

Méthodes stochastiques en analyse d'images

- Champs de Markov (MRF), méthodes paramétriques
- Analyse multi-résolution, ondelettes
- Méthodes semi et non paramétriques, réduction de dimension

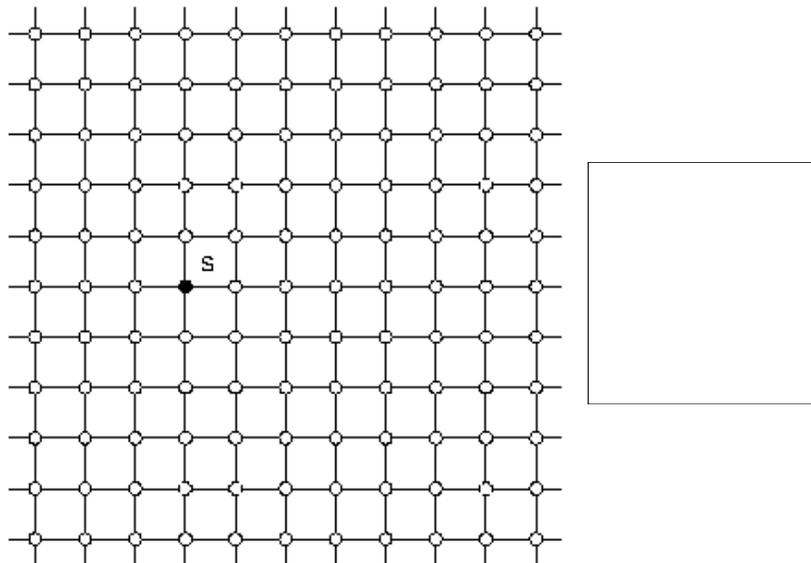
- Couplage: ex. Arbres de Markov sur coefficient d'ondelettes, etc.

Champs de Markov en analyse d'images

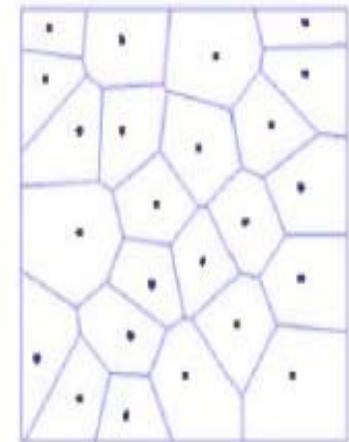
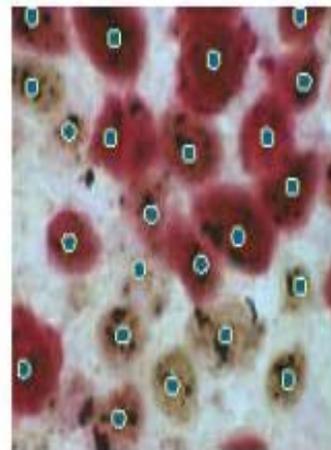
$$\forall z, \quad p(z_i \mid z_{\text{Sntfig}}) = p(z_i \mid z_j, i \in N(i))$$

$N(i)$: voisins de i

- Modéliser le contexte (spatial) et les interactions



Non indépendance des pixels

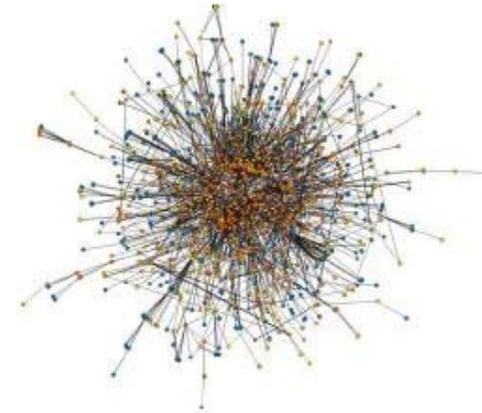
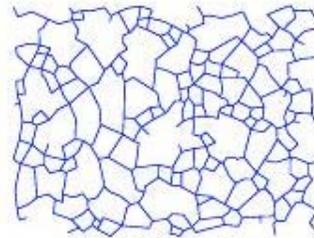
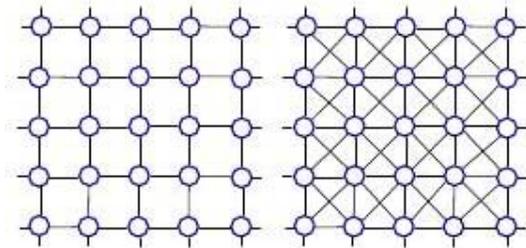


non indépendance des objets

Classification de données structurées

Objectif: Faire des groupes d'individus à partir d'observations

Hypothèses: Dépendances particulières entre les individus, définies à l'aide d'un graphe d'interactions



Noeuds = individus/sites

Aretes = interactions directes

Exemple: segmentation d'images



Classification **supervisée** : observations étiquetées (base d'apprentissage)

Classification **non supervisée**

Exemples d'applications

Images médicales

- Segmentation d'IRM du cerveau
- Détection des régions d'activation en IRMf
- Détection de tumeurs du sein (angio IRM)

Autres images

- Segmentation d'images satellitaires
- Reconnaissance de textures
- Reconnaissance d'objets

- **Utilisation bas niveau:**

restauration, segmentation, détection de contours

→ **MRF sur grilles régulières (pixels)**

- **Utilisation + haut niveau:**

reconnaissance d'objets, tracking, matching

→ **MRF sur graphes (points d'intérêt et descripteurs d'images)**

Modèles de mélanges pour la classification

Modèle génératif, décrit la formation des classes

$\mathbf{Z} = Z_1, \dots, Z_N$ les classes (1,..K) les observations $\mathbf{Y} = Y_1, \dots, Y_N$

Lois des classes a priori $P(z_i = k) = \pi_k$

Les individus (i=1,..N) sont **indépendants**

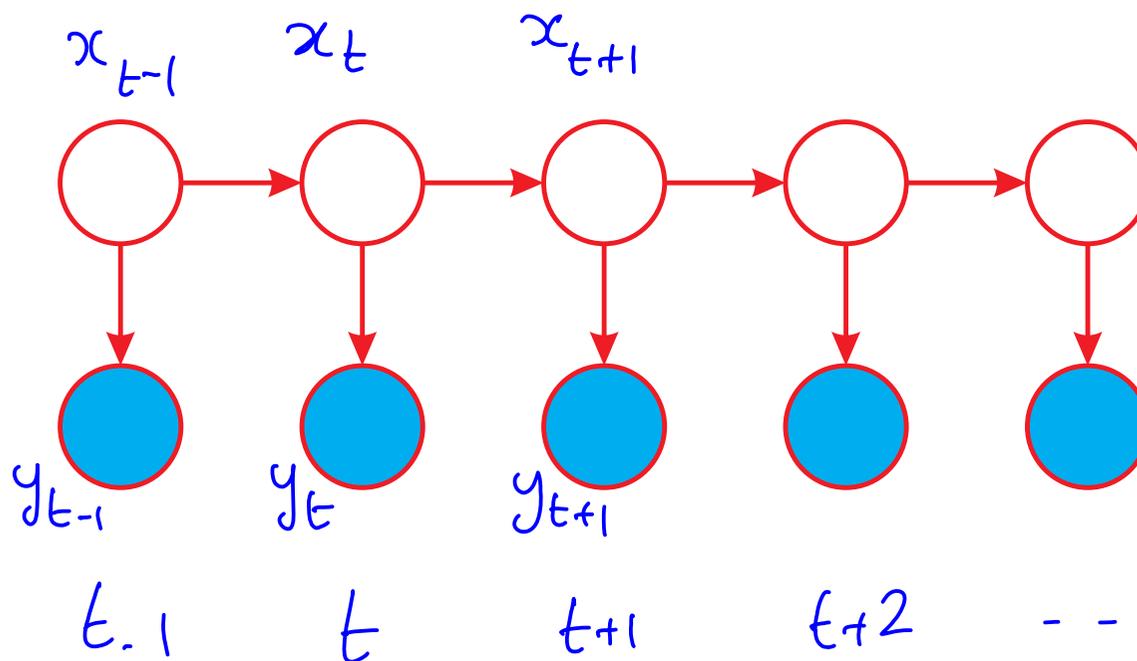
Les lois (multivariées) $P(y_i | z_i=k)$ dépendent de paramètres

ex. Mélange de gaussiennes $P(y_i | z_i = k) = \mathcal{N}(y_i | \mu_k, \sigma_k^2)$

Example 2: State Space Models

- Hidden Markov chain
- Kalman filter

$$--- p(x_t | x_{t-1}) p(y_t | x_t) p(x_{t+1} | x_t) ---$$



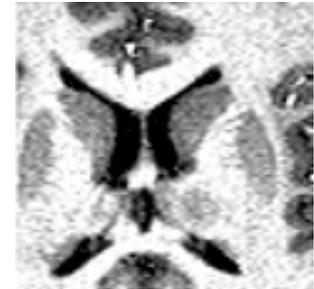
- Frequently wish to solve the problem of computing

$$P(x_t | y_1, \dots, y_n)$$

Modèle de Champ de Markov caché, interaction de paires

Observations : $\mathbf{Y} = Y_1, \dots, Y_N$ Etiquettes manquantes : $\mathbf{Z} = Z_1, \dots, Z_N$

Z champ de Markov : $z_i, P(z_i | \mathbf{Z}_{S \setminus i}) \quad \mathbf{Z}_{S \setminus i} \quad P(z_i | \mathbf{Z}_{N(i)}) \quad \mathbf{Z}_{N(i)}$



→ **Dépendance spatiale** entre les étiquettes qui permet une régularisation de la segmentation.

Un seul voxel gris au milieu d'un bloc blanc : peu de chance.

+ Hypothèse standard d'indépendance conditionnelle: $P(\mathbf{Y} | \mathbf{Z}) = \prod_i P(Y_i | Z_i)$

■ Segmenter l'image : Maximiser la probabilité :

$$p(\mathbf{z} | \mathbf{y}) = W^{-1} \exp \left(H(\mathbf{z} | \mathbf{y}) \right) \text{ avec } W = \exp \left(H(\mathbf{z} | \mathbf{y}) \right)$$

$$\text{avec } H(\mathbf{z} | \mathbf{y}) = \sum_{i=1}^N \left(\frac{1}{2} \sum_{j \in N(i)} \lambda_{ij} z_i z_j \right) + \sum_{i \in S} \log p(y_i | z_i)$$

Idée intuitive
pondère l'importance relative des différentes étiquettes au site

Régularisation spatiale

Terme d'attache aux données (Modèles d'intensités gaussiens)

avec $\mathbf{y} = (y_1, \dots, y_N)$, $\mathbf{z} = (z_1, \dots, z_N)$, $i \in \{1, \dots, N\}$, R^K

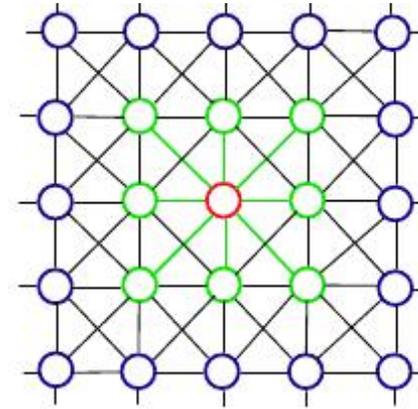
Modèle de Potts et généralisations

Définition : \mathbf{Z} est un champ de Markov ssi

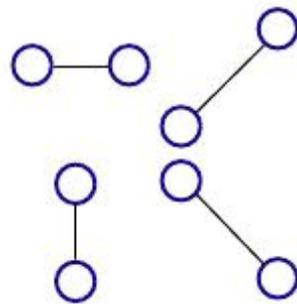
$$\forall \mathbf{z}, \forall i, P(z_i | \mathbf{z}_{\mathcal{I} \setminus i}) = P(z_i | \mathbf{z}_{N_i})$$

$\Leftrightarrow \mathbf{Z}$ suit une distribution de Gibbs :

$$P_G(\mathbf{z}) = W^{-1} \exp\left(\sum_{i \sim j} V(z_i, z_j)\right)$$



en supposant les potentiels homogènes et isotropes.



modèle de Potts:

$$V(k, k') = \beta \delta_{k=k'}$$

Paramètres = matrice symétrique $\mathbb{V} = (V(k, k'))_{k, k' \in \mathcal{K}}$

$V(k, k') \approx$ coefficient de compatibilité entre les classe k et k'



W ne peut être calculé.

Des approximations sont nécessaires.

Un problème de vision (incertitude, contraintes spatiales)



un problème d'optimisation

3 piliers (critiques) d'une approche par MRF

- **Modélisation (choix de modèles:** modele de bruit, distributions des classes, nombre de classes, dimensions Intrinseques...)
- **Estimation des paramètres:** en presence de donnees manquantes
- **Méthodes d'optimisation:** algorithmes d'inference, approximations...

Classification non supervisée (paramètres inconnus)

Approche *image*: objectif classification

Méthodes de classification (segmentation) supervisée adaptées au cas
des paramètres inconnus \longrightarrow *Classifications dures*

mises à jour itérativement, alternées avec une étape d'estimation des paramètres

Ex: recuit simulé, ICM, etc...

Approche *mélange*: objectif estimation des paramètres

Classification vue comme un problème à données manquantes

\longrightarrow *Classifications floues* (probabilités d'être dans chaque classe)

Algorithme EM et variantes

Richesses et points positifs du modèle de champ de Markov caché

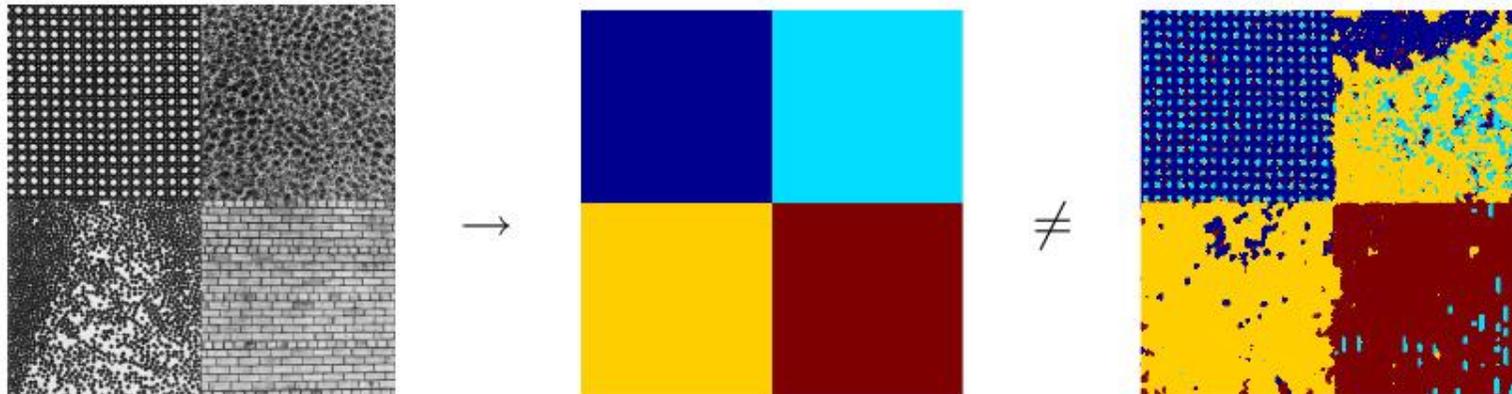
- Champ de Markov
 - Intégration de connaissances a priori : eg. champ externe
 - Régularisation spatiale: interaction de paires (fusion d'information)
 - Techniques d'inférences: algorithmes divers et variés
- Mélanges
 - Modèles gaussiens pour la grande dimension
 - Détection de outliers, classes supplémentaires
 - S'adapte au cas d'observations manquantes
 - Classification *probabiliste*, Interprétation simple
- **Limites principales**
 - Indépendance conditionnelle: bruit trop simple
 - Distributions gaussiennes unimodales
 - Hypothèse de classes non chevauchantes

Modèles de Markov Triplets

Le modèle de champ de Markov caché à bruit indépendant suppose :

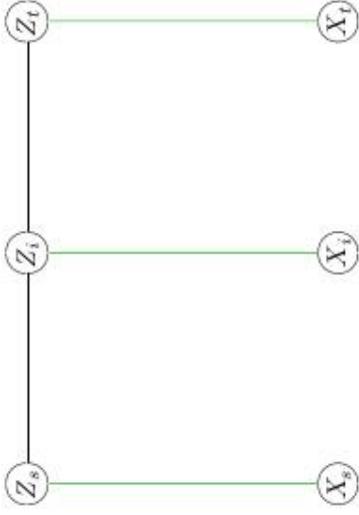
(A) \mathbf{Z} est un champ de Markov

(B) Le bruit est indépendant : $P(\mathbf{x}|\mathbf{z}) = \prod_{i \in \mathcal{I}} P(x_i|z_i)$



On va chercher à relâcher l'hypothèse de bruit indépendant (B).

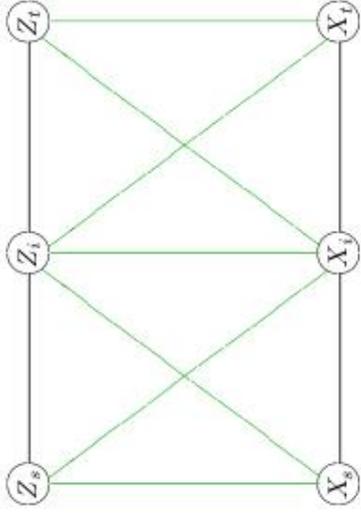
Remarque : En pratique dans les algorithmes, l'hypothèse (A) n'est pas nécessaire puisque seule est utilisée la markovianité de $\mathbf{Z}|\mathbf{X} = \mathbf{x}$ (et non directement celle de \mathbf{Z}).



(\mathbf{X}, \mathbf{Z}) est un champ de Markov caché à bruit indépendant

(A) \mathbf{Z} est markovien

$$(B) P(\mathbf{x}|\mathbf{z}) = \prod_{i \in \mathcal{I}} P(x_i|z_i)$$



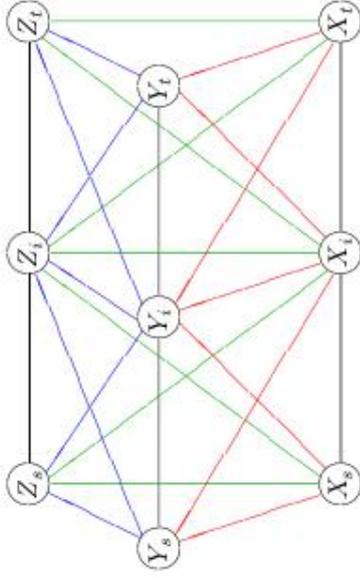
(\mathbf{X}, \mathbf{Z}) est un **champ de Markov couple** si sa distribution est markovienne :

$$P_G(\mathbf{x}, \mathbf{z}) \propto \exp\left(\sum_{c \in \mathcal{C}} V_c(\mathbf{x}_c, \mathbf{z}_c)\right)$$

Ajout d'un champ auxiliaire $\mathbf{Y} = (Y_i)_{i \in \mathcal{I}}$ discret, $Y_i \in \mathcal{L}$

$(\mathbf{X}, \mathbf{Y}, \mathbf{Z})$ est un **champ de Markov triplet** si sa distribution est markovienne :

$$P_G(\mathbf{x}, \mathbf{y}, \mathbf{z}) \propto \exp\left(\sum_{c \in \mathcal{C}} V_c(\mathbf{x}_c, \mathbf{y}_c, \mathbf{z}_c)\right)$$



Classes chevauchantes

Un individu dans plusieurs classes à la fois

→ Pertinence dans les applications

- Problème de résolution (eg. Volume Partiel en IRM)
- Multi-fonctionnalité/genre (eg. Classification de gènes, films)

→ Modèles de mélanges plus généraux

- Astuce de modélisation
- Différents des méthodes de seuillage de probabilités

→ Voir les fuzzy MRFs....

Réduction de dimension

Nouveaux modèles gaussiens de données de grande dimension pour la classification

- Discrimination: ref Bouveyron &al HDDA
- Clustering: ref Bouveyron &al HDDC

- Réduction de dimension et interactions spatiales [Blanchet &al]

- Autres modèles (non gaussiens): ACP généralisée [ref SG]

Détection de données aberrantes

Contexte mélanges:

- Ajout d'une ou plusieurs classes (eg. Uniforme)
- Mélange de lois de student (queues lourdes)

M-estimateurs

Méthodes de Trimming...

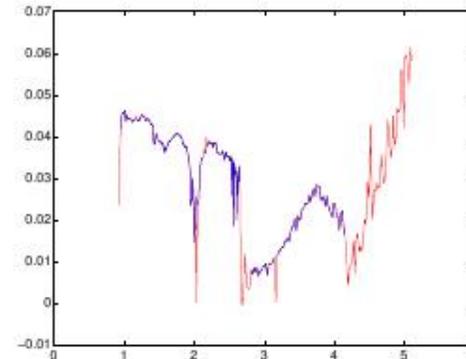
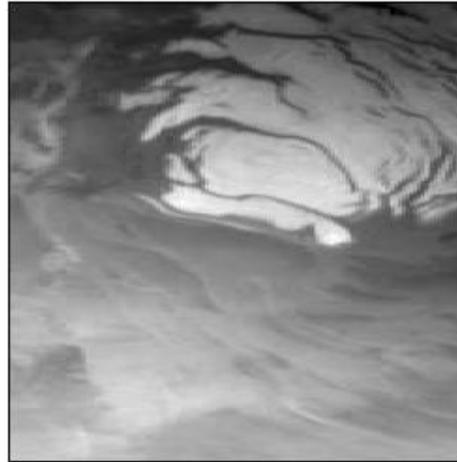
Nombreuses applications: IRM, télédétection, génomique, vision...

Etat de l'art à faire....

Cas d'observations manquantes

Certaines observations sont **manquantes** :

- elles n'ont pas pu être observées.
Ex : sondé ne répondant pas à une question
- elles sont incohérentes.
Ex : spectres de Mars Express (Labo. de Planétologie de Grenoble)



Objectif : classer les individus à partir d'observations incomplètes et du graphe d'interaction.

Se ramener à des observations complètes...

- suppression des vecteurs d'observations incomplets
- imputation : remplacer les observations manquantes par une valeur "raisonnable" (zéro, moyenne, k-plus proches voisins...)

... puis classer les individus à partir des observations complétées.

→ Ne tient compte ni de l'incertitude sur les valeurs imputées, ni du graphe, ni de l'objectif de classification.

→ Modifie les relations entre les observations (sous-estime la variabilité).

Approche probabiliste ne nécessitant pas
le remplacement préalable
des valeurs manquantes

Conclusion: Pistes de recherche

- Sources de complexité des données:
 - Grande dimension
 - Modèles d'interactions et de bruit
 - Observations manquantes
- Nature des classifications
 - Probabilistes: mesure de confiance, combinaison de modèles et d'estimateurs
 - Classes chevauchantes
 - Classe de données atypiques
- Choix de Modèles:
 - quel modèle de classification? modèle de bruit, distributions des classes, nombre de classes, dimensions intrinsèques...

- Mélange indépendant :

$$P(\mathbf{x}, \mathbf{z}) = \prod_{i \in \mathcal{I}} \pi_{z_i} f(x_i | \theta_{z_i})$$

- Champ de Markov caché :

$$P(\mathbf{x}, \mathbf{z}) \propto \exp(c \sum_{i \sim j} 1_{z_i = z_j}) \times \prod_{i \in \mathcal{I}} f(x_i | \theta_{z_i})$$

- Mélange de mélange indépendant :

$$P(\mathbf{x}, \mathbf{y}, \mathbf{z}) = \prod_{i \in \mathcal{I}} \lambda_{y_i z_i} \pi_{z_i} f(x_i | \theta_{y_i z_i})$$

- Champ de Markov triplet :

$$P_G(\mathbf{x}, \mathbf{y}, \mathbf{z}) \propto \exp\left(\sum_{i \sim j} [B_{z_i z_j}(y_i, y_j) + c] 1_{z_i = z_j}\right) \times \prod_{i \in \mathcal{I}} f(x_i | \theta_{y_i z_i})$$

où f est gaussienne de matrice de covariance diagonale ou paramétrée pour la grande dimension [Bouv07]

Approche et spécificités

- **Originalité:**

Stratégie de modélisation statistique qui repose sur la notion de **structure** dans

- **les systèmes/phénomènes complexes:** modélisation, interprétation
- **les modèles:** estimation, sélection, techniques d'approximation
- **les données:** réduction de dimension, analyse de données non linéaire

Etude théorique et pratique des méthodes:

- **qualité** des approximations,
- **comportement asymptotique** des estimateurs,
- **convergence** des algorithmes

- **Pertinence:** Couplage modèles/données, **au-dela des modèles statistiques traditionnels**