

CETS8AH :

Outils pour le traitement et l'analyse d'images


Session : Segmentation d'images

- Segmenter : Définition, rôle
- Classification : *K-means, Mean-shift*
- Contour déformable : *Snakes, Gradient vector flow*
- Séparation de graphes : *Graph-cuts*
- Région déformable : *Level set (Chan-Vese)*
- Modèles profonds : *Unet, SAM*

Perception d'une image

Image \neq pixels

Image = objets, formes




Berkeley segmentation dataset

(<https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds>)

Perception d'une image

Image \neq pixels

Image = objets, formes



Berkeley segmentation dataset

(<https://www2.eecs.berkeley.edu/Research/Projects/CS/vision/bsds/>)

Séparation objet/fond



Segmentation sémantique



Suivi d'objet



« Bilateral space video segmentation ». Märki et al. CVPR 2016


Reconstruction stéréo



Image de gauche





Image de droite





Carte de disparité (graph-cuts)



Méthode naïve : seuillage





Méthode naïve : seuillage





Méthode naïve : seuillage




Méthode naïve : seuillage




Méthode naïve : seuillage




K-means



K-means




K-means



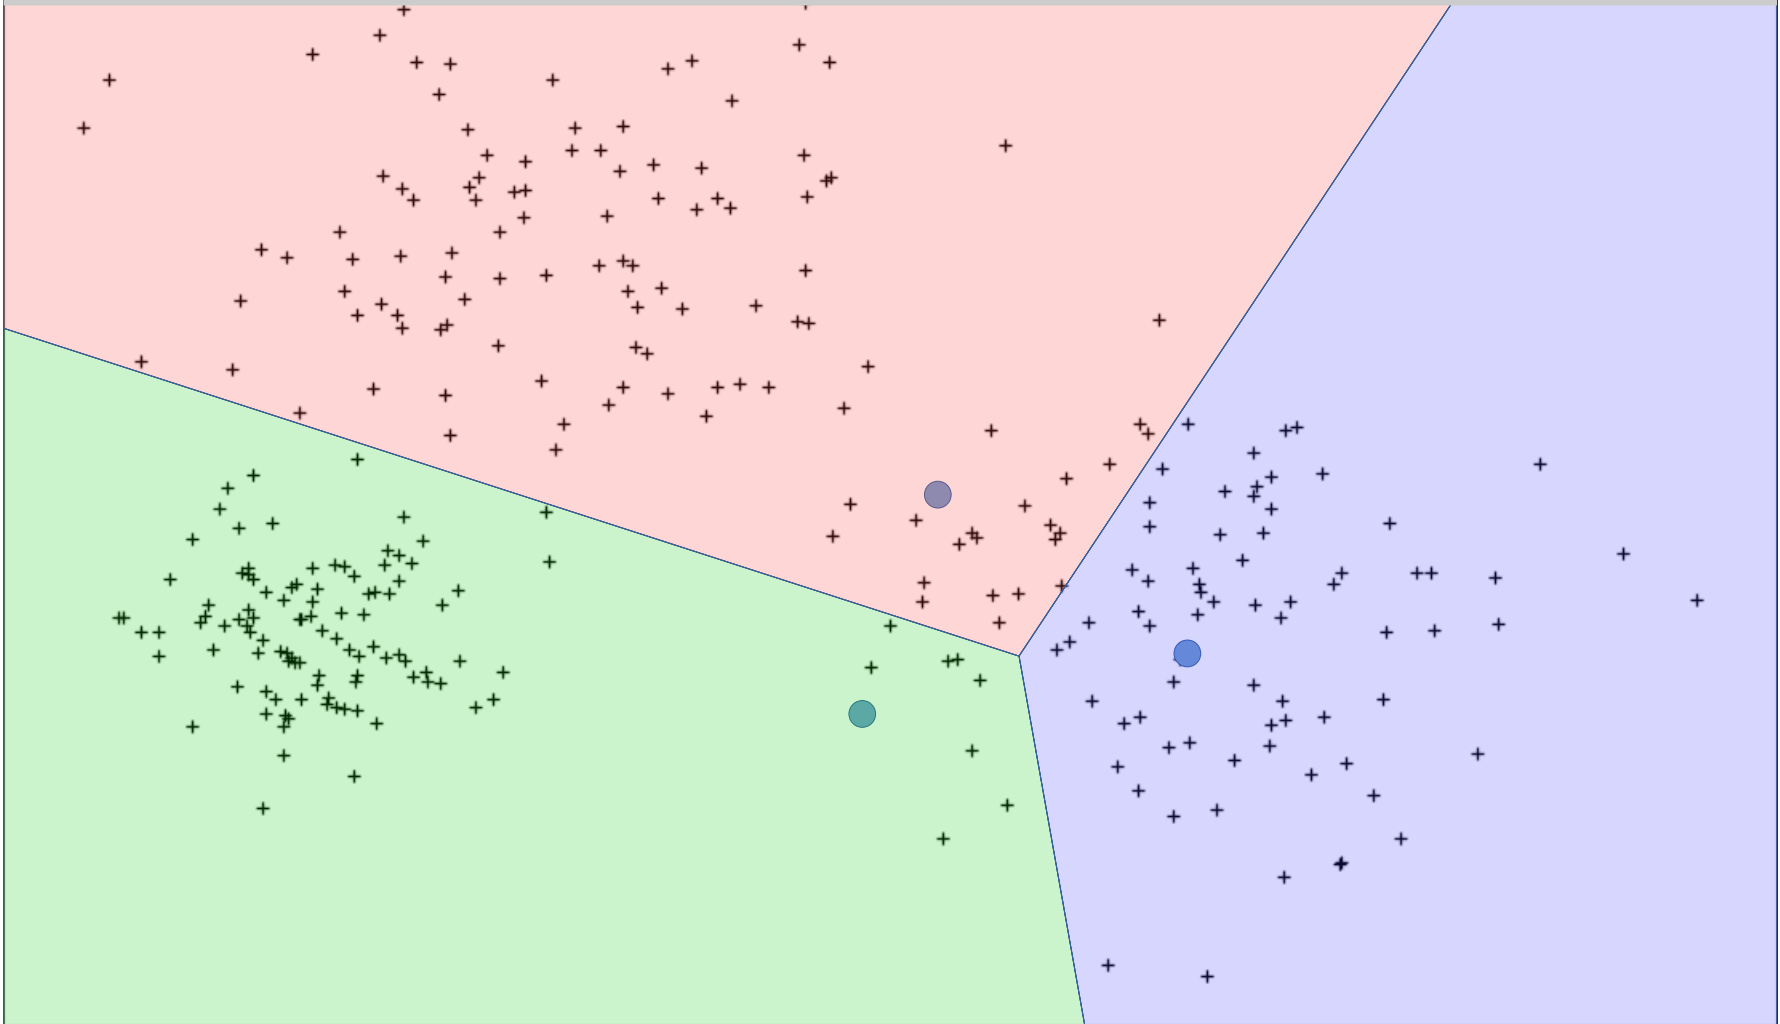
K-means

Supposons que des centres sont donnés



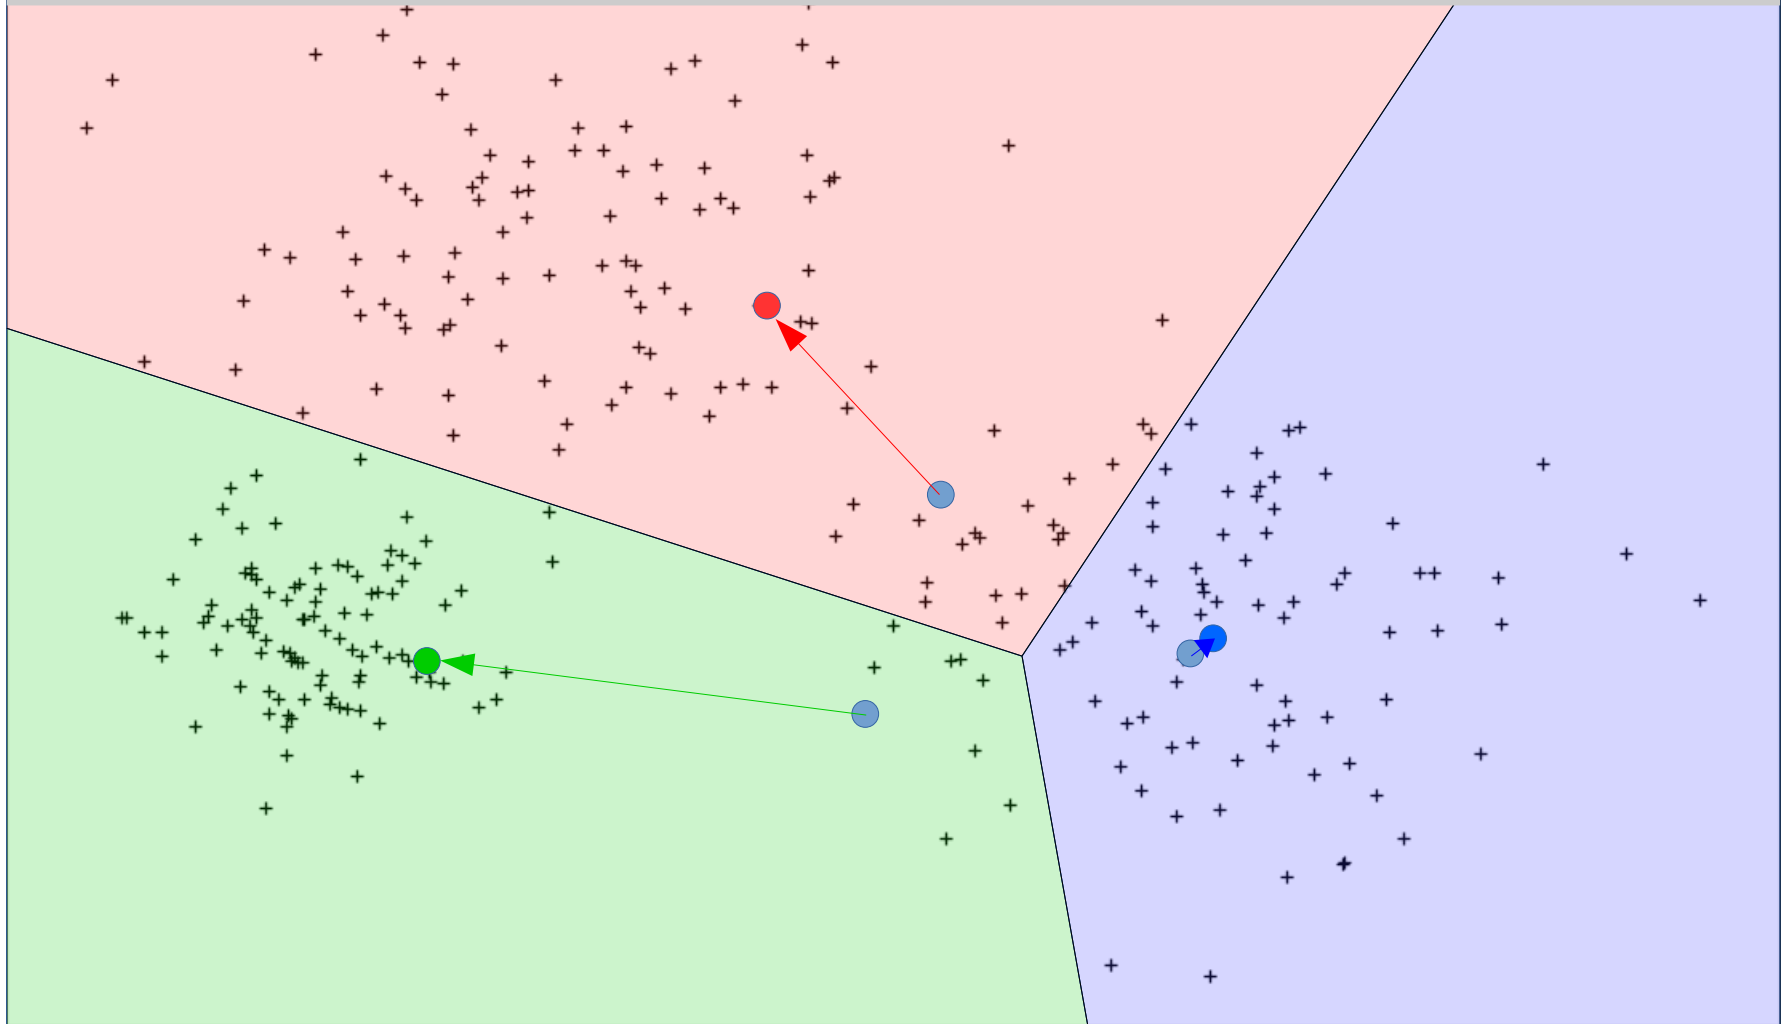
K-means

On détermine la classe des points (appariés au centre le plus proche)



K-means

On met à jour les centres (points moyens par classe)... Et on itère.



K-means : Algorithmme

- 1) K classes S_t
- 2) Initialiser les centres aléatoirement (c_1, \dots, c_K)
- 3) Déterminer la classe t des points $\{p_i\}$ (centre le plus proche)

$$t_i = \operatorname{argmin}_{1 \leq t \leq K} |p_i - c_t|$$

- 4) Mettre à jour les centres (moyenne sur la classe)

$$c_t = \frac{1}{\operatorname{card}(S_t)} \sum_{p_i \in S_t} p_i$$

- 5) Si les centres ont bougé, itérer à partir de 3)


K-means : Pros & Cons

Pros

- ✓ Très simple
- ✓ Converge vers un minimum local

Cons


- ✓ Gourmand en mémoire
- ✓ Nécessité de choisir K a priori
- ✓ Sensible à l'initialisation (minimum local)
- ✓ Sensible aux points aberrants (critère quadratique)
- ✓ Uniquement adapté aux classes de forme circulaire




Mean-shift




Mean-shift




Mean-shift



Mean-shift



Mean-shift



Mean-shift : algorithme

Pour tous les points

- 1) Initialiser le centre avec le point
- 2) Calculer la moyenne sur un voisinage
- 3) Mettre à jour le centre avec cette moyenne
- 4) Itérer jusqu'à convergence

Centres = points d'accumulation


Mean-shift: Pros & Cons

Pros

- ✓ Nombre de classes automatique
- ✓ Un seul paramètre (taille du voisinage pour la moyenne)
- ✓ Générique (pas d'hypothèse de forme de classe)

Cons

- ✓ Difficulté de choix de la taille du voisinage
- ✓ Très gourmand en temps de calcul
- ✓ Problème de passage à l'échelle si la dimension de l'espace des caractéristiques augmente



Espace de caractéristiques

Points \neq pixels

Points = mesure stockée en chaque pixel



Ex : image N&B = intensité (une dimension)

Espace de caractéristiques

Points \neq pixels

Points = mesure stockée en chaque pixel

Ex : image N&B = intensité (une dimension)





K=2

Espace de caractéristiques

Points \neq pixels

Points = mesure stockée en chaque pixel

Ex : image N&B = intensité (une dimension)





K=4

Espace de caractéristiques

Points \neq pixels


Points = mesure stockée en chaque pixel

Ex : image N&B = intensité (une dimension)



Mean-shift (K=2)

Espace de caractéristiques : couleurs




Comaniciu et al. « Mean-Shift: A Robust Approach Toward Feature Space Analysis », *IEEE PAMI*, 24(5):1-18, 2002.

Espace de caractéristiques : couleurs




Comaniciu et al. « Mean-Shift: A Robust Approach Toward Feature Space Analysis », IEEE PAMI, 24(5):1-18, 2002.

Limites approche intensité



Edward H. Adelson

Limites approche intensité



Edward H. Adelson

Approche contour



Approche duale : identifier les contours

Snakes :

- contour=courbe déformable
- s'adapte aux bords les plus proches de l'image

Snakes : énergie

Contour=courbe paramétrée $C(s)$



Kass et al « Snakes: Active contour models », *IJCV*, pp 321-331, 1988

Snakes : énergie

Contour=courbe paramétrée $C(s)$

Chaque point $C(s)$ soumis à un potentiel → Énergie

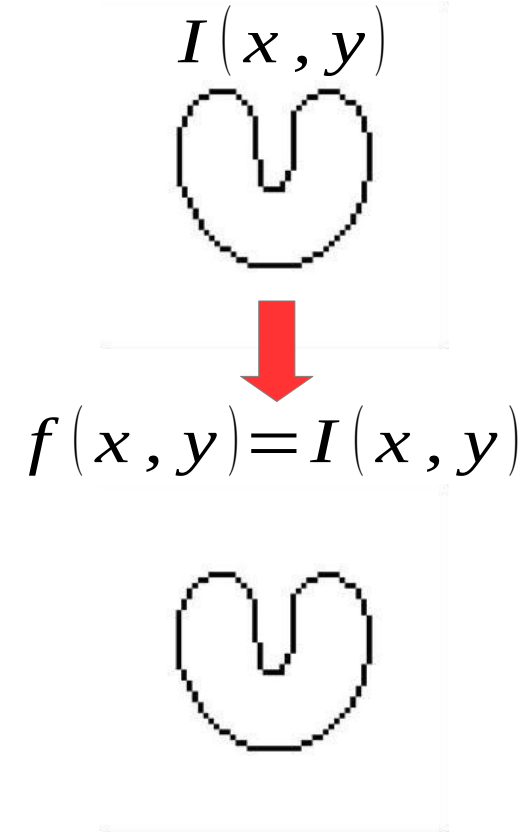
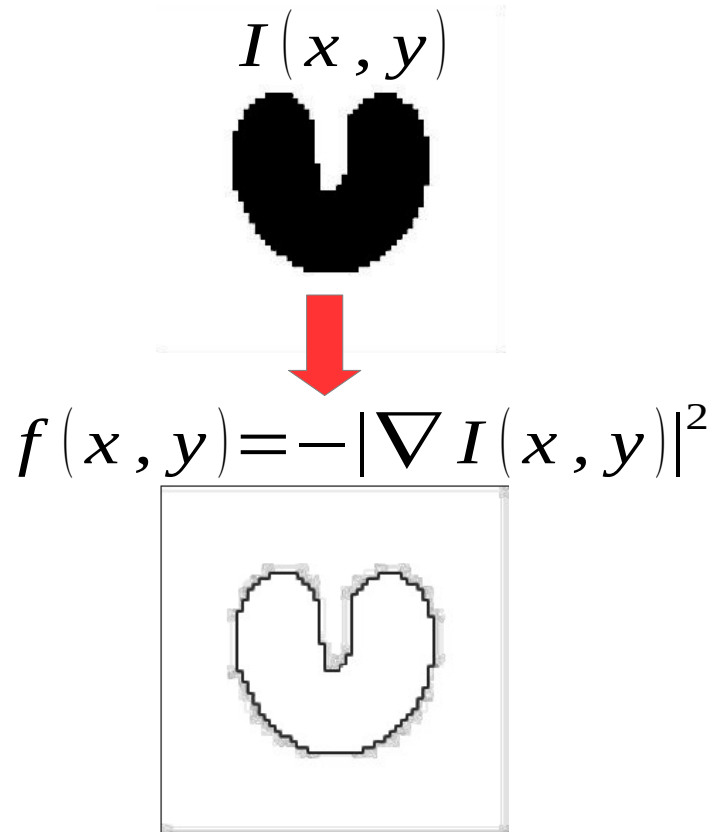
$$E_{snake} = \int_0^1 E_{int}(C(s)) + E_{image}(C(s)) ds$$

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

$$\begin{cases} E_{image}(C(s)) = -|\nabla I(C(s))|^2 \text{ (détection de bords)} \\ E_{image}(C(s)) = I(C(s)) \text{ (détection de lignes sombres)} \end{cases}$$

Kass et al « Snakes: Active contour models », IJCV, pp 321-331, 1988

Snakes : énergie externe



Carte des bords de l'image : $E_{\text{image}}(x, y) = f(x, y)$

Kass et al « Snakes: Active contour models », IJCV, pp 321-331, 1988

Snakes : résolution (minimisation E)

Dérivation (équation d'Euler-Lagrange)

$$-\alpha C_{ss} + \beta C_{ssss} + \frac{\partial E_{\text{image}}(C)}{\partial C} = 0$$

Discrétisation

$$AV - F = 0 \Leftrightarrow AV = F$$

Stabilisation

$$(A + \gamma I) V^{t+1} = F + \gamma V^t$$

Kass et al « Snakes: Active contour models », IJCV, pp 321-331, 1988

Snakes : limitations




Snakes traditionnels

- Sensibles à position initiale
- Difficulté de capturer les zones concaves

$$E_{\text{image}}(C(s)) = f(C(s))$$

$$\frac{\partial E_{\text{image}}(C)}{\partial C} = \nabla f(C)$$

$$\nabla f(x, y) = \left(\frac{\partial f(x, y)}{\partial x}, \frac{\partial f(x, y)}{\partial y} \right)$$



Xu and Prince « Gradient Vector Flow: A new external force for snakes », CVPR, pp 66-71, 1997

Gradient Vector Flow

Energie externe : remplacer le gradient de f par V

V défini comme minimisant

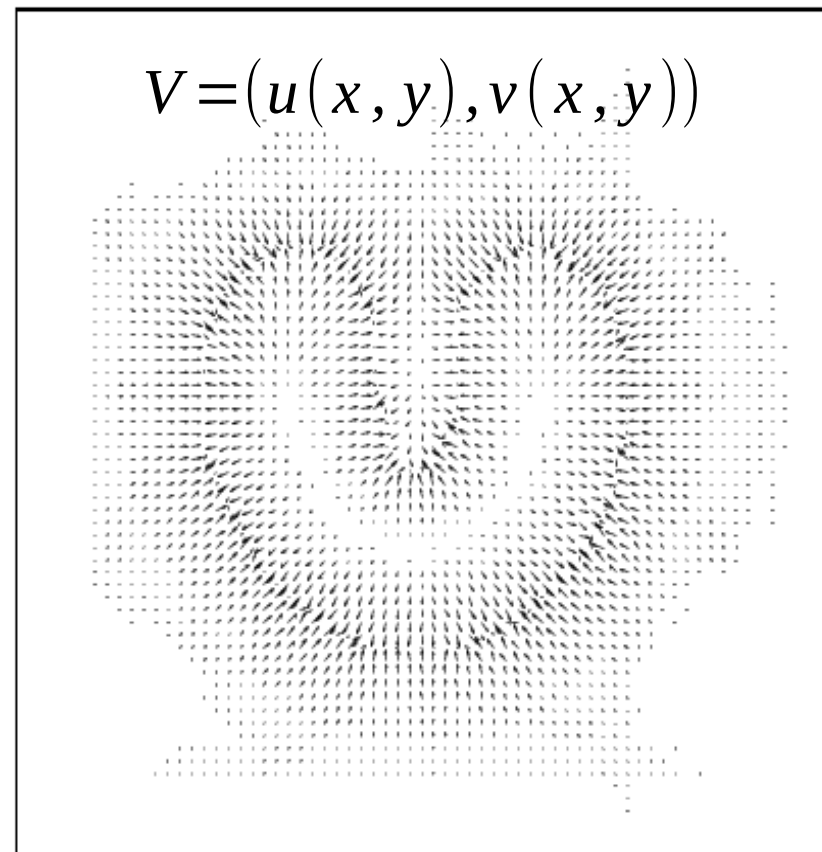
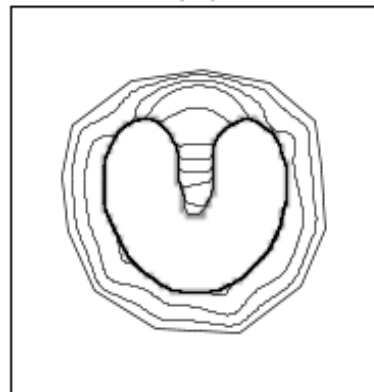
$$E = \iint \mu (u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla f|^2 |V - \nabla f|^2 dx dy$$

1^{er} terme : régularisation

2^e terme : V proche de ∇f



(a)



Xu and Prince « Gradient Vector Flow: A new external force for snakes », CVPR, pp 66-71, 1997

GVF : résolution

Equations d'Euler-Lagrange

$$\begin{aligned}\mu \nabla^2 u - (u - f_x)(f_x^2 + f_y^2) &= 0 \\ \mu \nabla^2 v - (v - f_y)(f_x^2 + f_y^2) &= 0\end{aligned}\quad (\nabla^2 \text{ est le laplacien})$$

Descente de gradient

$$\begin{aligned}\mu \nabla^2 u - (u - f_x)(f_x^2 + f_y^2) &= -\frac{\partial u}{\partial t} \\ \mu \nabla^2 v - (v - f_y)(f_x^2 + f_y^2) &= -\frac{\partial v}{\partial t}\end{aligned}$$

Xu and Prince « Gradient Vector Flow: A new external force for snakes », CVPR, pp 66-71, 1997

Approche contour vs approche région

Contours actifs

- Évolution d'une courbe
- Approche variationnelle → dynamique de la courbe, avec régularisation interne
- Objet = bords = forts gradients
- plus génériquement usage d'un champ énergétique régularisé

Prendre en compte l'espace : approches région


Problème

- Deux pixels proches peuvent avoir deux classes différentes
 - Segmentation bruitée
- Renforcer l'idée que pixels proches \Rightarrow même classe
 - « régularisation spatiale »
- Approche probabiliste :
 - Probabilité que l'intensité soit proche de celle caractéristique de la classe
 - Vs probabilité que deux pixels proches aient le même classe

Graph-cuts

Image représentée par un graphe

- ✓ Noeud = pixel
- ✓ Arc = voisinage
- ✓ Poids =
 - similarité au label (s ou t)
 - ou similarité entre labels voisins

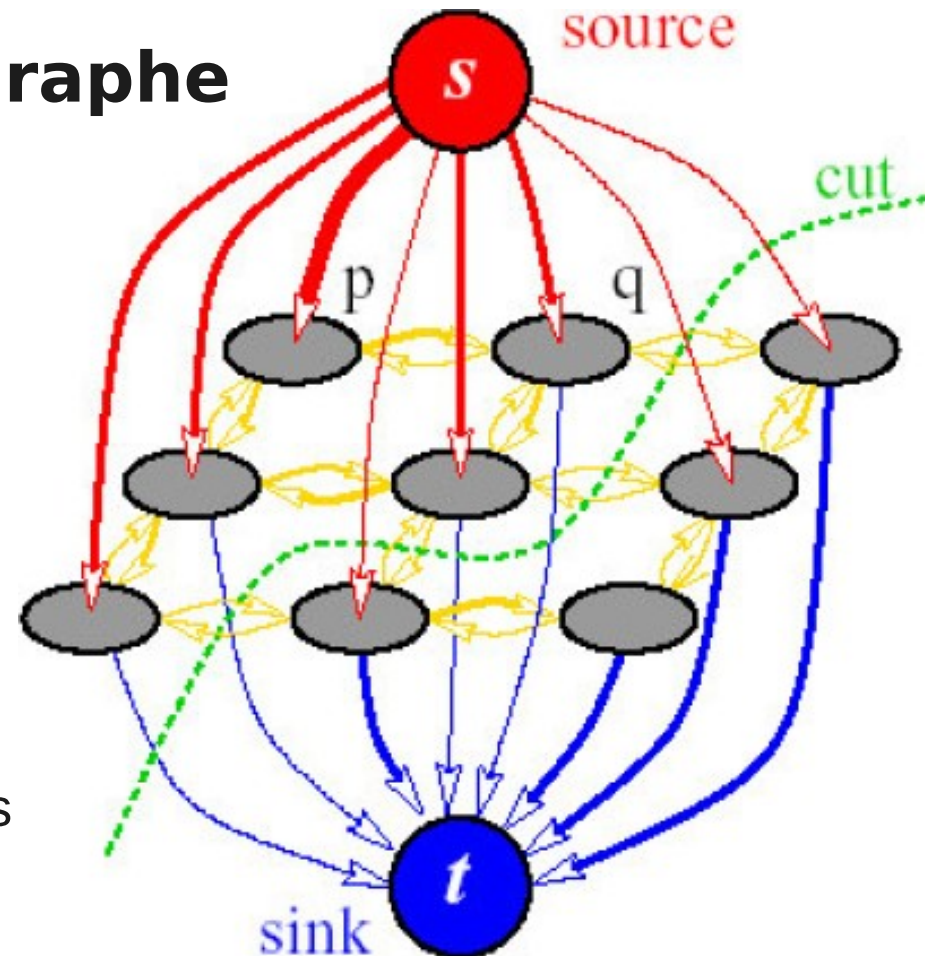


Boykov et al. « Fast approximate energy minimization via graph cuts », IEEE PAMI 23(11):1222-1239, 2001

Graph-cuts

Image représentée par un graphe

- ✓ Noeud = pixel
- ✓ Arc = voisinage
- ✓ Poids =
 - similarité au label (s ou t)
 - ou similarité entre labels voisins
- On veut le séparer en 2 graphes
- Coût de la coupe = somme des arcs ôtés
= somme des similarités
- On cherche une coupe min = flot max
(Ford-Fulkerson, voir Wikipedia: Maximum Flow Problem)



Boykov et al. « Fast energy minimization via graph cuts », IEEE PAMI 23(11):1222-1239

Modèle de Chan et Vese


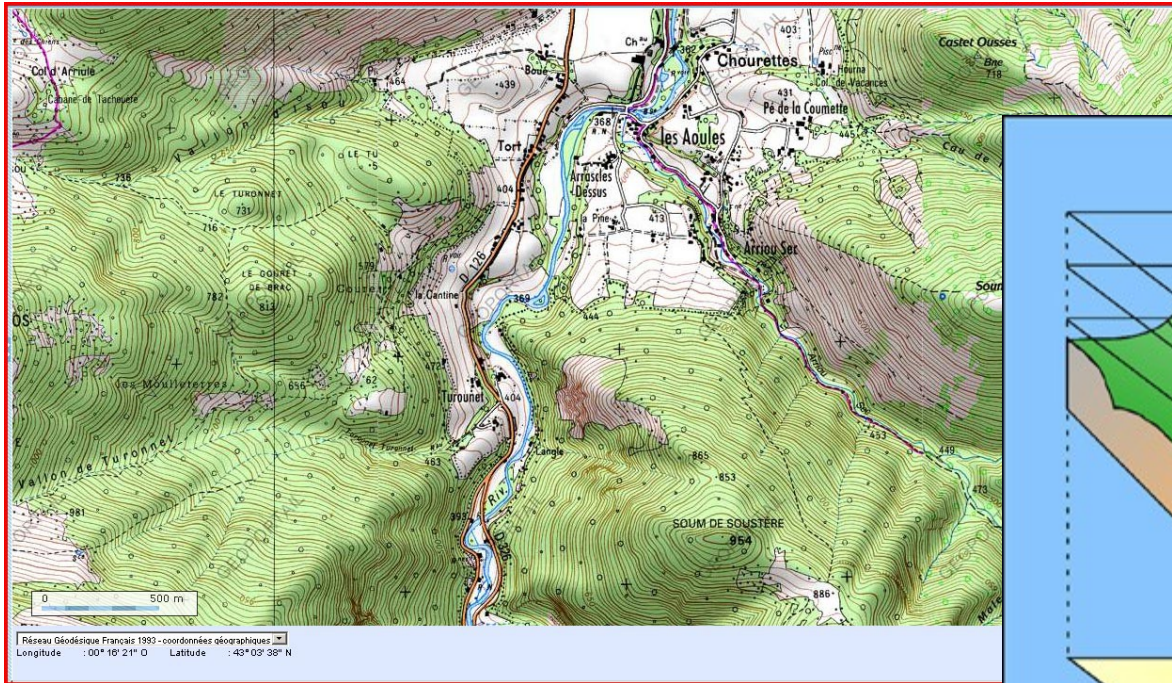
Modèle intensité constante

- Un objet d'intensité uniforme c_1
- Un fond d'intensité uniforme c_2
- Régularisation sur la longueur du contour et l'aire de l'objet

$$\begin{aligned} E(c_1, c_2, C) = & \mu \text{Length}(C) + \nu \text{Area}(\text{inside}(C)) \\ & + \lambda_1 \int_{\text{inside}(C)} |I(x, y) - c_1|^2 dx dy \\ & + \lambda_2 \int_{\text{outside}(C)} |I(x, y) - c_2|^2 dx dy \end{aligned}$$

Chan and Vese « Active contours without edges », IEEE TIP, 10(2):266-277, 2001

Level sets



Level sets


- Bord = isocontour = modèle implicite
- Régularisation = fonction implicite lisse

Reformulation

Emploi d'une fonction implicite

$$\phi(x, y) \text{ telle que } \begin{cases} C = \{(x, y) \in \Omega : \phi(x, y) = 0\} \\ \text{inside}(C) = \{(x, y) \in \Omega : \phi(x, y) > 0\} \\ \text{outside}(C) = \{(x, y) \in \Omega : \phi(x, y) < 0\} \end{cases}$$

Rappel : fonction Heaviside H (échelon unité)



$$H(s) = \begin{cases} 0 & \text{si } s < 0 \\ 1 & \text{si } s > 0 \end{cases}$$

$$H'(s) = \delta(s)$$

Chan and Vese « Active contours without edges », IEEE TIP, 10(2):266-277, 2001

Expression formelle

$$E(c_1, c_2, C) = \mu \text{Length}(C) + \nu \text{Area}(\text{inside}(C)) + \lambda_1 \int_{\text{inside}(C)} |I(x, y) - c_1|^2 dx dy \\ + \lambda_2 \int_{\text{outside}(C)} |I(x, y) - c_2|^2 dx dy$$

$$\text{Length}(C) = \int_{\Omega} |\nabla H(\phi(x, y))| dx dy$$

$$\text{Area}(C) = \int_{\Omega} H(\phi(x, y)) dx dy$$

$$\int_{\text{inside}(C)} |I(x, y) - c_1|^2 dx dy = \int_{\Omega} H(\phi(x, y)) |I(x, y) - c_1|^2 dx dy$$

$$\int_{\text{outside}(C)} |I(x, y) - c_2|^2 dx dy = \int_{\Omega} (1 - H(\phi(x, y))) |I(x, y) - c_2|^2 dx dy$$

$$\text{Descente de gradient : } \frac{\partial \phi}{\partial t} = - \frac{\partial E(c_1, c_2, \phi)}{\partial \phi}$$

Euler Lagrange

$$\frac{\partial}{\partial \phi} \text{Area}(C) = \delta(\phi(x, y))$$


$$\frac{\partial}{\partial \phi} \text{Length}(C) = \delta(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)$$

$$\frac{\partial}{\partial \phi} \int_{\text{inside}(C)} |I(x, y) - c_1|^2 dx dy = \delta(\phi) |I(x, y) - c_1|^2$$

$$\frac{\partial}{\partial \phi} \int_{\text{outside}(C)} |I(x, y) - c_2|^2 dx dy = -\delta(\phi) |I(x, y) - c_2|^2$$


Chan and Vese « Active contours without edges », IEEE TIP, 10(2):266-277, 2001

Exemple



Chan and Vese « Active contours without edges », *IEEE TIP*, 10(2):266-277, 2001

Architecture encodeur-décodeur



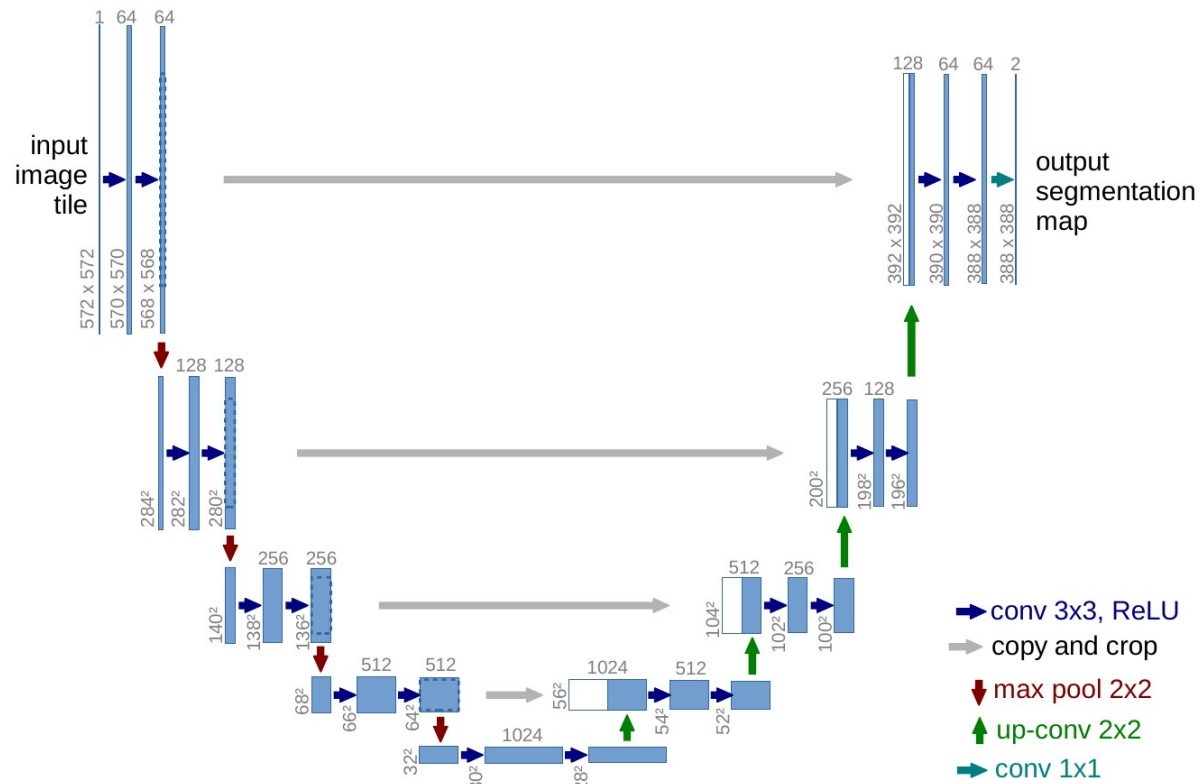
- Objectif : Classification de chaque pixel
- La sortie doit être de même taille que l'entrée
- Encodeur-décodeur : perte de précision
- Régularisation spatiale ?
 - FCN : couche fully connected en fin de réseau vue comme une (grosse) convolution
 - CRF : ajout de contraintes probabilistes sur la co-occurrence de labels à différents niveaux de voisinage
 - U-net, très utilisé en médical mais aussi ailleurs, et SegNet, plus petit

Minaee et al « Image Segmentation Using Deep Learning: A Survey », preprint arXiv:2001.05566, 2020

U-net


Principe : skip connections

Guider la déconvolution par une information à la bonne résolution




Ronneberger et al « U-Net: Convolutional Networks for Biomedical Image Segmentation », arXiv:1505.04597, 2015

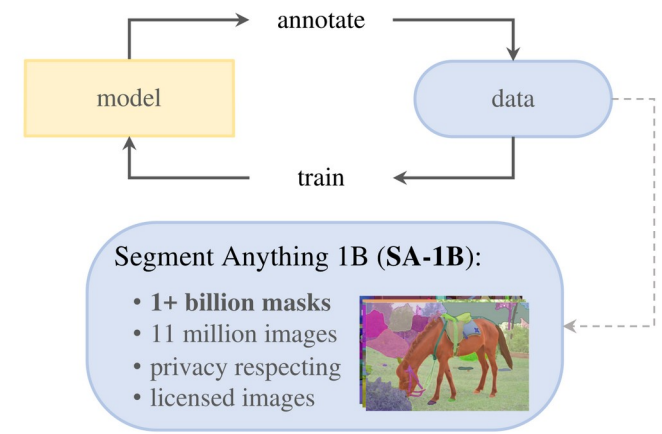
Segment Anything Model (SAM)



(a) **Task:** promptable segmentation



(b) **Model:** Segment Anything Model (SAM)



(c) **Data:** data engine (top) & dataset (bottom)

- Modèle fondamental pour la segmentation (*Foundation Model*)
- 4 tâches : masque, points, boîte, texte
- Entraînement sur SA-1B (11 millions d'images, plus d'1 milliards de masques)
- Annotation : Moteur de données, 3 étapes d'annotation (+ en + auto), de nombreux ré-entraînements
- Génère plusieurs masques avec score de confiance
- Validation sur expériences « zéro-shot »
- <https://segment-anything.com> (Meta)

En résumé

Deux approches : région vs contour

K-means, mean-shift :

- Simples, mais pas de régularisation spatiale
- Extension en classifiant une carte de caractéristique (ex : texture)

Snakes

- Contour, contrôle local, variations dans objet ou sur contour
- Convergence délicate, pas de changement de topologie
- Extensions nombreuses (GVF, diffusion snakes, Geometric Active Contours...)

Level-sets

- Région, contrôle global (fonction implicite), changement topologie ok
- Schémas numériques complexes (approche variationnelle), gourmands en temps de calcul
- Extensions nombreuses (régularisation, caractéristique image)

Deep learning

- Approches très efficaces, et majoritaires actuellement, même en 3D
- Toujours le problème des données annotées et la question de l'explicabilité