniowy”*

$$D_k(Y) = w_{k0} + \sum_{i=1}^p w_{ki} y_i, \quad k = 1, 2, \dots, K$$

Sztuczna sieć neuronowa





Model neuronu wg McCullocha i Pittsa (1943)

$$x_k(t+1) = \varphi \left(\sum_j w_{kj} x_j(t) - \theta_k \right)$$

$$\varphi(\alpha) = \begin{cases} 1, & \alpha \geq 0 \\ -1, & \alpha < 0 \end{cases}$$


Sztuczna sieć neuronowa

- Program komputerowy lub układ elektroniczny będący bardzo uproszczonym modelem mózgu.
- Sieć neuronowa składa się z wielu sztucznych neuronów (procesorów) – połączonych ze sobą i ułożonych w warstwy.



Sztuczna sieć neuronowa


- uczy się na przykładach,
- posiada zdolność uogólniania



Uczenie sieci

*Dobieranie siły połączeń $\{v\}$, $\{w\}$ między warstwami, aby dla **zbioru treningowego** wektorów wejściowych $\langle x \rangle$ sieć generowała odpowiedzi $\langle y \rangle$ bliskie odpowiedziom żądanym.*

Co potrafi prosty sztuczny neuron?




$$y = \varphi(w_1 x_1 + w_2 x_2 - \theta)$$

$$\varphi(\alpha) = \begin{cases} 1, & \alpha \geq 0 \\ -1, & \alpha < 0 \end{cases}$$

$$y = \begin{cases} 1 & \longrightarrow \text{klasa A} \\ -1 & \longrightarrow \text{klasa B} \end{cases}$$

Przykład: klasyfikacja punktów na płaszczyźnie



Uczenie neuronu (nadzorowane)

Krok 1. Inicjalizacja połączeń $\{w, \theta\}$
(małe wartości losowe)


Krok 2. Prezentacja nowego wejścia
 $\langle x \rangle$ i żadanego wyjścia d

Krok 3. Obliczanie wyjścia
$$y = \varphi(w_1 x_1 + w_2 x_2 - \theta)$$

Krok 4. Adaptacja
połączeń

$$\begin{aligned}w_1 &= w_1 + \eta(d - y)x_1 \\w_2 &= w_2 + \eta(d - y)x_2 \\ \theta &= \theta + \eta(d - y)\end{aligned}$$


Krok 5. Sprawdzenie kryterium końca
obliczeń i ewentualny powrót
do kroku 2



p-demo

η - parametr
(mała liczba dodatnia)

Co potrafi sieć wielowarstwowa?



$$y = \xi \left(v_0 + \sum_{k=1}^N v_k h_k \right)$$

$$\begin{aligned} y \geq 0,5 & \longrightarrow \text{klasa A} \\ y < 0,5 & \longrightarrow \text{klasa B} \end{aligned}$$

$$h_k = \xi \left(w_{k0} + \sum_{i=1}^N w_{ki} x_i \right), \quad k = 1, 2, \dots, N$$

$$\xi(\alpha) = \frac{1}{1 + \exp(-\alpha)}$$

Uczenie sieci wielowarstwowej (nadzorowane)

Minimalizacja sumy kwadratów błędu w zbiorze M
przykładów treningowych $\{\mathbf{x}_m, d_m\}$

$$E = \sum_{m=1}^M [d_m - y_m(\mathbf{x}_m, \mathbf{v}, \mathbf{w})]^2$$




Najpopularniejsza metoda uczenia:
algorytm wstecznej propagacji błędu
(ang. *BP – error back propagation*)

BP-demo



Problemy uczenia sieci neuronowych

- Minima lokalne funkcji błędu
- Dobór wielkości sieci
- Dobór liczby przykładów

Zbyt mała liczba neuronów (2)




Zbyt duża liczba neuronów (40)



Sieć Kohonena (nienadzorowana)

- Kwantyzacja wektorowa (np. kompresja kolorów)
- Klasyfikacja



k-demo



Zastosowania sztucznych sieci neuronowych

- ***Klasyfikacja, diagnoza.*** Sieć podejmuje decyzję, do której z określonych kategorii należy zaliczyć przedstawiony jej wektor danych.
- ***Aproksymacja funkcji.*** Sieć przypisuje wektor danych wartości pewnej nieznanej funkcji opisującej "rzeczywisty" proces (prognoza szeregów czasowych, identyfikacja procesów).
- ***Kompresja danych, ekstrakcja cech, kwantyzacja.*** Zmniejszenie liczby wymiarów oraz redukcja zakłóceń, poprzez wydobywanie istotnych informacji z danych.





Dlaczego sztuczne sieci neuronowe są używane?

- Pozwalają rozwiązać wiele problemów, z którymi nie radzą sobie inne metody, ograniczone silnymi założeniami (np. o rozkładzie normalnym, liniowości i wzajemnej niezależności zmiennych).
- Pozwalają odwzorować złożone, wielowymiarowe zależności i opisać zjawiska, dla których nie ma innego prostego opisu.



Nie powinny być traktowane jako panaceum na wszystkie problemy analizy danych (nieprzewidywalność procesu uczenia, minima lokalne, zjawisko „przeuczenia”, ...)