

# Widzenie Komputerowe - Segmentacja

## Wykład 2. i 3.

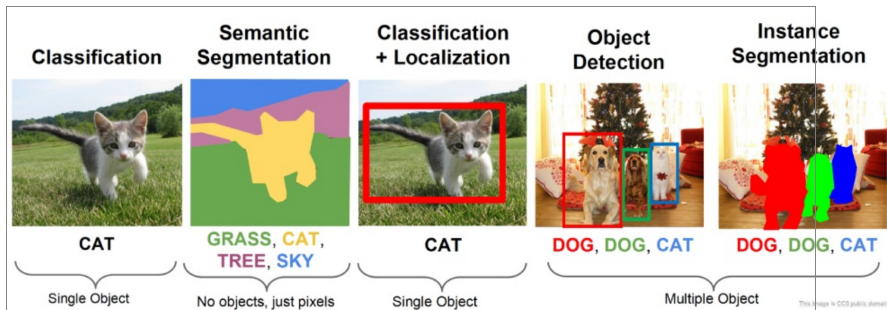
Magdalena Mazur-Milecka

Katedra Inżynierii Biomedycznej, WETI, PG

10 marca 2020

- **Klasyfikacja:** Jaki obiekt szerokiej kategorii znajduje się na obrazie?
- **Detekcja:** Gdzie znajdują się obiekty na obrazie?
- **Segmentacja:** Które piksele obrazu należą do obiektu?
- **Identyfikacja:** Jaki typ określonego obiektu jest na obrazie?
- **Weryfikacja:** Czy obiekt jest na obrazie?
- **Rozpoznanie:** Jakie obiekty są na obrazie i gdzie dokładnie się znajdują?





- **Klasyfikacja:** Jaki obiekt szerokiej kategorii znajduje się na obrazie?
- **Segmentacja:** Które piksele obrazu należą do obiektu?
- **Detekcja:** Gdzie znajdują się obiekty na obrazie?

# Semantic vs. Instance segmentation


Classification




Semantic Segmentation



Object Detection



Instance Segmentation



**Segmentacja** - proces podziału obrazu na części określane jako spójne obszary (regiony), które są jednorodne (homogeniczne) pod względem np. poziomu szarości, barwy czy tekstury. W praktyce - ustalenie do którego z obszarów należy każdy piksel.


Istnieją 2 grupy metod segmentacji:

- na podstawie podobieństwa wewnątrz obszarów
- na podstawie istnienia granic



Problemy segmentacji:



- kryterium jednolitości (koloru, tekstury, bez wyraźnych granic),




# Segmentacja

Problemy segmentacji:


- kryterium jednolitości (koloru, tekstury, bez wyraźnych granic),
- obiektywizm




Original Image



Subject 1



Subject 2



Subject 3

# Przykłady segmentacji

Przykłady segmentacji człowieka vs. maszyny

Oryginał



Człowiek



Maszyna




# Przykłady segmentacji

Przykłady segmentacji człowieka vs. maszyny

Oryginał

Człowiek


Maszyna



# Przykłady segmentacji

Przykłady segmentacji człowieka vs. maszyny

Oryginał



Człowiek



Maszyna



Segmentacja wykonywana przez człowieka jest zorientowana na obiekty, a segmentacja automatyczna na lokalne właściwości obrazu

<https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/bench/html/>



# Przykłady zastosowań segmentacji w medycynie

- Automatyczne rozpoznanie narządów,




# Przykłady zastosowań segmentacji w medycynie

- Automatyczne rozpoznanie narządów,
- Obraz naczyń krwionośnych,



# Przykłady zastosowań segmentacji w medycynie

- Automatyczne rozpoznanie narządów,
- Obraz naczyń krwionośnych,
- Detekcja zmian,




---

C. Yu, G.C.S. Ruppert, A.X. Falcao, D.T.D. Nguyen, and Y. Liu,  
"Statistical Asymmetry-based Fully Automatic Brain Tumor Segmentation  
From 3D MR Images." PSU CSE 09-015, CMU Robotics Institute TR-09-44,  
Nov 2009

# Przykłady zastosowań segmentacji w medycynie


- Automatyczne rozpoznanie narządów,
- Obraz naczyń krwionośnych,
- Detekcja zmian,
- Wyodrębnianie narzędzi chirurgicznych,



*Robotic Instrument Segmentation Sub-Challenge, Endoscopic Vision Challenge*

# Przykłady zastosowań segmentacji w medycynie

- Automatyczne rozpoznanie narządów,
- Obraz naczyń krwionośnych,
- Detekcja zmian,
- Wyodrębnianie narzędzi chirurgicznych,
- Parametryzacja laboratoryjna,




---

*C. Panagiotakis and A. Argyros, Cell Segmentation via Region-based Ellipse Fitting, IEEE International Conference on Image Processing, 2018.*

# Przykłady zastosowań segmentacji w medycynie

- Automatyczne rozpoznanie narządów,
- Obraz naczyń krwionośnych,
- Detekcja zmian,
- Wyodrębnianie narzędzi chirurgicznych,
- Parametryzacja laboratoryjna,
- Prognozowanie linii złamania




- Metody klasyczne
  - 1 binaryzacja (progowanie)
  - 2 wykrywanie krawędzi (np. aktywne kontury, snake)
  - 3 rozrost/podział obszaru (wododziały)
  - 4 głębokie sieci neuronowe (U-Net, autoencodery)
  - 5 inne (dopasowanie wzorca, graph-cut, mean-shift)
- Uczenie maszynowe
  - 1 enkoder-dekoder (U-Net)
  - 2 inne

- 1 **Progowanie:**
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 Etykietowanie - CC
- 3 Atywne kontury - Snake
- 4 Segmentacja oparta na regionach:
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 Graph-cuts
- 6 U-Net
- 7 Instance segmentation: Mask R-CNN

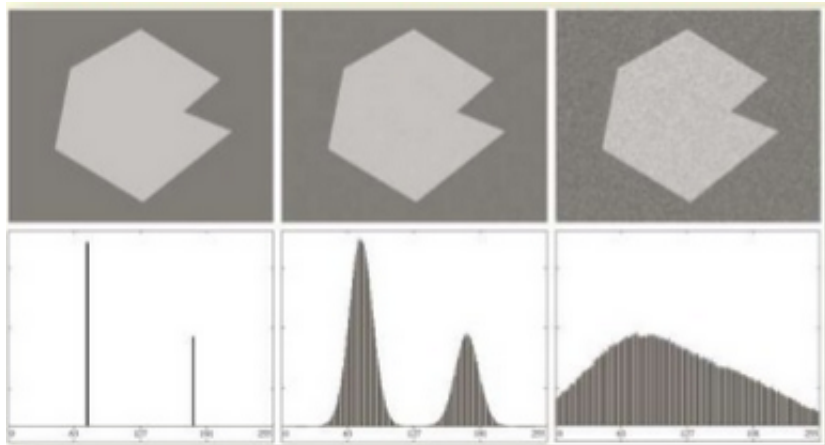


Binaryzacja obrazu na podstawie histogramu


$$g(x, y) = \begin{cases} 1 & \text{gdy } f(x, y) > T \\ 0 & \text{gdy } f(x, y) \leq T \end{cases}$$



Brak bimodalności histogramu



## Cieniowanie



Popularne metody progowania:

- progowanie nadzorowane globalne,
- lokalne i adaptacyjne progowanie,
- metoda Otsu.

---

*<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>*

Zalety:

- szybkie
- proste

---

*<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>*

Wady:

Zalety:

- szybkie
- proste

---

*<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>*

## Wady:

- trudny dobór progu

## Zalety:

- szybkie
- proste

---

*<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>*





Wady:

- trudny dobór progu

Zalety:

- szybkie
- proste



---

<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>

## Zalety:

- szybkie
- proste

## Wady:

- trudny dobór progu
- ignorowanie zmian koloru w całych podobszarach obrazu

---

*<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>*


## Zalety:

- szybkie
- proste


## Wady:

- trudny dobór progu
- ignorowanie zmian koloru w całych podobszarach obrazu

## Original



## Global thresholding

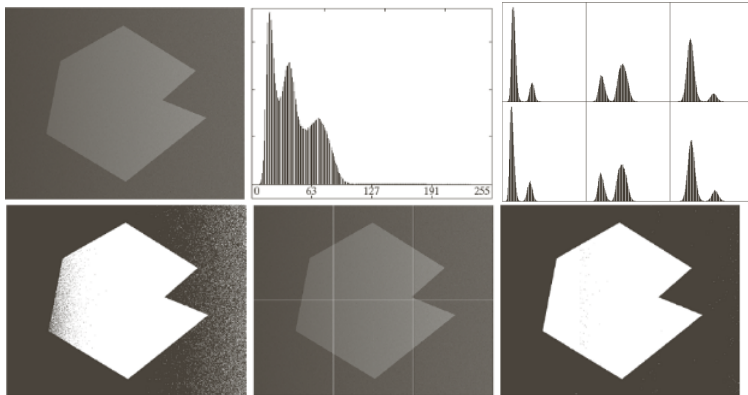


---

<http://scikit-image.org/docs/0.13.x/autoexamples/xxapplications/plotthresholding.html>


- Podział obrazu na mniejsze nienachodzące na siebie obszary,
- obliczanie histogramu dla każdej części osobno,
- dowolny dobór wielkości podobszaru,
- metoda używana w przypadku braku jednolitości oświetlenia (lub odbić)

# Progowanie lokalne




# Progowanie adaptacyjne

- Próg dla danego piksela wyznaczany w jego lokalnym otoczeniu,
- dobór otoczenia  $n \times n$  dowolny,
- metoda używana w przypadku braku jednolitości oświetlenia (lub odbić)




(a)



(b)




(c)



(d)

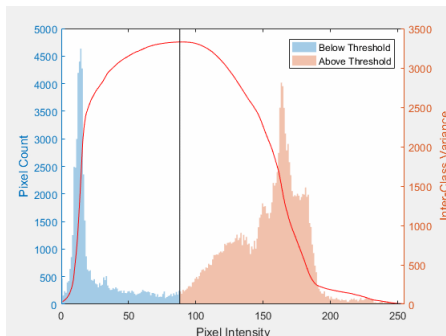
# Metoda Otsu

- Metoda optymalizacyjna - optymalizacja zadanego kryterium,



# Metoda Otsu


- Metoda optymalizacyjna - optymalizacja zadanego kryterium,
- kryterium - wariancja wewnątrzklasowa - minimalizacja,
- łatwiejsza w obliczeniu jest wariancja międzyklasowa - maksymalizacja,






# Metoda Otsu

- Metoda optymalizacyjna - optymalizacja zadanego kryterium,
- kryterium - wariancja wewnątrzklasowa - minimalizacja,
- łatwiejsza w obliczeniu jest wariancja międzyklasowa - maksymalizacja,
- prog  $t$  dokonuje podziału obrazu na klasę tła i obiektu,
- dla  $t$  z zakresu  $[0,255]$  obliczana wariancja histogramów obu powstałych klas



<https://en.wikipedia.org>



Wartości znormalizowanych histogramów są równe:

$$p_{tla} = \sum_{k=0}^t p_k$$

wartości średnie:

$$\mu_{tla} = \sum_{k=0}^t \frac{k p_k}{p_{tla}}$$

wariancje:

$$\sigma_{tla}^2 = \sum_{k=0}^t (k - \mu_{tla})^2 \frac{p_k}{p_{tla}}$$

$$p_{ob} = \sum_{k=t+1}^{255} p_k$$

$$\mu_{ob} = \sum_{k=t+1}^{255} \frac{k p_k}{p_{ob}}$$


$$\sigma_{ob}^2 = \sum_{k=t+1}^{255} (k - \mu_{ob})^2 \frac{p_k}{p_{ob}}$$

- Każdy obraz posiada wariancję globalną  $\sigma_G^2$ , która jest stała dla obrazu i niezależna od wyboru progu  $t$ ,
- Wariancja globalna to suma wariancji wewnątrzklasowej i międzyklasowej

$$\sigma_G^2 = \sigma_{wew}^2 + \sigma_{inter}^2$$


- Wybór progu  $t$  wpływa na wartości wariancji  $\sigma_{wew}^2$  oraz  $\sigma_{inter}^2$ ,
- Mniejszego nakładu obliczeniowego wymaga obliczenie wariancji międzyklasowej niż wewnątrzklasowej.

# Metoda Otsu




- 1 Progowanie:
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 **Etykietowanie - CC**
- 3 Atywne kontury - Snake
- 4 Segmentacja oparta na regionach:
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 Graph-cuts
- 6 U-Net
- 7 Instance segmentation: Mask R-CNN

Indeksacja obrazu - proces nieodłączny segmentacji




Indeksacja obrazu - proces nieodłączny segmentacji





## Cechy:


- Podstawowy algorytm analizy kształtu, powierzchni i granic obiektu
- Działa na obrazach binarnych
- Dwa przejścia na obrazie: pierwszy-etykietowanie wstępne oraz rejestracja macierzy korekty, drugi-korekta etykiet
- Skanowanie od lewej do prawej, od góry do dołu
















Macierz korekcji etykiet:  
 $2=1$



Macierz korekcji etykiet:

$$2=1$$


$$4=3$$



Macierz korekcji etykiet:

$$2=1$$

$$4=3$$



Macierz korekcji etykiet:

$$2=1$$

$$4=3$$

$$5=1$$




	1			2					
	1			2		3	3		
	1	1	1	1	4	3	3	3	
		1	1			3		3	
	5	1				3	3	3	
	5								

Macierz korekcji etykiet:

$$2=1$$


$$4=3$$

$$5=1$$





- 1 Progowanie:
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 Etykietowanie - CC
- 3 **Atywne kontury - Snake**
- 4 Segmentacja oparta na regionach:
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 Graph-cuts
- 6 U-Net
- 7 Instance segmentation - Mask R-CNN

# Segmentacja - wykrywanie krawędzi



# Aktywny kontur

**Aktywny kontur** - to model pewnej deformowalnej krzywej, która wykorzystywana jest do obrysu kształtów. Wymaga zainicjowania konturu niedaleko obiektu, który później zostaje przesuwany w stronę obiektu.

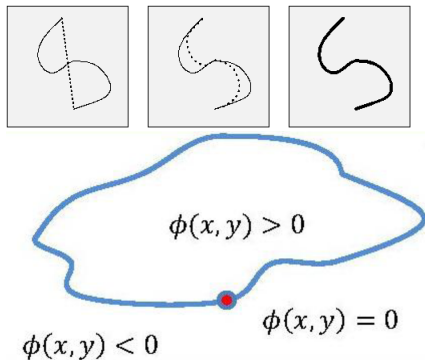


*Dambreville S., Yezzi A., Lankton S., Tannenbaum A. TAC: Thresholding Active Contours. Proceedings of the 15th IEEE International Conference on Image Processing 2008 Oct*

*M. Debakla, K. Djemal and M. Benyettou, 2011. Influence of Noise*

Podział aktywnych konturów:

- Parametryczny - krzywa przedstawiona w postaci zbioru punktów (węzłów) konturu - snake, balon  $v(s) = (x(s), y(s))$
- Geometryczny - krzywa przedstawiona nie bezpośrednio, w postaci funkcji  $\phi$ , która w miejscu konturu przyjmuje wartość  $\phi = 0$  - level set





Główny cel algorytmu -  
minimalizacja energii.

# Algorytm aktywnych konturów - Snake

Kontur to krzywa, która reprezentuje obrys obiektu (jego granice). Aktywny kontur oznacza, że krzywa jest deformowalna. Kontur jest reprezentowany jawnie najczęściej w postaci punktów składowych.

$$v(s) = (x(s), y(s))$$

$$v(s) = [x(s) \quad y(s)]^T, s \in [0, 1]$$



Do każdego punktu przyłożone są siły:

- Wewnętrzne
- Zewnętrzne
- Ograniczeń

Każda z sił wnosi energię, którą algorytm próbuje minimalizować w kolejnych iteracjach.

$$E_{snake} = \int_0^1 E_{snake}(v(s))ds = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{image}(v(s))ds + \int_0^1 E_{con}(v(s))ds$$

Snake to algorytm działający tylko w swoim lokalnym sąsiedztwie.



$$E_{snake} = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{image}(v(s))ds + \int_0^1 E_{con}(v(s))ds$$

Energia wewnętrzna krzywej  $v(s)$  jest równa ważonej sumie pochodnych cząstkowych krzywej względem  $s$ :


$$E_{int} = \frac{1}{2}(\alpha(s)|\frac{\delta v}{\delta s}|^2 + \beta(s)|\frac{\delta^2 v}{\delta s^2}|^2)$$

$\alpha$  - współczynnik elastyczności (tension)

$\beta$  - współczynnik sztywności (rigidity)

# Snake - Energia wewnętrzna

Naturalne obiekty wymagają gładkich konturów



Wyzerowanie lokalne  $\alpha$  powoduje zezwolenie na nieciągłości, ujemny znak to promowanie nieciągłości. Wyzerowanie lokalne  $\beta$  powoduje zezwolenie na formowanie rogów, ujemny znak to promowanie rogów.

# Energia wewnętrzna - Constant flow

$$C_t = \vec{n}$$




Zachowanie fali

# Energia wewnętrzna - Constant flow

$$C_t = \vec{n}$$




Zachowanie fali




# Energia wewnętrzna - Constant flow

$$C_t = \vec{n}$$



Zachowanie fali

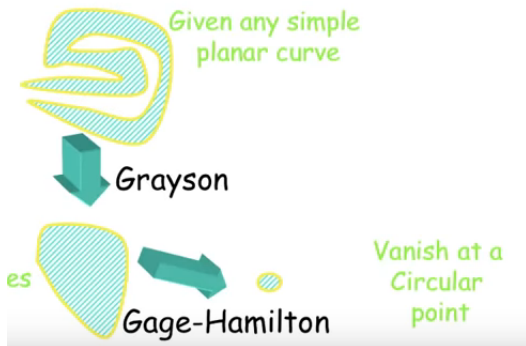


Change in topology



# Energia wewnętrzna - Curvature flow

Przestrzeń jednospójna - dowolną pętlę wewnątrz obiektu można ściągnąć do punktu



$$\frac{\delta v}{\delta t} = \frac{\delta^2 v}{\delta s^2}$$

$$E_{snake} = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{image}(v(s))ds + \int_0^1 E_{con}(v(s))ds$$

Energia zewnętrzna pochodzi od obrazu

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term}$$

Energia zewnętrzna przesuwa kontur do obszarów, które mają pewne interesujące właściwości:

# Snake - Energia zewnętrzna

Energia zewnętrzna pochodzi od obrazu

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term}$$

Energia zewnętrzna przesuwa kontur do obszarów, które mają pewne interesujące właściwości:

- linie:

$$E_{line}(s) = I(x(s), y(s))$$

waga  $w_{line}$  określa czy snake ma dążyć do jasnych czy ciemnych linii



Energia zewnętrzna pochodzi od obrazu

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term}$$

Energia zewnętrzna przesuwa kontur do obszarów, które mają pewne interesujące właściwości:

- linie:

$$E_{line}(s) = I(x(s), y(s))$$

waga  $w_{line}$  określa czy snake ma dążyć do jasnych czy ciemnych linii

- krawędzie:

$$E_{edge}(s) = -|\nabla I(x(s), y(s))|^2 \text{ lub}$$

$$E_{edge}(s) = -|\nabla G(\sigma) \otimes I(x(s), y(s))|^2$$

Energia zewnętrzna pochodzi od obrazu

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term}$$

Energia zewnętrzna przesuwa kontur do obszarów, które mają pewne interesujące właściwości:

- linie:

$$E_{line}(s) = I(x(s), y(s))$$

waga  $w_{line}$  określa czy snake ma dążyć do jasnych czy ciemnych linii

- krawędzie:

$$E_{edge}(s) = -|\nabla I(x(s), y(s))|^2 \text{ lub}$$

$$E_{edge}(s) = -|\nabla G(\sigma) \otimes I(x(s), y(s))|^2$$

- zakończenia (zerwania, narożniki):

# Snake - Energia zewnętrzna

Energia zewnętrzna pochodzi od obrazu

$$E_{image} = w_{line}E_{line} + w_{edge}E_{edge} + w_{term}E_{term}$$

Energia zewnętrzna przesuwa kontur do obszarów, które mają pewne interesujące właściwości:

- linie:

$$E_{line}(s) = I(x(s), y(s))$$



waga  $w_{line}$  określa czy snake ma dążyć do jasnych czy ciemnych linii

- krawędzie:


$$E_{edge}(s) = -|\nabla I(x(s), y(s))|^2 \text{ lub}$$

$$E_{edge}(s) = -|\nabla G(\sigma) \otimes I(x(s), y(s))|^2$$


- zakończenia (zerwania, narożniki):



When locating an object in an image...



High energy



Low energy

External Energy is derived  
from the image data

Look for high intensity gradient  
(watch out for noise - gradient of smoothed image)

high  $\nabla[G_\sigma * I(x, y)]$   Low external energy

$G_\sigma * I$  image convolved with a  
smoothing (ex. Gaussian) filter.

$I(x, y)$  image intensity

$\sigma$  parameter controlling the extent of the  
smoothing (ex. variance of Gaussian).

[http://demo.ipol.im/demo/g\\_chan\\_vese\\_segmentation](http://demo.ipol.im/demo/g_chan_vese_segmentation)

$$E_{snake} = \int_0^1 E_{int}(v(s))ds + \int_0^1 E_{image}(v(s))ds + \int_0^1 E_{con}(v(s))ds$$

Ograniczenia mogą być nałożone przez użytkownika lub proces wyższego rzędu oraz skierować snake'a w stronę (lub oddalić go) określonych cech.

## Energia sprężyny:

$$E_{spring}^i(s = s_i) = -k^i |x_1^i, x_2^i|$$

## Energia wulkanu:

odpycha kontur od pewnych obszarów otoczenia

$$E_{volcano}^i(s) = \min(\text{peak}_i, \frac{1}{|v(s), volcano^i|})$$





# Problemy tradycyjnego Snake'a (model Kass'a)

- wrażliwy na parametry
- bliski zakres działania, gradient z dala od krawędzi na jednolitych obszarach jest zerowy
- kształty wklęsłe



- gradient jest lokalny
- duża zależność od konturu początkowego

Wprowadzony przez L. Cohen. Bardzo dobrze działa w przypadku inicjowania kontury wewnątrz obiektu.

Dodaje nową siłę:


$$F_{balona}(s) = kn(v(s))$$

$k$  - współczynnik wagi,  $n(v(s))$  - wektor normalny do konturu


Rozszerzenie zasięgu gradientu - Gradient Vector Flow (GVF):  
detekcja wklęsłości,  
daleki zakres działania



(a) Original image



(b) Traditional external force




(c) GVF external force

---

*Q. Zhang, R. Skjetne, I. Metrikin, S. Løset, Image processing for ice floe analyses in broken-ice model testing, Cold Regions Science and Technology, 2015, 111, 27*

Podział aktywnych konturów:





- Parametryczny - krzywa przedstawiona w postaci zbioru punktów (węzłów) konturu - snake, balon  $v(s) = (x(s), y(s))$
- Geometryczny - krzywa przedstawiona nie bezpośrednio, w postaci funkcji  $\phi$ , która w miejscu konturu przyjmuje wartość  $\phi = 0$  - level set



Główny cel algorytmu -  
minimalizacja energii.

Komputerowa implementacja łatwiejsza w przypadku przedstawienia konturu w postaci funkcji  $\phi$ .

Pochodne równe 0



- 1 Progowanie:
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 Etykietowanie - CC
- 3 Atywne kontury - Snake
- 4 **Segmentacja oparta na regionach:**
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 Graph-cuts
- 6 U-Net
- 7 Instance segmentation - Mask R-CNN

# Segmentacja oparta na regionach (Region-based Segmentation)

Główne algorytmy oparte na:

- rozroście regionów,
- podziale regionów,

Główne cechy:

- regiony mają zamknięte granice,
- **kryterium jednolitości  $H(R)$**  oparte na podobieństwie.

# Segmentacja oparta na regionach (Region-based Segmentation)

Główne algorytmy oparte na:

- rozroście regionów,
- podziale regionów,

Główne cechy:

- regiony mają zamknięte granice,
- **kryterium jednolitości  $H(R)$**  oparte na podobieństwie.

Podziałem  $P$  obszaru  $U$  nazywamy zbiór regionów:

$$P = R_i \subset U \mid \left( \bigcup_{i \in I} R_i = U \right) \wedge (R_i \cap R_j \neq \emptyset \implies i = j)$$



Przykłady kryterium dołączania nowych pikseli:

- wartość amplitudy gradientu intensywności pikseli,
- różnica intensywności piksela włączanego a startowego w określonym przedziale,

$$H_T(R) = \begin{cases} 1 & \iff (\forall_{u,v \in R})(|f(u) - f(v)| < T) \\ 0 & \iff (\exists_{u,v \in R})(|f(u) - f(v)| \geq T) \end{cases}$$

- intensywność włączanego piksela w porównaniu ze średnią intensywnością regionu (przeliczana dynamicznie)
- porównanie histogramów

$$H_b(R) = \begin{cases} 1 & \iff \text{histogram } R \text{ nie jest bimodalny} \\ 0 & \iff \text{histogram } R \text{ jest bimodalny} \end{cases}$$

Metoda: startując z "elementarnych" obszarów  $R_i$ , łączy w coraz większe (dodając piksele) na podstawie spełnienia kryterium jednolitości  $H$ .

Dla każdego obszaru  $R_i$ :

- Dla każdego punktu obrazu  $p$  niedołączonego do innego obszaru sprawdzanie czy:

$p$  sąsiaduje z  $R_i$  oraz  $H(R_i \cup \{p\}) = 1$ ,


jeżeli spełnione, to  $p$  dołączany do  $R_i$ :  $R'_i = R_i \cup \{p\}$

Podział  $P$  jest zgodny z  $H$ , gdy wszystkie regiony są jednorodne i nie można połączyć żadnych regionów bez naruszenia jednorodności:

$$H(R_i \cup R_j) = \begin{cases} 1 & \iff i = j \\ 0 & \iff i \neq j \end{cases}$$

Właściwości algorytmu:

- Można zdefiniować punkty startowe  $R_i$ , tzw. seed points (ziarna) od których zaczyna się rozrost, może być ich wiele,
- Dany punkt przyłączony jest do ziarna, jeżeli spełnia test jednolitości oraz istnieje ścieżka punktów od ziarna do tego punktu spełniających test jednolitości,
- Rozrost regionu powinien zostać zatrzymany, jeżeli już żaden z pikseli nie spełnia kryterium jednolitości,
- Wynik segmentacji często zależy od punktów startowych.



DIAS, P. A.; MEDEIROS, H. "Semantic Segmentation Refinement by Monte Carlo Region Growing of High Confidence Detections," *Asian Conference on Computer Vision (ACCV), 2018.*

# Rozrost regionów - Region Growing

	1	2	3	4	5
1	100	101	101	100	101
2	100	127	126	128	100
3	100	124	128	127	100
4	100	124	125	126	101
5	101	100	100	101	102

(a)

	1	2	3	4	5
1	100	101	101	100	101
2	100	seed	126	128	100
3	100	124	128	127	100
4	100	124	125	126	101
5	101	100	100	101	102

(b)

	1	2	3	4	5
1	100	101	101	100	101
2	100	127	126	128	100
3	100	124	seed	127	100
4	100	124	125	126	101
5	101	100	100	101	102

(c)

Test jednolitości:

$$|f(p) - f(s)| \leq T,$$

$$T = 3$$

Metoda:

**Podział (Splitting)** - rekurencyjny podział obrazu na coraz to mniejsze obszary i poszukiwanie obszarów jednolitych


- Obraz traktowany jako całość,
- Kryteria podziału, np. multimodalny histogram,
- Najmniejsze obszary powstają na granicach,
- Każdemu obszarowi nadawana jest etykieta.

**Łączenie (Merging)** - łączenie podobnych obszarów sąsiadujących

- Obszary są jednolite,
- Kryteria łączenia:
  - średnia intensywność obszaru po złączeniu zmieniona w określonym zakresie,
  - wciąż histogram unimodalny,
  - krawędź między obszarami o niskim gradiencie intensywności.


# Podział regionów - Splitting

$R_1$	$R_2$	
$R_3$	$R_{41}$	$R_{42}$
	$R_{43}$	$R_{44}$




Warunkiem końcowym podziału może być także głębokość (liczba poziomów) drzewa

# Podział regionów - Splitting




# Podział regionów - Splitting






# Podział regionów - Splitting



# Podział regionów - Splitting



Mając zbiór regionów  $Q = \{R_i | i \in I\}$ ,  
gdzie dla każdego  $i \in I$ :

$$H(R_i) = 1,$$


sprawdzamy czy istnieją takie  $i, j \in I$ , dla których zachodzi:

$$H(R_i \cup R_j) = 1,$$

wtedy regiony  $R_i$  oraz  $R_j$  powinny być połączone.

# Metoda działów wodnych (Watershed)


- Obraz wejściowy traktowany jest jak 3D powierzchnia topograficzna. Obszary o małej intensywności stanowią lokalne doliny, a te o dużej intensywności - lokalne wzniesienia.
- Algorytm polega na "zalewaniu" wodą tak zinterpretowanego obrazu.



Praktyczne algorytmy realizacji:


## Opad deszczu - Rainfall

- Odległości od minimów lokalnych



## Rozlewanie - Flood fill

- startuje z lokalnych minimów
- rejestruje gdzie spotykają się rozlewiska



# Metoda działów wodnych (Watershed)


- Pixel przyporządkowany jest do obszaru, do którego spłynie kropla upuszczona w miejscu tego piksela.
- Granica oddziaływania grawitacyjnego na krople (inaczej: punkty w których spotykają się rozlewiska) wyznacza linię działu wodnego, czyli, granice między obszarami (tamy między rozlewiskami).
- Segmentacja jest zakończona, gdy wszystkie punkty są pod wodą.
- Wszystkie punkty na obrazie można podzielić na:
  - punkty lokalnych minimów,
  - punkty leżące na zboczach,
  - punkty leżące na granicach.
- W praktyce częściej używane są gradienty intensywności obrazów niż same obrazy.

# Flood fill Film

---

*<http://cmm.ensmp.fr/beucher/wtshed.html>*

- Często problemem algorytmu jest nadmierna segmentacja (oversegmentation) z powodu dużej liczby minimów lokalnych,
- Rozwiązaniem w tym przypadku jest wprowadzenie markerów, które definiują punkty startowe (zamiast lokalnych minimów), analogicznie do ziaren w algorytmie rozrostu regionów,
- Markery mogą być definiowane ręcznie lub automatycznie.



---

*Al-shaikhli, Saif, Bahrani, Ahmed. (2010). Segmentation of Tumor Tissue in Gray Medical Images Using Watershed Transformation Method.. Int. J. Adv. Comp. Techn.. 2. 123-127.*






# Marker Watershed Film

---


*<http://cmm.ensmp.fr/beucher/wtshed.html>*



# Działy wodne z markerami





Ograniczenia liczby regionów można również dokonać poprzez progowanie obrazu gradientowego:




- 1 Progowanie:
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 Etykietowanie - CC
- 3 Atywne kontury - Snake
- 4 Segmentacja oparta na regionach:
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 **Graph-cuts**
- 6 U-Net
- 7 Instance segmentation - Mask R-CNN

- Algorytm opracowany w 2001 r.
- Stosuje algorytmy z teorii grafów do celów segmentacji obrazu,
- Traktuje każdy piksel obrazu jako węzeł grafu.


Image




- Wprowadza węzły oznaczające obszary (source, sink),



- Łączy każdy piksel z węzłami obszarów ważonymi krawędziami (prawdopodobieństwo przynależności),




- Wprowadza też połączenia między pikselami



- Wyszukuje rozcięcia (cuts) rozdzielające obiekty (source i sink), którego miarą jest zbiór krawędzi,


- Wśród przecięć wyszukuje minimalne przecięcie (minimum cut) - takie, którego rozmiar, waga lub energia jest najmniejsze ze wszystkich możliwych






- 1 Progowanie:
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 Etykietowanie - CC
- 3 Atywne kontury - Snake
- 4 Segmentacja oparta na regionach:
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 Graph-cuts
- 6 **U-Net**
- 7 Instance segmentation - Mask R-CNN

## Network Architecture





*U-Net: Convolutional Networks for Biomedical Image Segmentation* O. Ronneberger, P. Fischer, T. Brox, *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351: [\[1\]](#) [\[2\]](#) [\[3\]](#) [\[4\]](#) [\[5\]](#) [\[6\]](#) [\[7\]](#) [\[8\]](#) [\[9\]](#) [\[10\]](#) [\[11\]](#) [\[12\]](#) [\[13\]](#) [\[14\]](#) [\[15\]](#) [\[16\]](#) [\[17\]](#) [\[18\]](#) [\[19\]](#) [\[20\]](#) [\[21\]](#) [\[22\]](#) [\[23\]](#) [\[24\]](#) [\[25\]](#) [\[26\]](#) [\[27\]](#) [\[28\]](#) [\[29\]](#) [\[30\]](#) [\[31\]](#) [\[32\]](#) [\[33\]](#) [\[34\]](#) [\[35\]](#) [\[36\]](#) [\[37\]](#) [\[38\]](#) [\[39\]](#) [\[40\]](#) [\[41\]](#) [\[42\]](#) [\[43\]](#) [\[44\]](#) [\[45\]](#) [\[46\]](#) [\[47\]](#) [\[48\]](#) [\[49\]](#) [\[50\]](#) [\[51\]](#) [\[52\]](#) [\[53\]](#) [\[54\]](#) [\[55\]](#) [\[56\]](#) [\[57\]](#) [\[58\]](#) [\[59\]](#) [\[60\]](#) [\[61\]](#) [\[62\]](#) [\[63\]](#) [\[64\]](#) [\[65\]](#) [\[66\]](#) [\[67\]](#) [\[68\]](#) [\[69\]](#) [\[70\]](#) [\[71\]](#) [\[72\]](#) [\[73\]](#) [\[74\]](#) [\[75\]](#) [\[76\]](#) [\[77\]](#) [\[78\]](#) [\[79\]](#) [\[80\]](#) [\[81\]](#) [\[82\]](#) [\[83\]](#) [\[84\]](#) [\[85\]](#) [\[86\]](#) [\[87\]](#) [\[88\]](#) [\[89\]](#) [\[90\]](#) [\[91\]](#) [\[92\]](#) [\[93\]](#) [\[94\]](#) [\[95\]](#) [\[96\]](#) [\[97\]](#) [\[98\]](#) [\[99\]](#) [\[100\]](#) [\[101\]](#) [\[102\]](#) [\[103\]](#) [\[104\]](#) [\[105\]](#) [\[106\]](#) [\[107\]](#) [\[108\]](#) [\[109\]](#) [\[110\]](#) [\[111\]](#) [\[112\]](#) [\[113\]](#) [\[114\]](#) [\[115\]](#) [\[116\]](#) [\[117\]](#) [\[118\]](#) [\[119\]](#) [\[120\]](#) [\[121\]](#) [\[122\]](#) [\[123\]](#) [\[124\]](#) [\[125\]](#) [\[126\]](#) [\[127\]](#) [\[128\]](#) [\[129\]](#) [\[130\]](#) [\[131\]](#) [\[132\]](#) [\[133\]](#) [\[134\]](#) [\[135\]](#) [\[136\]](#) [\[137\]](#) [\[138\]](#) [\[139\]](#) [\[140\]](#) [\[141\]](#) [\[142\]](#) [\[143\]](#) [\[144\]](#) [\[145\]](#) [\[146\]](#) [\[147\]](#) [\[148\]](#) [\[149\]](#) [\[150\]](#) [\[151\]](#) [\[152\]](#) [\[153\]](#) [\[154\]](#) [\[155\]](#) [\[156\]](#) [\[157\]](#) [\[158\]](#) [\[159\]](#) [\[160\]](#) [\[161\]](#) [\[162\]](#) [\[163\]](#) [\[164\]](#) [\[165\]](#) [\[166\]](#) [\[167\]](#) [\[168\]](#) [\[169\]](#) [\[170\]](#) [\[171\]](#) [\[172\]](#) [\[173\]](#) [\[174\]](#) [\[175\]](#) [\[176\]](#) [\[177\]](#) [\[178\]](#) [\[179\]](#) [\[180\]](#) [\[181\]](#) [\[182\]](#) [\[183\]](#) [\[184\]](#) [\[185\]](#) [\[186\]](#) [\[187\]](#) [\[188\]](#) [\[189\]](#) [\[190\]](#) [\[191\]](#) [\[192\]](#) [\[193\]](#) [\[194\]](#) [\[195\]](#) [\[196\]](#) [\[197\]](#) [\[198\]](#) [\[199\]](#) [\[200\]](#) [\[201\]](#) [\[202\]](#) [\[203\]](#) [\[204\]](#) [\[205\]](#) [\[206\]](#) [\[207\]](#) [\[208\]](#) [\[209\]](#) [\[210\]](#) [\[211\]](#) [\[212\]](#) [\[213\]](#) [\[214\]](#) [\[215\]](#) [\[216\]](#) [\[217\]](#) [\[218\]](#) [\[219\]](#) [\[220\]](#) [\[221\]](#) [\[222\]](#) [\[223\]](#) [\[224\]](#) [\[225\]](#) [\[226\]](#) [\[227\]](#) [\[228\]](#) [\[229\]](#) [\[230\]](#) [\[231\]](#) [\[232\]](#) [\[233\]](#) [\[234\]](#) [\[235\]](#) [\[236\]](#) [\[237\]](#) [\[238\]](#) [\[239\]](#) [\[240\]](#) [\[241\]](#) [\[242\]](#) [\[243\]](#) [\[244\]](#) [\[245\]](#) [\[246\]](#) [\[247\]](#) [\[248\]](#) [\[249\]](#) [\[250\]](#) [\[251\]](#) [\[252\]](#) [\[253\]](#) [\[254\]](#) [\[255\]](#) [\[256\]](#) [\[257\]](#) [\[258\]](#) [\[259\]](#) [\[260\]](#) [\[261\]](#) [\[262\]](#) [\[263\]](#) [\[264\]](#) [\[265\]](#) [\[266\]](#) [\[267\]](#) [\[268\]](#) [\[269\]](#) [\[270\]](#) [\[271\]](#) [\[272\]](#) [\[273\]](#) [\[274\]](#) [\[275\]](#) [\[276\]](#) [\[277\]](#) [\[278\]](#) [\[279\]](#) [\[280\]](#) [\[281\]](#) [\[282\]](#) [\[283\]](#) [\[284\]](#) [\[285\]](#) [\[286\]](#) [\[287\]](#) [\[288\]](#) [\[289\]](#) [\[290\]](#) [\[291\]](#) [\[292\]](#) [\[293\]](#) [\[294\]](#) [\[295\]](#) [\[296\]](#) [\[297\]](#) [\[298\]](#) [\[299\]](#) [\[300\]](#) [\[301\]](#) [\[302\]](#) [\[303\]](#) [\[304\]](#) [\[305\]](#) [\[306\]](#) [\[307\]](#) [\[308\]](#) [\[309\]](#) [\[310\]](#) [\[311\]](#) [\[312\]](#) [\[313\]](#) [\[314\]](#) [\[315\]](#) [\[316\]](#) [\[317\]](#) [\[318\]](#) [\[319\]](#) [\[320\]](#) [\[321\]](#) [\[322\]](#) [\[323\]](#) [\[324\]](#) [\[325\]](#) [\[326\]](#) [\[327\]](#) [\[328\]](#) [\[329\]](#) [\[330\]](#) [\[331\]](#) [\[332\]](#) [\[333\]](#) [\[334\]](#) [\[335\]](#) [\[336\]](#) [\[337\]](#) [\[338\]](#) [\[339\]](#) [\[340\]](#) [\[341\]](#) [\[342\]](#) [\[343\]](#) [\[344\]](#) [\[345\]](#) [\[346\]](#) [\[347\]](#) [\[348\]](#) [\[349\]](#) [\[350\]](#) [\[351\]](#) [\[352\]](#) [\[353\]](#) [\[354\]](#) [\[355\]](#) [\[356\]](#) [\[357\]](#) [\[358\]](#) [\[359\]](#) [\[360\]](#) [\[361\]](#) [\[362\]](#) [\[363\]](#) [\[364\]](#) [\[365\]](#) [\[366\]](#) [\[367\]](#) [\[368\]](#) [\[369\]](#) [\[370\]](#) [\[371\]](#) [\[372\]](#) [\[373\]](#) [\[374\]](#) [\[375\]](#) [\[376\]](#) [\[377\]](#) [\[378\]](#) [\[379\]](#) [\[380\]](#) [\[381\]](#) [\[382\]](#) [\[383\]](#) [\[384\]](#) [\[385\]](#) [\[386\]](#) [\[387\]](#) [\[388\]](#) [\[389\]](#) [\[390\]](#) [\[391\]](#) [\[392\]](#) [\[393\]](#) [\[394\]](#) [\[395\]](#) [\[396\]](#) [\[397\]](#) [\[398\]](#) [\[399\]](#) [\[400\]](#) [\[401\]](#) [\[402\]](#) [\[403\]](#) [\[404\]](#) [\[405\]](#) [\[406\]](#) [\[407\]](#) [\[408\]](#) [\[409\]](#) [\[410\]](#) [\[411\]](#) [\[412\]](#) [\[413\]](#) [\[414\]](#) [\[415\]](#) [\[416\]](#) [\[417\]](#) [\[418\]](#) [\[419\]](#) [\[420\]](#) [\[421\]](#) [\[422\]](#) [\[423\]](#) [\[424\]](#) [\[425\]](#) [\[426\]](#) [\[427\]](#) [\[428\]](#) [\[429\]](#) [\[430\]](#) [\[431\]](#) [\[432\]](#) [\[433\]](#) [\[434\]](#) [\[435\]](#) [\[436\]](#) [\[437\]](#) [\[438\]](#) [\[439\]](#) [\[440\]](#) [\[441\]](#) [\[442\]](#) [\[443\]](#) [\[444\]](#) [\[445\]](#) [\[446\]](#) [\[447\]](#) [\[448\]](#) [\[449\]](#) [\[450\]](#) [\[451\]](#) [\[452\]](#) [\[453\]](#) [\[454\]](#) [\[455\]](#) [\[456\]](#) [\[457\]](#) [\[458\]](#) [\[459\]](#) [\[460\]](#) [\[461\]](#) [\[462\]](#) [\[463\]](#) [\[464\]](#) [\[465\]](#) [\[466\]](#) [\[467\]](#) [\[468\]](#) [\[469\]](#) [\[470\]](#) [\[471\]](#) [\[472\]](#) [\[473\]](#) [\[474\]](#) [\[475\]](#) [\[476\]](#) [\[477\]](#) [\[478\]](#) [\[479\]](#) [\[480\]](#) [\[481\]](#) [\[482\]](#) [\[483\]](#) [\[484\]](#) [\[485\]](#) [\[486\]](#) [\[487\]](#) [\[488\]](#) [\[489\]](#) [\[490\]](#) [\[491\]](#) [\[492\]](#) [\[493\]](#) [\[494\]](#) [\[495\]](#) [\[496\]](#) [\[497\]](#) [\[498\]](#) [\[499\]](#) [\[500\]](#) [\[501\]](#) [\[502\]](#) [\[503\]](#) [\[504\]](#) [\[505\]](#) [\[506\]](#) [\[507\]](#) [\[508\]](#) [\[509\]](#) [\[510\]](#) [\[511\]](#) [\[512\]](#) [\[513\]](#) [\[514\]](#) [\[515\]](#) [\[516\]](#) [\[517\]](#) [\[518\]](#) [\[519\]](#) [\[520\]](#) [\[521\]](#) [\[522\]](#) [\[523\]](#) [\[524\]](#) [\[525\]](#) [\[526\]](#) [\[527\]](#) [\[528\]](#) [\[529\]](#) [\[530\]](#) [\[531\]](#) [\[532\]](#) [\[533\]](#) [\[534\]](#) [\[535\]](#) [\[536\]](#) [\[537\]](#) [\[538\]](#) [\[539\]](#) [\[540\]](#) [\[541\]](#) [\[542\]](#) [\[543\]](#) [\[544\]](#) [\[545\]](#) [\[546\]](#) [\[547\]](#) [\[548\]](#) [\[549\]](#) [\[550\]](#) [\[551\]](#) [\[552\]](#) [\[553\]](#) [\[554\]](#) [\[555\]](#) [\[556\]](#) [\[557\]](#) [\[558\]](#) [\[559\]](#) [\[560\]](#) [\[561\]](#) [\[562\]](#) [\[563\]](#) [\[564\]](#) [\[565\]](#) [\[566\]](#) [\[567\]](#) [\[568\]](#) [\[569\]](#) [\[570\]](#) [\[571\]](#) [\[572\]](#) [\[573\]](#) [\[574\]](#) [\[575\]](#) [\[576\]](#) [\[577\]](#) [\[578\]](#) [\[579\]](#) [\[580\]](#) [\[581\]](#) [\[582\]](#) [\[583\]](#) [\[584\]](#) [\[585\]](#) [\[586\]](#) [\[587\]](#) [\[588\]](#) [\[589\]](#) [\[590\]](#) [\[591\]](#) [\[592\]](#) [\[593\]](#) [\[594\]](#) [\[595\]](#) [\[596\]](#) [\[597\]](#) [\[598\]](#) [\[599\]](#) [\[600\]](#) [\[601\]](#) [\[602\]](#) [\[603\]](#) [\[604\]](#) [\[605\]](#) [\[606\]](#) [\[607\]](#) [\[608\]](#) [\[609\]](#) [\[610\]](#) [\[611\]](#) [\[612\]](#) [\[613\]](#) [\[614\]](#) [\[615\]](#) [\[616\]](#) [\[617\]](#) [\[618\]](#) [\[619\]](#) [\[620\]](#) [\[621\]](#) [\[622\]](#) [\[623\]](#) [\[624\]](#) [\[625\]](#) [\[626\]](#) [\[627\]](#) [\[628\]](#) [\[629\]](#) [\[630\]](#) [\[631\]](#) [\[632\]](#) [\[633\]](#) [\[634\]](#) [\[635\]](#) [\[636\]](#) [\[637\]](#) [\[638\]](#) [\[639\]](#) [\[640\]](#) [\[641\]](#) [\[642\]](#) [\[643\]](#) [\[644\]](#) [\[645\]](#) [\[646\]](#) [\[647\]](#) [\[648\]](#) [\[649\]](#) [\[650\]](#) [\[651\]](#) [\[652\]](#) [\[653\]](#) [\[654\]](#) [\[655\]](#) [\[656\]](#) [\[657\]](#) [\[658\]](#) [\[659\]](#) [\[660\]](#) [\[661\]](#) [\[662\]](#) [\[663\]](#) [\[664\]](#) [\[665\]](#) [\[666\]](#) [\[667\]](#) [\[668\]](#) [\[669\]](#) [\[670\]](#) [\[671\]](#) [\[672\]](#) [\[673\]](#) [\[674\]](#) [\[675\]](#) [\[676\]](#) [\[677\]](#) [\[678\]](#) [\[679\]](#) [\[680\]](#) [\[681\]](#) [\[682\]](#) [\[683\]](#) [\[684\]](#) [\[685\]](#) [\[686\]](#) [\[687\]](#) [\[688\]](#) [\[689\]](#) [\[690\]](#) [\[691\]](#) [\[692\]](#) [\[693\]](#) [\[694\]](#) [\[695\]](#) [\[696\]](#) [\[697\]](#) [\[698\]](#) [\[699\]](#) [\[700\]](#) [\[701\]](#) [\[702\]](#) [\[703\]](#) [\[704\]](#) [\[705\]](#) [\[706\]](#) [\[707\]](#) [\[708\]](#) [\[709\]](#) [\[710\]](#) [\[711\]](#) [\[712\]](#) [\[713\]](#) [\[714\]](#) [\[715\]](#) [\[716\]](#) [\[717\]](#) [\[718\]](#) [\[719\]](#) [\[720\]](#) [\[721\]](#) [\[722\]](#) [\[723\]](#) [\[724\]](#) [\[725\]](#) [\[726\]](#) [\[727\]](#) [\[728\]](#) [\[729\]](#) [\[730\]](#) [\[731\]](#) [\[732\]](#) [\[733\]](#) [\[734\]](#) [\[735\]](#) [\[736\]](#) [\[737\]](#) [\[738\]](#) [\[739\]](#) [\[740\]](#) [\[741\]](#) [\[742\]](#) [\[743\]](#) [\[744\]](#) [\[745\]](#) [\[746\]](#) [\[747\]](#) [\[748\]](#) [\[749\]](#) [\[750\]](#) [\[751\]](#) [\[752\]](#) [\[753\]](#) [\[754\]](#) [\[755\]](#) [\[756\]](#) [\[757\]](#) [\[758\]](#) [\[759\]](#) [\[760\]](#) [\[761\]](#) [\[762\]](#) [\[763\]](#) [\[764\]](#) [\[765\]](#) [\[766\]](#) [\[767\]](#) [\[768\]](#) [\[769\]](#) [\[770\]](#) [\[771\]](#) [\[772\]](#) [\[773\]](#) [\[774\]](#) [\[775\]](#) [\[776\]](#) [\[777\]](#) [\[778\]](#) [\[779\]](#) [\[780\]](#) [\[781\]](#) [\[782\]](#) [\[783\]](#) [\[784\]](#) [\[785\]](#) [\[786\]](#) [\[787\]](#) [\[788\]](#) [\[789\]](#) [\[790\]](#) [\[791\]](#) [\[792\]](#) [\[793\]](#) [\[794\]](#) [\[795\]](#) [\[796\]](#) [\[797\]](#) [\[798\]](#) [\[799\]](#) [\[800\]](#) [\[801\]](#) [\[802\]](#) [\[803\]](#) [\[804\]](#) [\[805\]](#) [\[806\]](#) [\[807\]](#) [\[808\]](#) [\[809\]](#) [\[810\]](#) [\[811\]](#) [\[812\]](#) [\[813\]](#) [\[814\]](#) [\[815\]](#) [\[816\]](#) [\[817\]](#) [\[818\]](#) [\[819\]](#) [\[820\]](#) [\[821\]](#) [\[822\]](#) [\[823\]](#) [\[824\]](#) [\[825\]](#) [\[826\]](#) [\[827\]](#) [\[828\]](#) [\[829\]](#) [\[830\]](#) [\[831\]](#) [\[832\]](#) [\[833\]](#) [\[834\]](#) [\[835\]](#) [\[836\]](#) [\[837\]](#) [\[838\]](#) [\[839\]](#) [\[840\]](#) [\[841\]](#) [\[842\]](#) [\[843\]](#) [\[844\]](#) [\[845\]](#) [\[846\]](#) [\[847\]](#) [\[848\]](#) [\[849\]](#) [\[850\]](#) [\[851\]](#) [\[852\]](#) [\[853\]](#) [\[854\]](#) [\[855\]](#) [\[856\]](#) [\[857\]](#) [\[858\]](#) [\[859\]](#) [\[860\]](#) [\[861\]](#) [\[862\]](#) [\[863\]](#) [\[864\]](#) [\[865\]](#) [\[866\]](#) [\[867\]](#) [\[868\]](#) [\[869\]](#) [\[870\]](#) [\[871\]](#) [\[872\]](#) [\[873\]](#) [\[874\]](#) [\[875\]](#) [\[876\]](#) [\[877\]](#) [\[878\]](#) [\[879\]](#) [\[880\]](#) [\[881\]](#) [\[882\]](#) [\[883\]](#) [\[884\]](#) [\[885\]](#) [\[886\]](#) [\[887\]](#) [\[888\]](#) [\[889\]](#) [\[890\]](#) [\[891\]](#) [\[892\]](#) [\[893\]](#) [\[894\]](#) [\[895\]](#) [\[896\]](#) [\[897\]](#) [\[898\]](#) [\[899\]](#) [\[900\]](#) [\[901\]](#) [\[902\]](#) [\[903\]](#) [\[904\]](#) [\[905\]](#) [\[906\]](#) [\[907\]](#) [\[908\]](#) [\[909\]](#) [\[910\]](#) [\[911\]](#) [\[912\]](#) [\[913\]](#) [\[914\]](#) [\[915\]](#) [\[916\]](#) [\[917\]](#) [\[918\]](#) [\[919\]](#) [\[920\]](#) [\[921\]](#) [\[922\]](#) [\[923\]](#) [\[924\]](#) [\[925\]](#) [\[926\]](#) [\[927\]](#) [\[928\]](#) [\[929\]](#) [\[930\]](#) [\[931\]](#) [\[932\]](#) [\[933\]](#) [\[934\]](#) [\[935\]](#) [\[936\]](#) [\[937\]](#) [\[938\]](#) [\[939\]](#) [\[940\]](#) [\[941\]](#) [\[942\]](#) [\[943\]](#) [\[944\]](#) [\[945\]](#) [\[946\]](#) [\[947\]](#) [\[948\]](#) [\[949\]](#) [\[950\]](#) [\[951\]](#) [\[952\]](#) [\[953\]](#) [\[954\]](#) [\[955\]](#) [\[956\]](#) [\[957\]](#) [\[958\]](#) [\[959\]](#) [\[960\]](#) [\[961\]](#) [\[962\]](#) [\[963\]](#) [\[964\]](#) [\[965\]](#) [\[966\]](#) [\[967\]](#) [\[968\]](#) [\[969\]](#) [\[970\]](#) [\[971\]](#) [\[972\]](#) [\[973\]](#) [\[974\]](#) [\[975\]](#) [\[976\]](#) [\[977\]](#) [\[978\]](#) [\[979\]](#) [\[980\]](#) [\[981\]](#) [\[982\]](#) [\[983\]](#) [\[984\]](#) [\[985\]](#) [\[986\]](#) [\[987\]](#) [\[988\]](#) [\[989\]](#) [\[990\]](#) [\[991\]](#) [\[992\]](#) [\[993\]](#) [\[994\]](#) [\[995\]](#) [\[996\]](#) [\[997\]](#) [\[998\]](#) [\[999\]](#) [\[1000\]](#)

# Encoder-decoder




Youssef A., Pennisi A., Bloisi D., Nardi D., Muscio M., Facchiano A.  
(2018). *Deep Convolutional Pixelwise Labeling for Skin Lesion Image Segmentation*

# U-Net Segmentation




---

*T. Falk, D. Mai et al. U-Net – Deep Learning for Cell Counting, Detection, and Morphometry. Nature Methods, 16, 67–70, Jan 2019*



Zalety:


- Mały zbiór wejściowy - data augmentation,
- Rozdzielenie obiektów związanych



---


*T. Falk, D. Mai et al. U-Net – Deep Learning for Cell Counting, Detection, and Morphometry. Nature Methods, 16, 67–70, Jan 2019*

## Network Architecture




*U-Net: Convolutional Networks for Biomedical Image Segmentation* O. Ronneberger, P. Fischer, T. Brox, *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351:

# Splot




## 3x3 convolution + ReLU



*5 Minute Teaser Presentation of the U-net, Dept. of Computer Science, University of Freiburg*

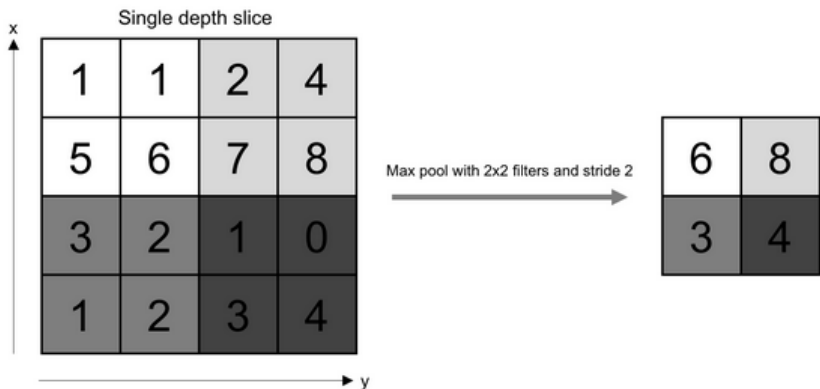


## Network Architecture




*U-Net: Convolutional Networks for Biomedical Image Segmentation* O. Ronneberger, P. Fischer, T. Brox, *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351:

# Max pooling

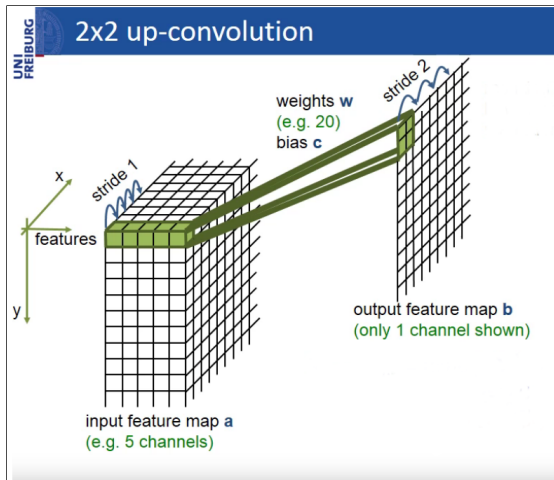


## Network Architecture



*U-Net: Convolutional Networks for Biomedical Image Segmentation* O. Ronneberger, P. Fischer, T. Brox, *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, Springer, LNCS, Vol.9351:

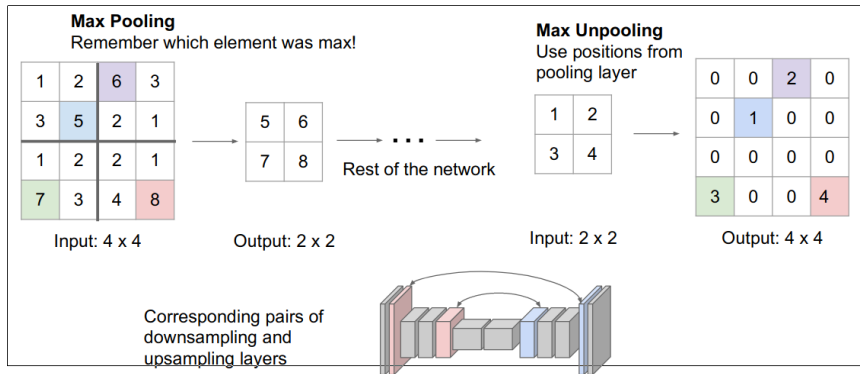
# Up-convolution - deconvolution




[https://github.com/vdumoulin/conv\\_arithmetic/blob/master/gif/no\\_padding\\_no\\_strides\\_transposed.gif](https://github.com/vdumoulin/conv_arithmetic/blob/master/gif/no_padding_no_strides_transposed.gif)

Vincent Dumoulin, Francesco Visin - *A guide to convolution arithmetic for deep learning*


# Max Unpooling



# Data augmentation



resulting deformed image  
(for visualization: no rotation. no shift. no extrapolation)



correspondingly deformed  
manual labels

*5 Minute Teaser Presentation of the U-net, Dept. of Computer Science,  
University of Freiburg*

- 1 Progowanie:
  - globalne
  - lokalne
  - adaptacyjne
  - metoda Otsu
- 2 Etykietowanie - CC
- 3 Atywne kontury - Snake
- 4 Segmentacja oparta na regionach:
  - rozrost regionów
  - podział regionów
  - metoda działów wodnych
- 5 Graph-cuts
- 6 U-Net
- 7 **Instance segmentation: Mask R-CNN**

# Semantic vs. Instance segmentation


Classification




Semantic Segmentation



Object Detection



Instance Segmentation








Algorytm dwu-etapowy:

- 1 Propozycja regionów (Region Proposal Network - RPN)
- 2 Predykcja klasy, oczyszczenie bbox, **wygenerowanie dokładnej maski** - wszystko na podstawie 1. etapu

`https://github.com/matterport/Mask\_RCNN`



## 1. Propozycje regionów - Selective search:

- Odnajdywanie regionów, w których prawdopodobnie znajdują się obiekty
- Metoda szybka i wydajna, stosuje sieci CNN (FPN - Feature Pyramid Network)

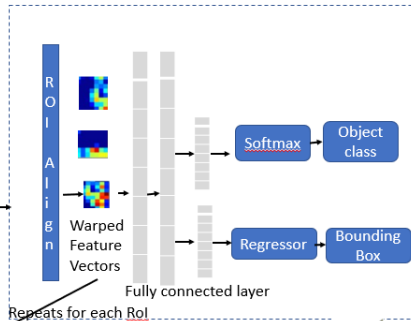


## Mask RCNN


### Region Proposal Network




Regions after Non Max suppression




Mask Classifier






Anchor boxes, które mają  $IoU > 0.5$  są wybierane przy użyciu **Non-Max suppression**: wybór regionu o największym  $IoU$  i ukrycie pozostałych propozycji bbox dla tego obiektu

## Intersection over Union





Blue is predicted bounding box and red is ground truth bounding box



Intersection





Union




## Mask RCNN

### Region Proposal Network



Regions after  
Non Max suppression




Repeats for each RoI

Mask Classifier



# 2a. Klasyfikacja propozycji

Detections



[github.com/matterport/MaskRCNN](https://github.com/matterport/MaskRCNN)

Magdalena Mazur-Milecka




## 2b. Bbox

Detections after NMS



## 2c. Generowanie masek



# Połączenie wszystkich elementów - Final result

Predictions



[github.com/matterport/MaskRCNN](https://github.com/matterport/MaskRCNN)

Magdalena Mazur-Milecka