



## Analyse bayésienne et champs markoviens en traitement d'images

Florence Tupin  
Télécom ParisTech

# Sujets

- **Classification d'images**


- ▷ Modélisation du problème
- ▷ Solution sans modèle markovien
- ▷ Solution avec modèle markovien
- ▷ Exemples

- **Restauration d'images**

- ▷ Modélisation du problème
- ▷ Les processus bords

# Analyse Bayésienne en Traitement des Images

## Loi du processus de formation des observations




### o Espaces d'états

- restauration :  $y_s$  et  $x_s$  dans  $E$  (espace des niveaux de gris)
- classification :  $y_s$  dans  $E$ ,  $x_s$  dans  $\Lambda$  (espace des classes - *labels*)

## Distribution a posteriori

- **modélise le problème** :  $y \rightarrow x$  ?

$$\Pr(X = x / Y = y) = \frac{\Pr(Y = y / X = x) \cdot \Pr(X = x)}{\Pr(Y = y)} \quad [\text{Bayes}]$$



- **estimateur MAP** :  $\hat{x} = \arg \max_{x \in \Omega} \Pr(X = x / Y = y)$

# Classification d'images bayésienne ponctuelle

- **Exemple** Supposons qu'on veuille segmenter l'image cérébrale en 6 classes

$$\Lambda = \lambda_1, \lambda_2, \dots, \lambda_6$$

avec fond, peau, os, MG, MB, ventricules

- **Modèle ponctuel**

On suppose que chaque pixel est indépendant de ses voisins pour  $P(X|Y)$  :

$$P(X|Y) = \prod_s P(X_s|Y_s)$$

Finalement, le problème revient à chercher au pixel  $s$  la “meilleure” classe au sens du maximum de  $P(X_s|Y_s)$ .

$$P(X_s|Y_s) \propto P(Y_s|X_s)P(X_s)$$

(MAP ponctuel)

## Classification d'images bayésienne ponctuelle

- **Vraisemblance (ponctuelle)**

Terme  $P(Y_s = y_s | X_s = x_s)$

dépend du capteur (du processus d'acquisition) et des classes considérées.

⇒ modélisation physique, apprentissage supervisé par sélection manuelle de régions, apprentissage automatique par méthodes itératives (EM)

- **A priori (ponctuel)**

Terme  $P(X_s = x_s)$

Connaissance a priori de la proportion des classes

## Classification d'images bayésienne ponctuelle

- **Exemple**

cas de distributions gaussiennes pour la distribution des niveaux de gris  
conditionnellement aux classes

pas d'a priori sur les classes

- **Limites**

pas de cohérence spatiale

modèle peu efficace en TdI

⇒ modèles globaux sur  $X$  = modèle markovien

## Classification d'images

### Loi du processus de formation des observations

Critère MAP  $P(X = x|Y = y) \propto P(Y|X)P(X)$

- **Terme  $P(Y|X)$  - Hypothèses**

$$\Pr(Y = y / X = x) = \prod_{s \in S} \Pr(Y_s = y_s / x) = \prod_{s \in S} \Pr(Y_s = y_s / X_s = x_s)$$

- **Lois conditionnelles**

dépendent du capteur, des classes considérées



## Modèle (loi) a priori : propriétés désirées sur l'image réelle (image des classes)

- **Indépendance des sites**

$$P(X = x) = \prod_{s \in S} P(X_s = x_s)$$

probabilité a priori d'apparition des classes

classification bayésienne “ponctuelle”

$$P(Y_s = y_s / X_s = x_s)P(X_s) \propto P(X_s = x_s / Y_s = y_s)$$

- **Hypothèse markovienne sur  $X$**

⇒ interaction entre un site et ses voisins (régularité des régions, ...)

$$\Pr(X = x) = \frac{\exp -U(x)}{Z}$$

## Distribution a posteriori

- nouvelle distribution de Gibbs

$$\Pr(X = x / Y = y) = \frac{\exp -\mathcal{U}(x / y)}{Z'}$$

$$\mathcal{U}(x / y) = \sum_{s \in S} -\ln(P(Y_s = y_s / X_s)) + U(x)$$

$$\max_{x \in \Omega} \Pr(X = x / Y = y) \Leftrightarrow \min_{x \in \Omega} \mathcal{U}(x / y)$$

le champ *a posteriori* est markovien relativement au même système de voisinage que le champ a priori

# Optimisation

Recherche de la configuration la plus probable i.e d'énergie minimale

- **Recuit simulé**

distribution de Gibbs à température décroissante

(loi a posteriori)

inconvenient : lenteur de la convergence

- **ICM (modes conditionnels itérés)**

algorithme déterministe, convergence vers un minimum local

# Optimisation

- **ICM (modes conditionnels itérés) : algorithme déterministe**

- ▷ Initialisation  $x^{(0)}$  proche de la solution (ex MV ponctuel)
- ▷ Suite d'images  $x^{(n)}$  : à l'étape  $n$  (balayage de tous les sites)
  - tirage aléatoire d'un site  $s$  : loi uniforme ou mode raster
  - nouvelle valeur = max des proba locales


$$x_s^{(n)} = \operatorname{argmax}_{\xi \in E} P(X_s = \xi \mid y, V_s^{(n-1)})$$

- ▷ arrêt : taux de changement  $<$  seuil


## Caractéristiques

- ▷ Algorithme déterministe, résultat dépendant de l'initialisation
- ▷ Convergence rapide (quelques balayages)
- ▷ Risque de converger vers un minimum local de  $\mathcal{U}(x \mid y)$ .

## Exemple 1



# Exemple 1



## Exemple 1 : imagerie cérébrale

- **attache aux données : indépendance des lois conditionnelles**

$$P(Y = y \mid X = x) = \prod_{s \in S} P(Y_s = y_s \mid X_s = x_s)$$

Cas gaussien : apprentissage des lois normales des classes  $i$  :  $\mathcal{N}(\mu_i, \sigma_i)$

$$P(Y_s = y_s \mid X_s = i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp - \left( \frac{(y_s - \mu_i)^2}{2\sigma_i^2} \right)$$

- **régularisation**

Intéractions locales entre étiquettes : modèle de Potts, voisinage 8-connexes


⇒ Distribution a posteriori  $P(X \mid Y)$  : loi de Gibbs d'énergie locale

$$\mathcal{U}(x_s \mid y, V_s) = \log \sigma_{x_s} + \frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} - \beta \sum_{r \in \mathcal{V}_s} 1_{(x_s = x_r)}$$

- **optimisation - estimation au sens du MAP de  $x$**

initialisation : aléatoire ; algorithme : recuit simulé

# Exemple 1





## Exemple 2



## Exemple 2 : imagerie satellitaire radar

- **attache aux données : indépendance des lois conditionnelles**

$$P(Y = y \mid X = x) = \prod_{s \in S} P(Y_s = y_s \mid X_s = x_s)$$

lois Gamma

$$P(Y_s = y_s \mid X_s = x_s) = \frac{2L^L}{\Gamma(L)} \frac{y_s^{(2L-1)}}{\mu_{x_s}} \exp - \left( \frac{Ly_s^2}{\mu_{x_s}} \right)$$

- **régularisation**

Intéractions locales entre étiquettes : modèle de Potts, voisinage 8-connexe

- **distribution a posteriori : loi de Gibbs**

loi de Gibbs

$$\mathcal{U}(x_s \mid y, V_s) = L \frac{y_s^2}{\mu_{x_s}} - \log \mu_{x_s} - \beta \sum_{r \in \mathcal{V}_s} 1_{(x_s=x_r)}$$

- **optimisation : recuit simulé ou ICM**

## Exemple 2



## Exemple 3 : segmentation et fusion de données

- **position du problème**

$K$  = nombre de données (ou canaux)  $\Rightarrow$  vecteur d'attributs  $Y = (Y^1, \dots, Y^K)$

$M$  nombre de classes  $\Lambda = \{\lambda_1, \dots, \lambda_M\}$

- **attache aux données : indépendance des sources entre elles**

$$\begin{aligned} p(Y|X) &= \prod_{s \in S} P(Y_s|X_s) = \prod_{s \in S} P(\{Y_s^1, Y_s^2, \dots, Y_s^K\}|X_s) \\ &= \prod_{s \in S} P(Y_s^1|X_s) \dots P(Y_s^K|X_s) = \prod_{s \in S} \prod_{k=1}^K P(Y_s^k|X_s) \end{aligned}$$


$$\Rightarrow V((y_s^k)_k|\lambda) = \sum_k V(y_s^k|\lambda)$$

- **coefficients de confiance (fiabilité)  $C_{(k,\lambda)}$  : source  $k \rightarrow$  classe  $\lambda$**

$$V((y_s^k)_k|\lambda) = \frac{1}{(\sum_k C_{(k,\lambda)})} \sum_k C_{(k,\lambda)} V(y_s^k|\lambda)$$

## Méthode markovienne de fusion de données (suite)

- potentiels d'attache aux données  $V(y_s^k|\lambda)$  linéaires par morceaux



⇒ définition supervisée (histogramme, seuillage,...)

⇒ définition automatique (analyse multi-échelles de l'histogramme, recuit simulé sous contraintes...)

- coefficients de confiance  $C_{(k,\lambda)}$  du capteur  $k$  relativement au label  $\lambda$

= 0 si source  $k$  non significative pour  $\lambda$

= 0,5 si source  $k$  info. approximative

= 1 si source  $k$  pertinente pour  $\lambda$

## Méthode markovienne de fusion de données (suite)

- **terme contextuel : le champ des étiquettes est markovien**

$$U_{\text{context}}(x) = \sum_{c \in C} V_c(x_c)$$

- **connaissances a priori : matrice d'adjacence**  $(\gamma(\lambda_i, \lambda_j))_{i,j \in \{1, \dots, M\}}$

potentiel de régularisation :  $V_{c=(s,t)}(x_s, x_t) = \gamma(x_s, x_t)$


◇ adjacence interdite entre  $\lambda_1$  et  $\lambda_3 \Rightarrow \gamma(\lambda_1, \lambda_3) = +\infty$

◇ adjacence favorable entre  $\lambda_1$  et  $\lambda_2 \Rightarrow \gamma(\lambda_1, \lambda_2) = 0$


- **choix des paramètres** Méthode des boîtes qualitatives d'Azencott

comparaison des énergies locales dans des configurations “extrêmes”


## Classification multispectrale AVHR RNOAA zones glace



canal 1




canal 3



résultat

# Restauration d'images

## Loi du processus de formation des observations



- o **bruit blanc additif gaussien**

$$\left[ \begin{array}{l} y = x + \epsilon \qquad y_s = x_s + \epsilon_s \quad \forall s \in S \qquad \epsilon_s \rightarrow \mathcal{N}(0, \sigma^2) \\ \Pr(Y = y / X = x) = \prod_{s \in S} \Pr(Y_s = y_s / X_s = x_s) \propto \prod_{s \in S} \exp - \frac{(y_s - x_s)^2}{2\sigma^2} \end{array} \right.$$




# Loi du processus de formation des observations (suite)


- **convolution**

$$\left[ \begin{array}{l} y = h x + \epsilon \\ y_s = \sum_{r \in S} h_{rs} x_r + \epsilon_s \quad \forall s \in S \quad \epsilon_s \rightarrow \mathcal{N}(0, \sigma^2) \end{array} \right.$$

- flou de bougé isotrope uniforme



- flou de mise au point (gaussien)



## Débruitage d'image avec bruit blanc additif gaussien

$$\Pr(Y = y / X = x) = \prod_{s \in S} \Pr(Y_s = y_s / X_s = x_s) \propto \prod_{s \in S} \exp - \frac{(y_s - x_s)^2}{2\sigma^2}$$

- régularité de l'image réelle à niveaux de gris

$$\Pr(X = x) = \frac{\exp - \beta \sum_{(r,s) \in \mathcal{C}} \Phi(x_r, x_s)}{Z}$$

- nouvelle distribution de Gibbs  $\Pr(X = x / Y = y) = \frac{\exp - \mathcal{U}(x / y)}{Z'}$  !

$$\mathcal{U}(x / y) = \sum_{s \in S} \frac{(y_s - x_s)^2}{2\sigma^2} + \beta \sum_{(r,s) \in \mathcal{C}} \Phi(x_r, x_s)$$

$$\max_{x \in \Omega} \Pr(X = x / Y = y) \Leftrightarrow \min_{x \in \Omega} \mathcal{U}(x / y)$$

- régularisation  $\Phi(x_r, x_s) = \Phi((x_r - x_s)) = \Phi(u)$

## Débruitage d'image : choix de la fonction $\Phi$

- **régularisation quadratique**

champ gaussien

$$\Phi(u) = u^2$$

bonne régularisation des zones homogènes


dégradation des contours (flou)

- **suppression du lissage aux discontinuités**

- intuitivement : quadratique  $\Rightarrow$  quadratique tronquée

- introduction d'un processus bords

# Restauration avec prise en compte des discontinuités



## ○ processus bords $B$

$$B = (B_{st})$$

$b_{st} = 1$  en présence d'une discontinuité,  $b_{st} = 0$  sinon

## ○ champ a posteriori

$$P((X, B)|Y) = \frac{P(Y|(X, B))P(X, B)}{P(Y)} = \frac{P(Y|X)P(X, B)}{P(Y)}$$

## ○ énergie a priori

$$U(x, b) = \sum_{s,t} (1 - b_{st})(x_s - x_t)^2 + \gamma b_{st}$$

# Restauration avec prise en compte des discontinuités

- Minimisation de l'énergie en  $(x, b)$

$$\min_{(x,b)} U(x, b) = \min_x \sum_{s,t} \min_{b_{st}} f(x_s - x_t, b_{st})$$

$$\min_{(x,b)} U(x, b) = \min_x \tilde{U}(x)$$

$$\min_{b_{st}} f(x_s - x_t, b_{st}) = \phi(x_s - x_t)$$

modèle implicite  $\Leftrightarrow$  modèle explicite

(modèle de la membrane mince -*weak membrane*)

# Restauration avec prise en compte des discontinuités

- **exemples de fonctions de régularisation pour  $\phi(x_s - x_r)$**

Geman et Mac Clure 85  $\phi(u) = \frac{u^2}{1 + u^2}$

Hebert et Leahy 89  $\phi(u) = \log(1 + u^2)$

Charbonnier 94  $\phi(u) = 2\sqrt{1 + u^2} - 2$

- **conditions sur les fonctions  $\phi$**

1.  $\lim_{u \rightarrow 0^+} \frac{\phi'(u)}{2u} = 1$
2.  $\lim_{u \rightarrow +\infty} \frac{\phi'(u)}{2u} = 0$
3.  $\frac{\phi'(u)}{2u}$  est continue et strictement décroissante sur  $[0, +\infty[$

## Théorème

Soit :

$$\phi : [0, +\infty[ \rightarrow [0, +\infty[$$

$\phi(\sqrt{u})$  strictement concave sur  $]0, +\infty[$

et soit

$$L = \lim_{u \rightarrow +\infty} \frac{\phi'(u)}{2u} \quad \text{and} \quad M = \lim_{u \rightarrow 0^+} \frac{\phi'(u)}{2u}$$

Alors :

–  $\exists \psi$  strictement convexe et décroissante :  $[L, M] \mapsto [\alpha, \beta]$ , tel que :

$$\phi(u) = \inf_{L \leq b \leq M} (bu^2 + \psi(b))$$

$$\alpha = \lim_{u \rightarrow \infty} \phi(u) - u^2 \frac{\phi'(u)}{2u}, \quad \beta = \lim_{u \rightarrow 0^+} \phi(u) - u^2 \frac{\phi'(u)}{2u}$$

–


$$\forall u \quad b_u = \frac{\phi'(u)}{2u}$$

est la valeur unique pour laquelle l'infimum est atteint

# Restauration d'image : potentiel de Geman et Reynolds

- sa formulation

$$\beta \Phi(u) = \frac{-\beta}{1 + \left(\frac{u}{\delta}\right)^2}$$



- $\left\{ \begin{array}{l} \beta : \text{“Portée” du potentiel} \\ \delta : \text{“Amplitude” du potentiel} \end{array} \right.$

- $\Rightarrow$  choix de  $\beta$  et  $\delta$  : choix des paramètres



## Expression implicite et explicite

pour préserver les discontinuités il est strictement équivalent de minimiser

- **une expression explicite avec processus bords**

$$U(x, b|y) = \sum_s (y_s - x_s)^2 + \lambda \sum_{(r,s)} b_{rs} (x_s - x_r)^2 + \mu \sum_{(r,s)} \psi(b_{rs})$$

- **une expression implicite sans processus bords**

$$U(x|y) = \sum_s (y_s - x_s)^2 + \lambda' \sum_{(r,s)} \phi(x_s - x_r)$$

- **l'expression de  $b_{rs}$  pour l'équivalence est donnée par**

$$b_{rs} = \frac{\phi'(x_s - x_r)}{2(x_s - x_r)}$$

# Algorithmes de minimisation

- **GNC Graduated non convexity (Blake et Zisserman)**

- Principe : approximation du critère par une fonction convexe puis modification graduelle du critère
- algorithme déterministe
- preuves de convergence seulement dans certains cas

- **MFA Mean Field Annealing**

- processus bords explicite
- descente de température et approximation au sens du champ moyen
- estimation itérative du processus bords et de la solution

- **Artur et Legend**

- processus bords explicite
- calcul itératif du processus bords (expression analytique) puis à  $b$  fixé estimation de la solution  $x$  (descente de gradient)