


Chaire Informatique et sciences numériques



2. Se repérer dans les images médicales

Recalage et segmentation

Nicholas Ayache

6 mai 2014

Collège de France



Le patient numérique personnalisé
Images, médecine et informatique




**COLLÈGE
DE FRANCE**
—1530—


- 29 avril 2014 **Sciences des images médicales : les grandes classes de problèmes + recalage**
Chirurgie du futur guidée par l'image numérique, Jacques Marescaux, *IHU Strasbourg, IRCAD*
Cardiologie du futur à l'ère du patient numérique, Michel Haïssaguerre, *CHU Bordeaux, Université Victor-Segalen, IHU LIRYC*
- 6 mai 2014 **Se repérer dans les images : recalage et segmentation**
Mesurer le cerveau numérique, Jean-François Mangin, *Neurospin Saclay*
Reconstruction d'organes dans les formes, Hervé Delingette, *Inria, Sophia Antipolis*
- 13 mai 2014 **Variabilité anatomique et fonctionnelle : atlas statistiques**
Phénotype, fonction et génotype, Bertrand Thirion, *Inria Saclay Île-de-France, CEA, DSV, I2BM, Neurospin*
Statistiques de formes et variétés anatomiques, Xavier Pennec, *Inria Sophia Antipolis*
- 20 mai 2014 **La dimension temporelle : quantifier une évolution**
La neuro-imagerie à l'ère du patient numérique, Stéphane Lehericy, *IHU Pitié Salpêtrière*
Biomarqueurs d'imagerie dans les pathologies cérébrales, Christian Barillot, *CNRS, Inserm, Inria Rennes*
- 27 mai 2014 **Imagerie des tumeurs : modèles biophysiques pour mesurer et prédire**
Neurochirurgie guidée par l'image, Emmanuel Mandonnet, *Hôpital Lariboisière*
Radiothérapie guidée par l'image, Jocelyne Troccaz, *TIMC Grenoble, CNRS*
- 03 juin 2014 **Imagerie microscopique in vivo : mosaïques numériques et indexation**
Les enjeux médicaux de l'endomicroscopie, Stanislas Chaussade, *Hôpital Cochin*
Des étoiles aux cellules, de la recherche à l'entreprise, Sacha Loiseau, *Mauna Kea Technologies*
- 10 juin 2014 **Le cœur numérique personnalisé : diagnostic, pronostic et thérapie**
Images et signaux cardiaques : état de l'art et futur, Pierre Jaïs, *CHU Bordeaux, Université Victor-Segalen, IHU LIRYC*
Vers un système vasculaire numérique, Jean-Frédéric Gerbeau, *Inria UPMC*
- 17 juin 2014 **Réalité virtuelle, simulation, et perspectives**
Réalité augmentée en endoscopie et chirurgie, Luc Soler, *IRCAD/IHU, Strasbourg*
Simulation en médecine : présent et futur, Stéphane Cotin, *Inria*

La segmentation: c'est quoi?

- Extraire les *frontières* ou *contours* des structures anatomiques ou pathologiques pour révéler leur *forme géométrique*
- Une étape nécessaire pour guider
 - détection
 - quantification
 - interprétation
 - simulation




Apparence et forme





Des intensités aux formes



L. Soler, Visible Patient

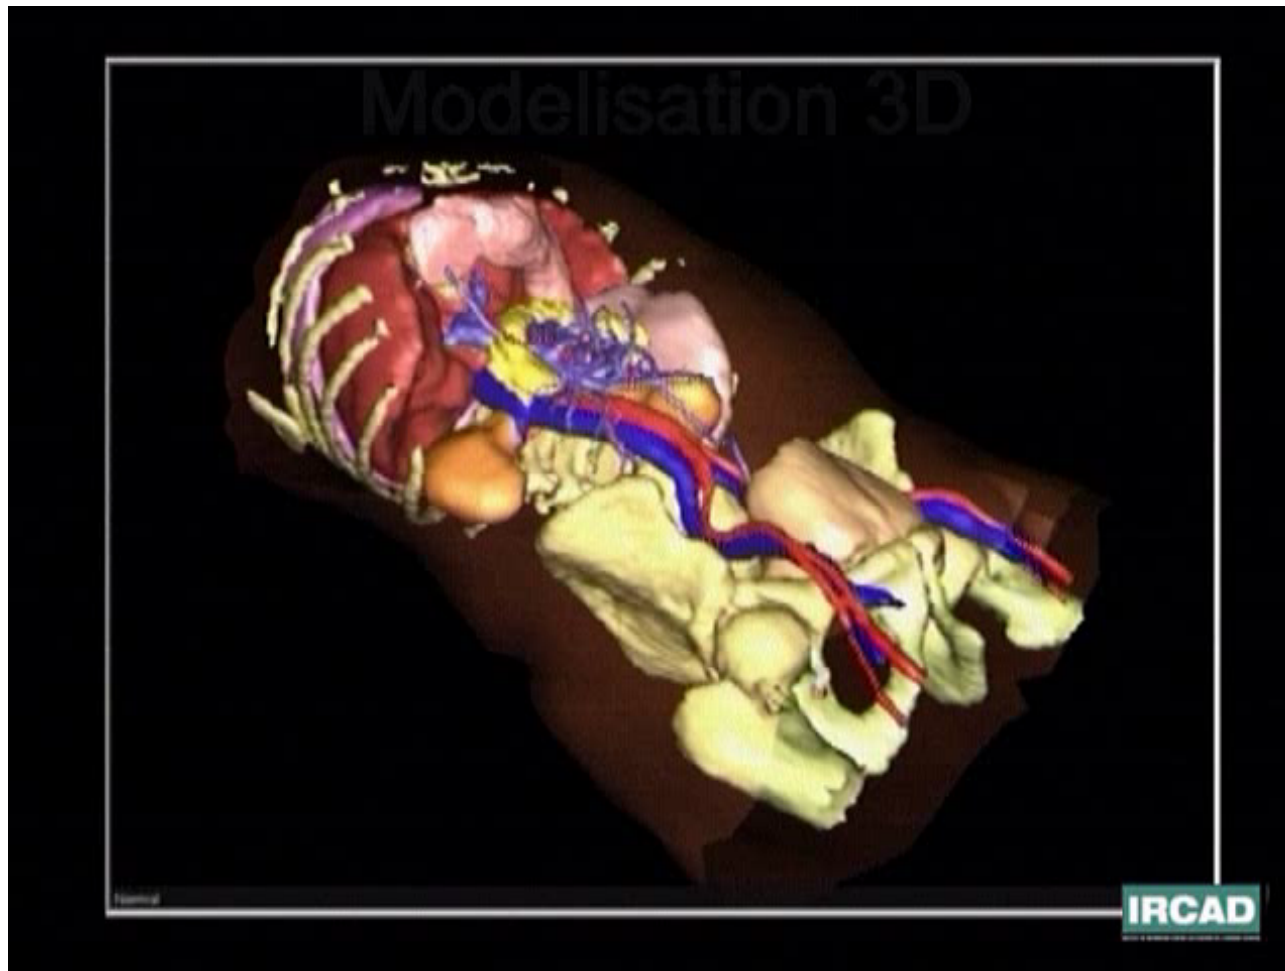
Nicholas Ayache
6 Mai 2014

Le patient numérique personnalisé
Images, médecine & informatique



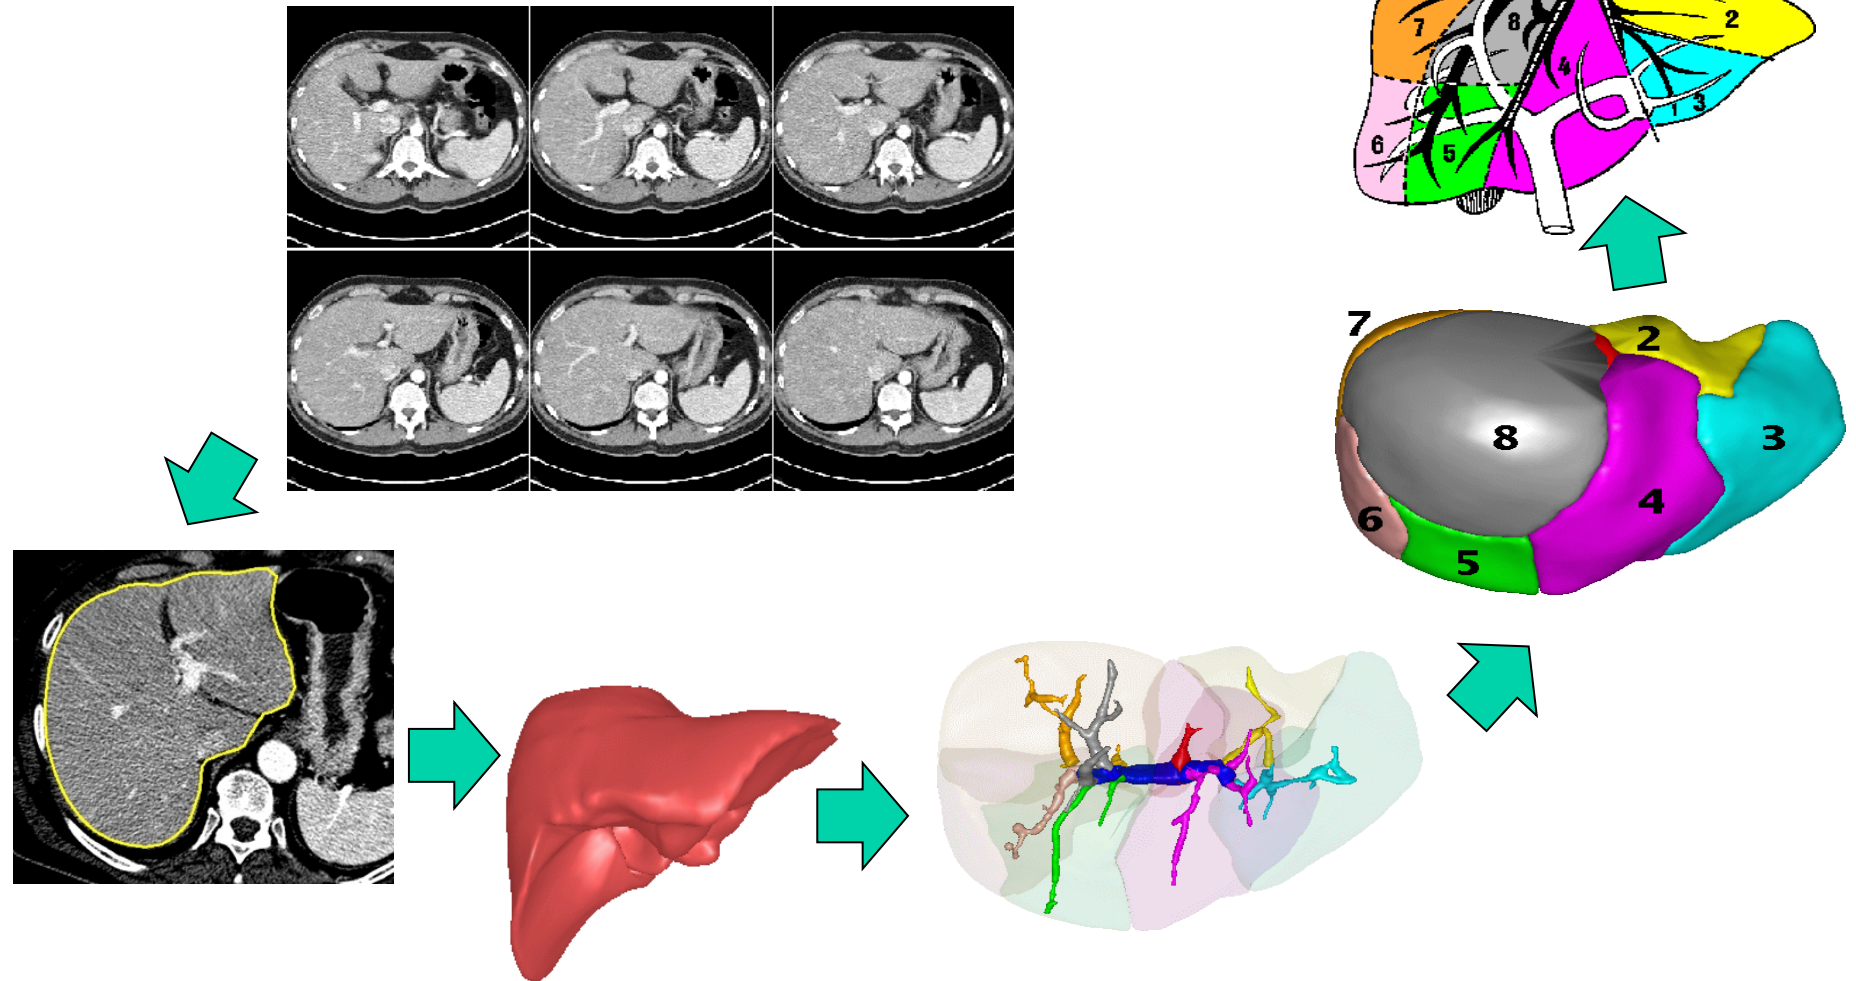
COLLÈGE
DE FRANCE
—1530—

Des intensités aux formes



L. Soler, Ircad

Des intensités aux formes et à l'interprétation



L Soler, H Delingette, G Malandain, J Montagnat, N Ayache, C Koehl, O Dourthe, B Malassagne, M Smith, D Mutter, and J Marescaux. Fully automatic anatomical, pathological, and functional segmentation from CT scans for hepatic surgery. *Comput Aided Surg*, 6(3):131-42, 2001.


Quelques algorithmes clefs

- Approche bayésienne
 - Algorithme E/M
- Apprentissage automatique
 - Algorithme des forêts aléatoires
- Recalage multi-atlas
 - Algorithme STAPLE


Un exemple didactique

- Extraire les principales classes de tissus cérébraux dans une IRM




coronal



sagittal




axial



Van Leemput 2013

Segmentation Manuelle




Une semaine pour un expert


Puonti, Iglesias, Van Leemput 2013

Segmentation automatique : difficultés

- L'intensité varie au sein d'une même classe
- Les intensités se chevauchent entre les classes




Coupes Axiales IRM



Seuillage : pas possible

Segmentation automatique


- Premier objectif :
 - segmenter en 3 classes principales



Matière blanche (MB), matière grise (MG), liquide céphalo rachidien (LCR)

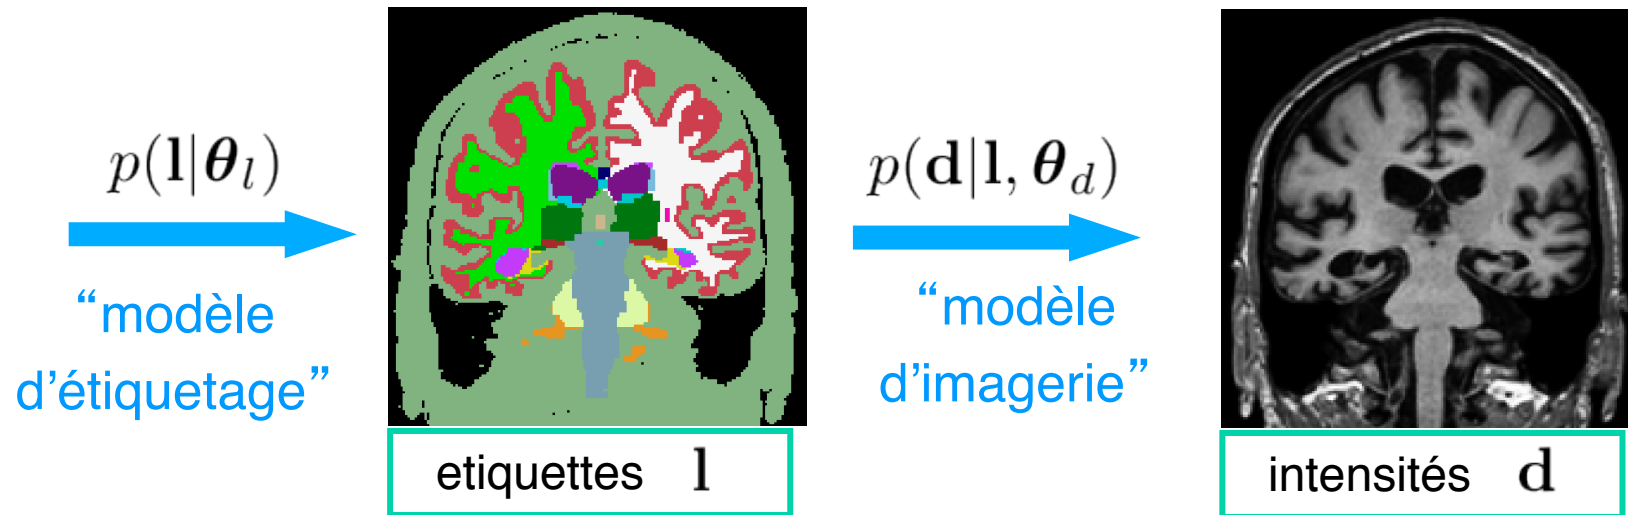
Article fondateur : [K Van Leemput, F Maes, D Vandermeulen, P Suetens](#)
[Automated model-based tissue classification of MR images of the brain](#)
[IEEE Transactions on Medical Imaging, 1999](#)

Une approche bayésienne




- On considère deux modèles statistiques :
 - Un modèle **d’étiquetage spatial** qui assigne à chaque voxel une classe de tissus selon une loi probabiliste
 - Un modèle **de formation d’image** qui assigne à chaque étiquette une intensité selon une loi probabiliste

Paramètres cachés




- Les modèles dépendent de paramètres: $\boldsymbol{\theta} = (\boldsymbol{\theta}_l^T, \boldsymbol{\theta}_d^T)^T$
- Les valeurs réelles $\hat{\boldsymbol{\theta}}$ sont cachées

Segmentation : un problème inverse



- Passer des intensités d aux étiquettes l

Maximiser les probabilités



Intensités \mathbf{d}




Étiquettes $\hat{\mathbf{l}}$

$$\hat{\mathbf{l}} = \arg \max_{\mathbf{l}} p(\mathbf{l}|\mathbf{d}, \hat{\boldsymbol{\theta}})$$

- La probabilité $p(\mathbf{l}|\mathbf{d}, \hat{\boldsymbol{\theta}})$ est donnée par la loi de Bayes

$$p(\mathbf{l}|\mathbf{d}, \hat{\boldsymbol{\theta}}) = \frac{p(\mathbf{d}|\mathbf{l}, \hat{\boldsymbol{\theta}}_d)p(\mathbf{l}|\hat{\boldsymbol{\theta}}_l)}{p(\mathbf{d}|\hat{\boldsymbol{\theta}})}$$

Maximiser les probabilités



Intensités \mathbf{d}



Etiquettes $\hat{\mathbf{l}}$

$$\hat{\mathbf{l}} = \arg \max_{\mathbf{l}} p(\mathbf{l}|\mathbf{d}, \hat{\boldsymbol{\theta}})$$

- La probabilité $p(\mathbf{l}|\mathbf{d}, \hat{\boldsymbol{\theta}})$ est donnée par la loi de Bayes

Modèle imagerie


Modèle étiquetage

$$p(\mathbf{l}|\mathbf{d}, \hat{\boldsymbol{\theta}}) = \frac{p(\mathbf{d}|\mathbf{l}, \hat{\boldsymbol{\theta}}_d) p(\mathbf{l}|\hat{\boldsymbol{\theta}}_l)}{p(\mathbf{d}|\hat{\boldsymbol{\theta}})} = \sum_{\mathbf{l}} p(\mathbf{d}|\mathbf{l}, \hat{\boldsymbol{\theta}}_d) p(\mathbf{l}|\hat{\boldsymbol{\theta}}_l)$$

Les modèles considérés

- Le modèle **d'étiquetage spatial** provient d'un atlas statistique construit à partir d'un grand nombre d'images segmentées
- Le modèle **de formation d'image** est un modèle de mélange gaussien (*Gaussian Mixture Model*) dont moyennes et covariances dépendent du tissu et du protocole d'acquisition

Atlas statistique





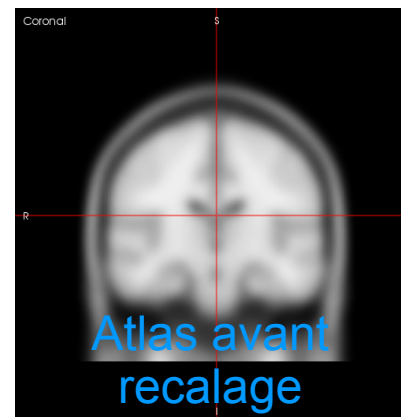




- En chaque voxel : probabilité *a priori* d'observer une classe de tissus.
- Moyenne d'un grand nombre de segmentations MG, MB, LCR après normalisation spatiale (recalage affine du référentiel atlas)

Source: *Montreal Neurological Institute*

Recalage de l'atlas

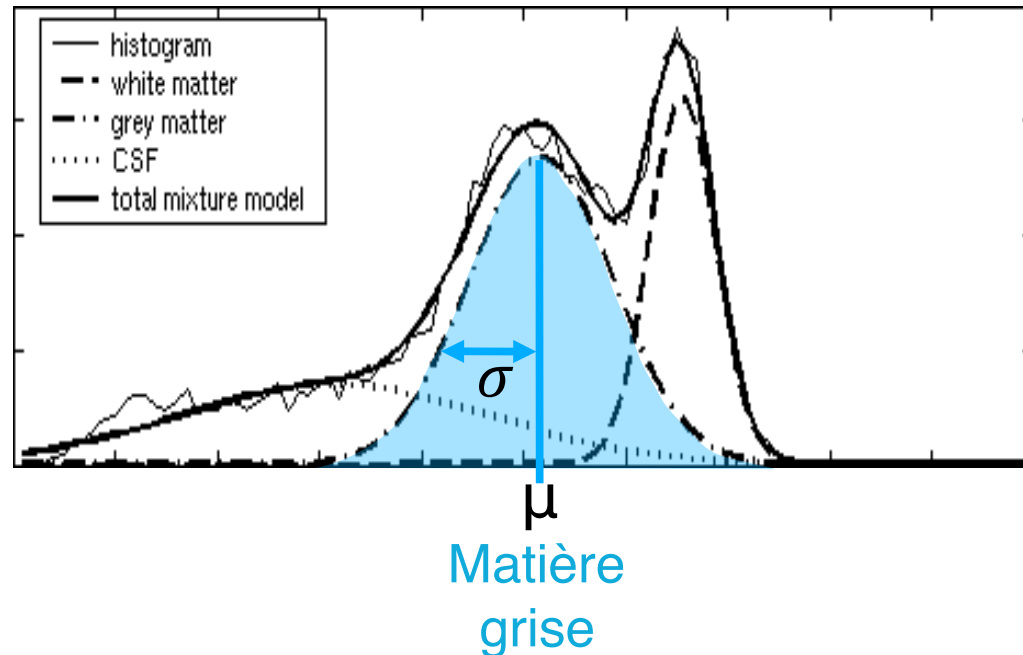
- Recalage iconique affine, information mutuelle



K. Van Leemput 2003

Modèle d'imagerie

Modèle de mélange gaussien




- Moyenne μ
- Variance σ

$$\mathcal{N}(d|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{(d - \mu)^2}{2\sigma^2} \right]$$

L'algorithme EM

[Dempster et al., 1977]

- Algorithme Espérance-Maximisation (*Expectation-Maximisation*)
 - *Optimise itérativement la vraisemblance des paramètres des modèles*



Connaissant les modèles de mélange gaussien

- **Espérance** : classification probabiliste

Connaissant la classification probabiliste

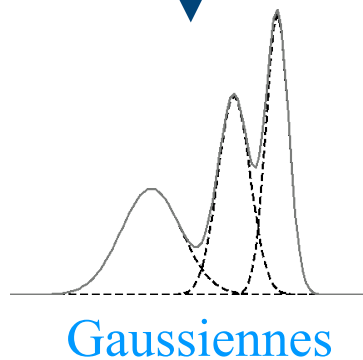

- **Maximisation** : optimiser mélange gaussien



Maximisation

à partir des classifications probabilistes de chaque voxel

Optimiser paramètres des mélanges gaussiens



Nouveaux paramètres
de la classe k

$$\tilde{\mu}_k \leftarrow \frac{\sum_n w_k^n d_n}{\sum_n w_k^n}$$

$$\tilde{\sigma}_k^2 \leftarrow \frac{\sum_n w_k^n (d_n - \tilde{\mu}_k)^2}{\sum_n w_k^n}$$

Nouvelle probabilité
de la classe k

$$\tilde{\pi}_k \leftarrow \frac{\sum_n w_k^n}{N}$$

K. Van Leemput 2003

Nicholas Ayache
6 Mai 2014

Le patient numérique personnalisé
Images, médecine & informatique




COLLÈGE
DE FRANCE
—1530—

23


Espérance

à partir de l'estimation des mélanges gaussiens de l'intensité

Classification probabiliste des voxels (Bayes)



IRM



Gaussiennes

$$p(l_n | d_n, \theta) \propto \mathcal{N}(d_n | \mu_{l_n}, \sigma_{l_n}^2) \pi_{l_n}$$




classification

Classification « soft » :

Conserver probabilités
pour chaque classe en
chaque voxel

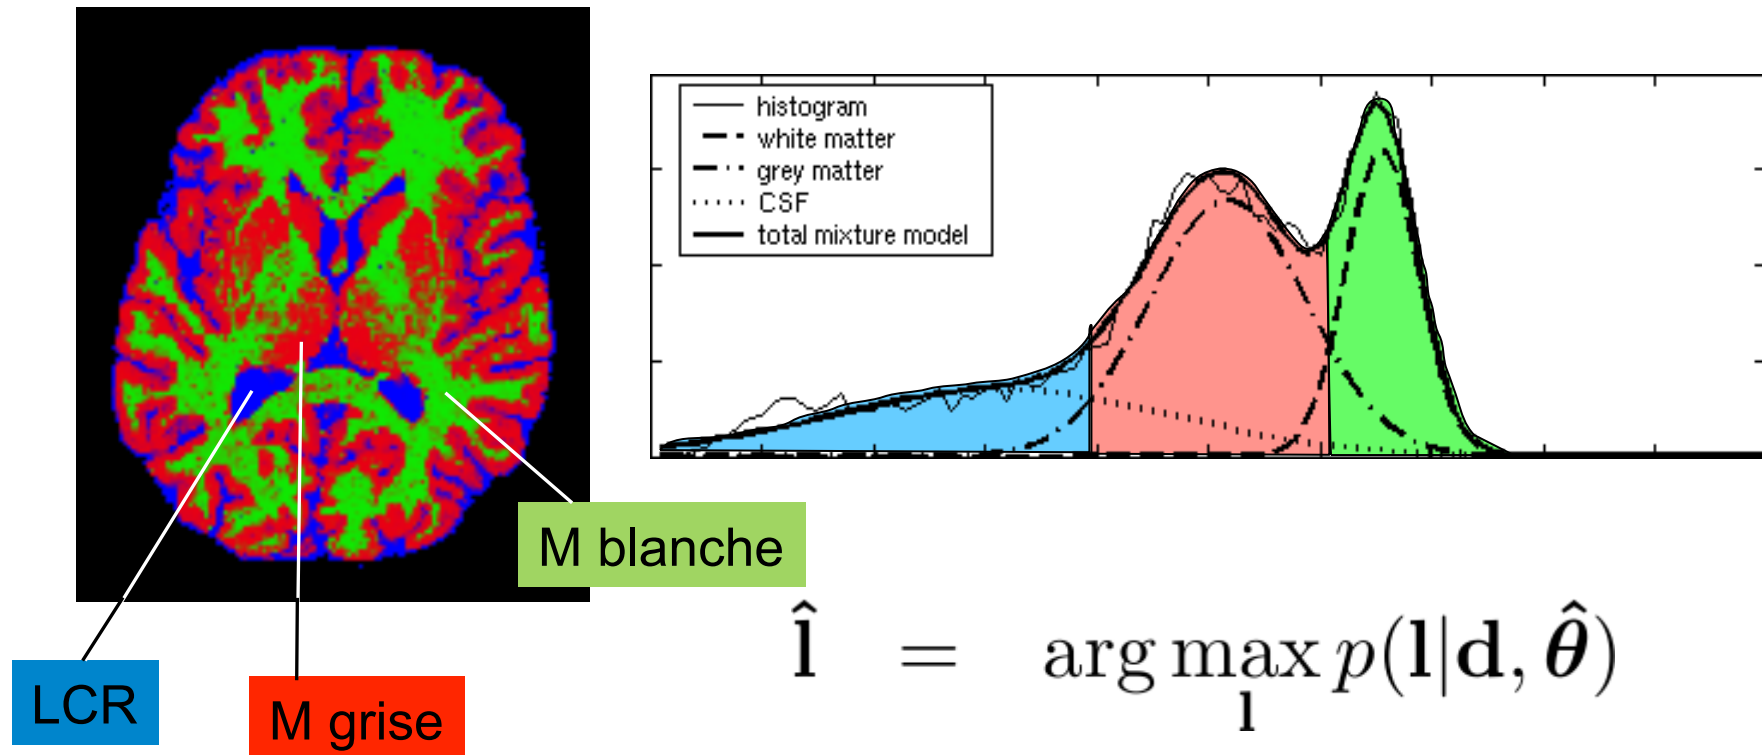
K. Van Leemput 2003

Itérations EM




Segmentation finale

On classe chaque voxel dans la classe la plus probable




Inhomogénéités du gain

- Gain multiplicatif variable qui entraîne des erreurs de segmentation





Estimation du gain



On impose un
modèle
paramétrique de
gain multiplicatif :
bases de fonctions
régulières (splines
ou trigonométriques)

Ceci garantit **une grande régularité spatiale**


EM à trois étapes



M2 : Correction gain



E: Classification probabiliste



M1 : Correction mélanges gaussiens

K. Van Leemput 2003

Le patient numérique personnalisé
Images, médecine & informatique




COLLÈGE
DE FRANCE
—1530—

M2 : correction du gain


Le gain est estimé en comparant les intensités prédites aux intensités réelles pour les classes de tissus ayant le plus petit écart-type. Il est extrapolé aux régions voisines




Classification



Mélanges gaussiens




IRM prédite



IRM réelle

-



Correction gain


Résultat

IRM

Matière blanche
sans correction du gain


avec correction du gain

Gain multiplicatif estimé




K. Van Leemput 2003

Correction gain




sans
correction




Matière blanche

Matière grise



avec
correction




K. Van Leemput 2003

Extensions EM

- Optimiser simultanément étiquetage *et* recalage de l'atlas statistique
- Introduire plusieurs atlas pour mieux prendre en compte la variabilité anatomique
- Davantage de classes (40+)

Iglesias-Puonti-Sabuncu-Van Leemput 2013


Etat de l'art (2013)



Iglesias-Puonti-Sabuncu-Van Leemput 2013

Images multi séquences

- L'algorithme EM peut être étendu à des images multi séquences (à recalcr soigneusement)
 - Un voxel a plusieurs intensités (intensité vectorielle)
 - On généralise le modèle probabiliste d'imagerie à des **gaussiennes multivariées**



IRM T2

IRM DP

IRM T1




IRM T2 FLAIR

Détection de lésions

- Les lésions correspondent à des intensités vectorielles \mathbf{i} peu probables dans les classes de tissus sains
- On les détecte avec un seuil sur la distance de Mahalanobis appliquée à chaque classe (μ, Σ)

$$(\mathbf{i} - \mu)^t \Sigma^{-1} (\mathbf{i} - \mu)$$



- Difficulté: les volumes partiels sont parfois pris pour des lésions



G Dugas-Phocion, MA González Ballester, G Malandain, C Lebrun, N Ayache. Improved EM-Based Tissue Segmentation and Partial Volume Effect Quantification in Multi-Sequence Brain MRI. MICCAI'04


Volumes partiels

- Hypothèse : $I_p = \alpha I_1 + (1 - \alpha)I_2$



**M. A. González Ballester, A. Zisserman, and M. Brady, 'Estimation of the partial volume effect in MRI'.
Medical Image Analysis, vol 6, no 4, pp 389-405, 2002.**

Histogrammes conjoints




Matière grise Matière blanche

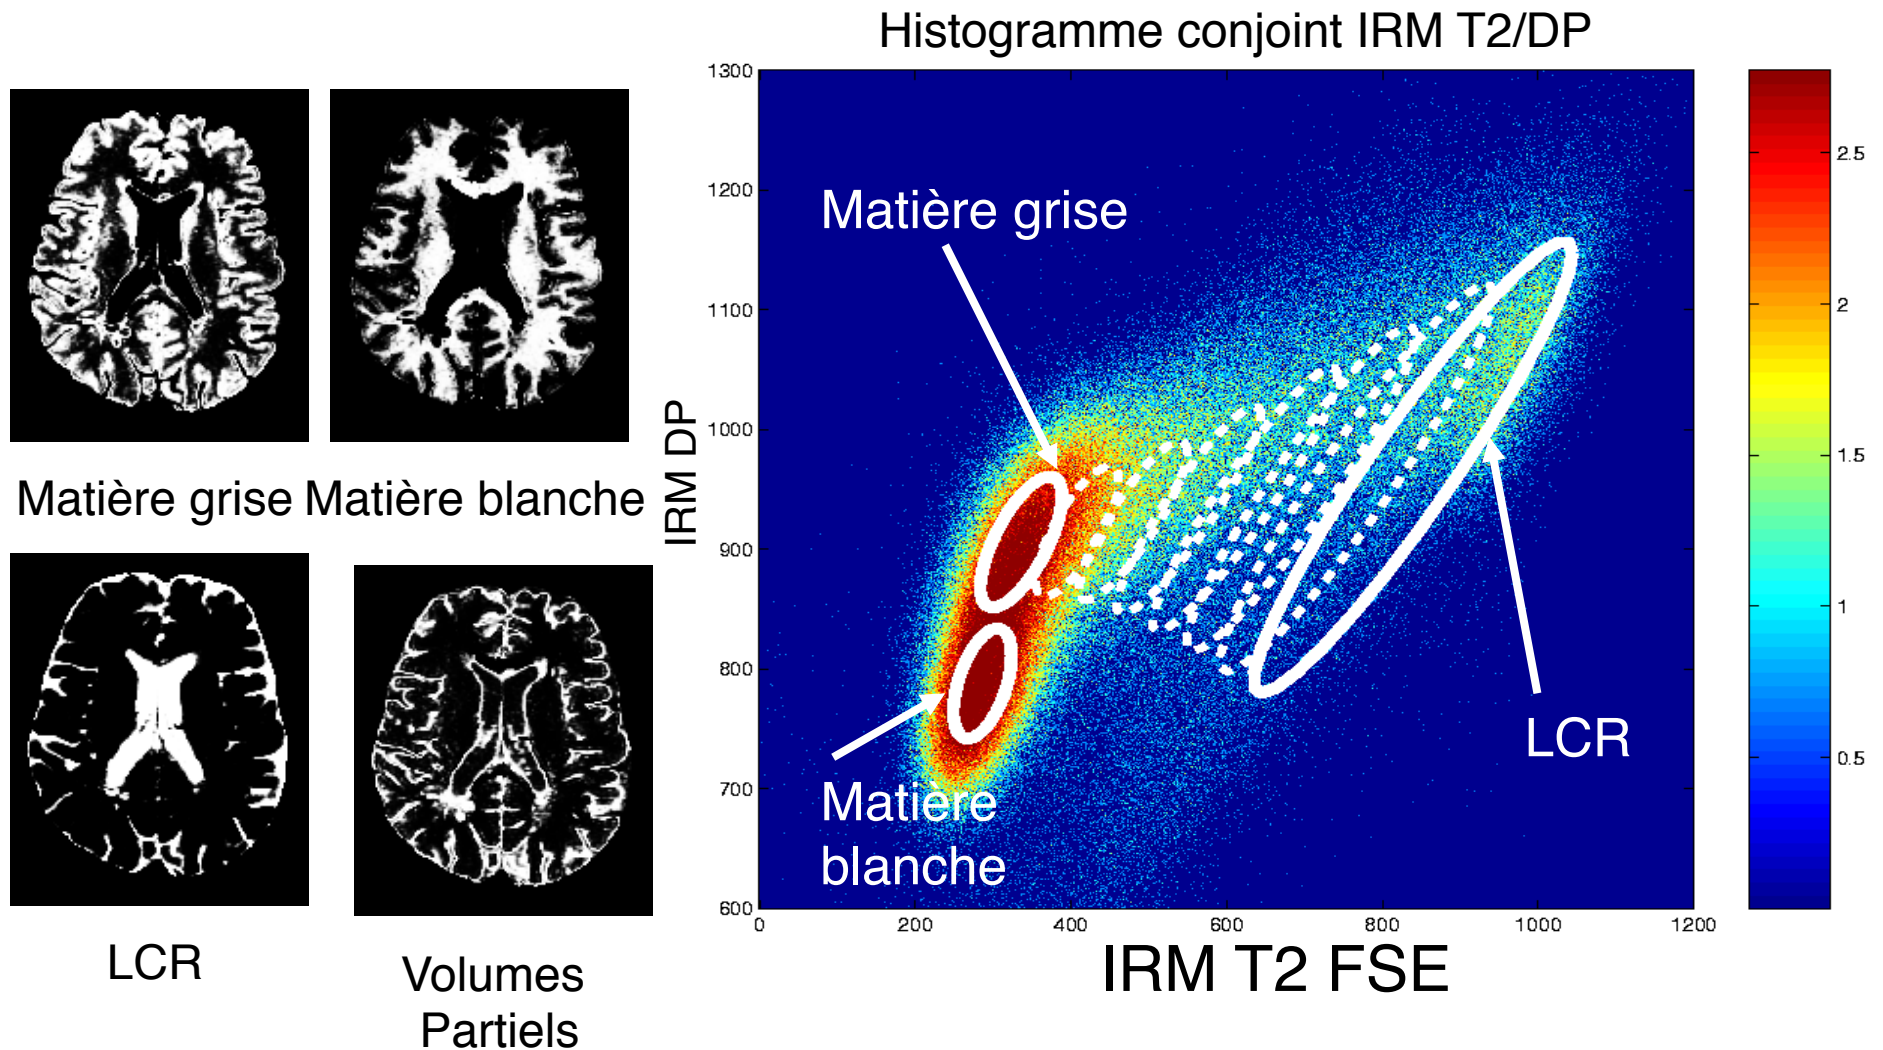


LCR

Histogramme conjoint IRM T2/DP




Histogrammes conjoints



Segmentation de lésions SEP

- Intensités « hors classe »



IRM DP

Lésions
(Seg. Auto)

Lésions
(Seg. Manuelle)

IRM T1

G Dugas-Phocion, MA González Ballester, G Malandain, C Lebrun, N Ayache. Improved EM-Based Tissue Segmentation and Partial Volume Effect Quantification in Multi-Sequence Brain MRI. MICCAI'04

Limites de l'approche bayésienne

- On n'utilise pas l'intensité contextuelle autour ou à distance d'un voxel (texture, forme). Ceci peut-être partiellement corrigé par l'addition d'un modèle markovien
- La détection de lésions est obtenue « par défaut », elle n'est pas recherchée explicitement
- Ces deux limitations sont surmontées par les forêts aléatoires et l'apprentissage statistique


Quelques algorithmes clefs

- Approche bayésienne
 - Algorithme E/M
- Apprentissage automatique
 - Algorithme des forêts aléatoires
- Recalage multi-atlas
 - Algorithme STAPLE

Arbres de décision



Forêts aléatoires

- Algorithmes d'abord populaires en vision par ordinateur pour l'analyse de scènes
- Introduits plus récemment en imagerie médicale par le groupe de A. Criminisi (*Microsoft Research*)
- Résultats emblématiques pour la détection d'organes dans des images du corps entier




Voir aussi thèses O. Pauly (N. Navab) et R. Prevost (L. Cohen)

Détection d'organes




A Criminisi et al., Medical Image Analysis, 2013

Détection d'organes




R. Prevost 2013



Arbres de décision & Apprentissage statistique

- Grâce à un ensemble d'apprentissage, définir une succession de tests binaires qui réalisent progressivement et par dichotomie une partition plus homogène de l'image.

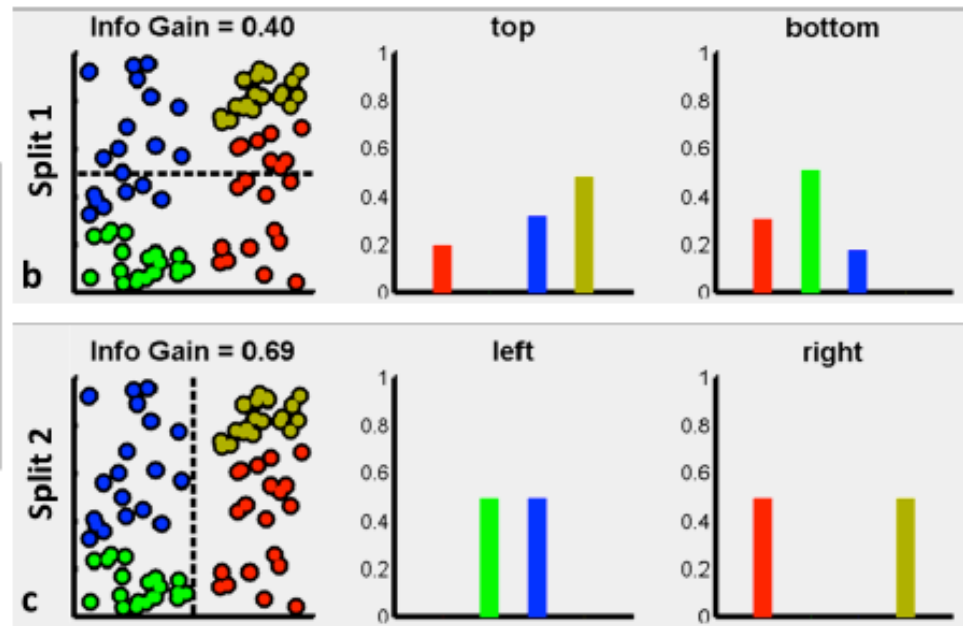

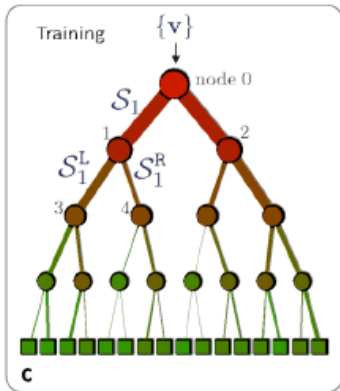


A. Criminisi, J. Shotton,
*Decision Forests for
Computer Vision and
Medical Image Analysis*,
Springer 2013

- Choisir les tests qui maximisent le **gain d'information**

Gain d'information

D'après Criminisi et al. 2013



Gain d'information



$$I = H(S) - \sum_{i \in \{L, R\}} \frac{|S^i|}{|S|} H(S^i).$$

Entropie

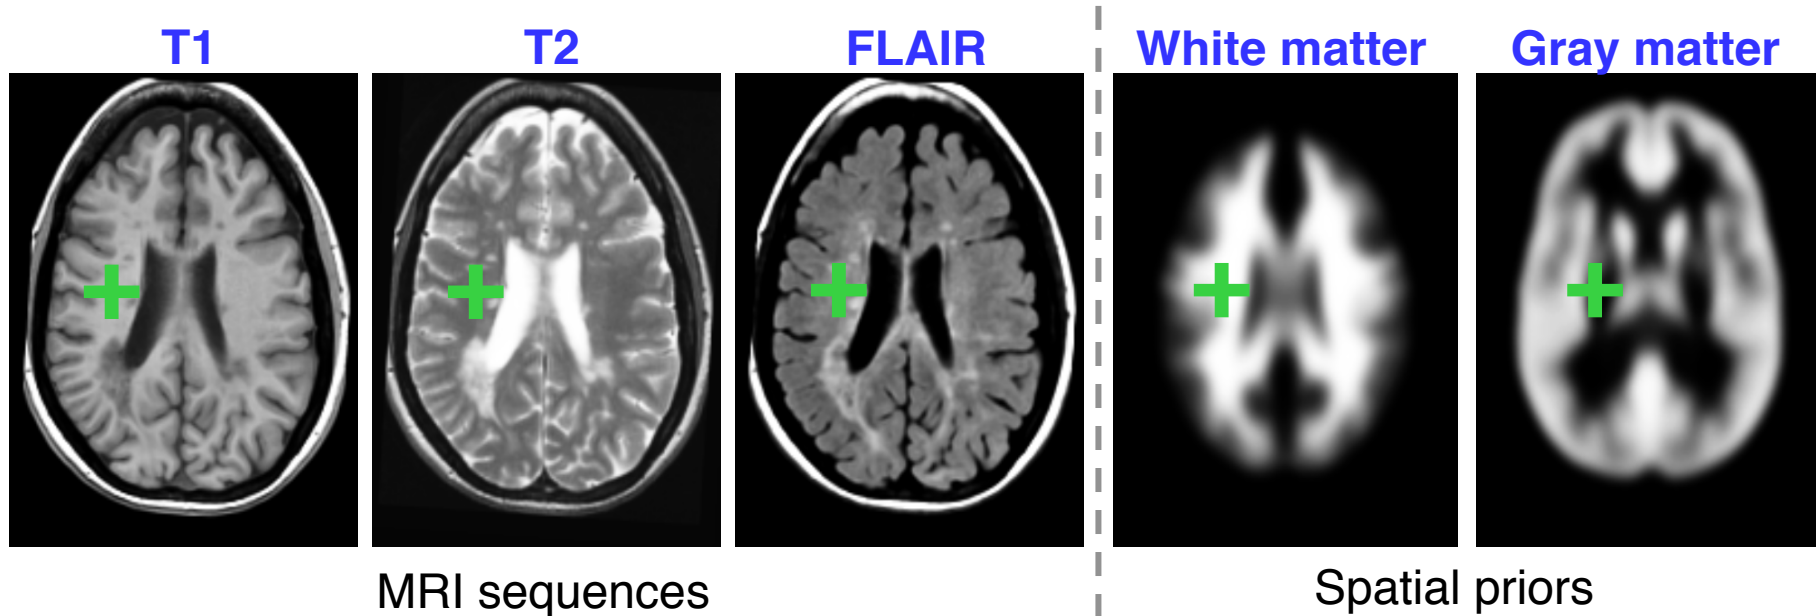
$$H(S) = - \sum_{c \in \mathcal{C}} p(c) \log(p(c))$$

Arbres et forêts aléatoires

- **Arbre aléatoire** : en chaque nœud, générer aléatoirement un très grand nombre de tests et conserver celui qui maximise le gain d'information
- **Forêt aléatoire** : constituée de plusieurs arbres aléatoires générés indépendamment



Mesures locales

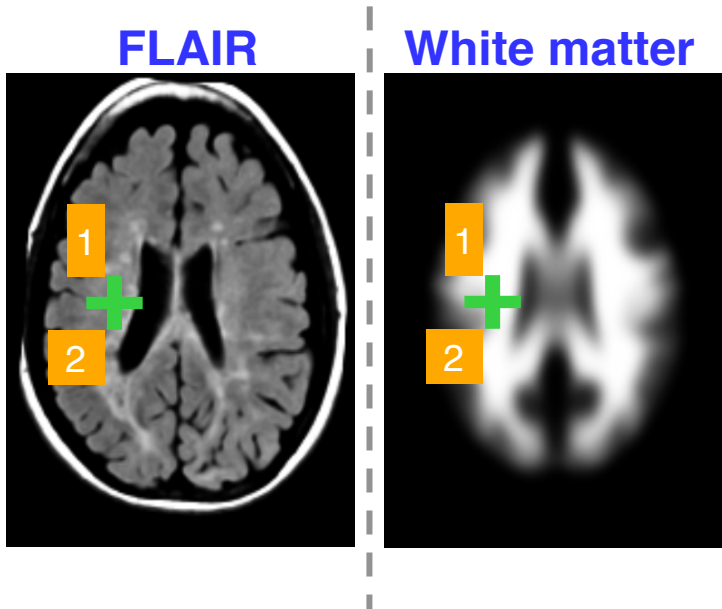


$$\theta(x) = C(x)$$

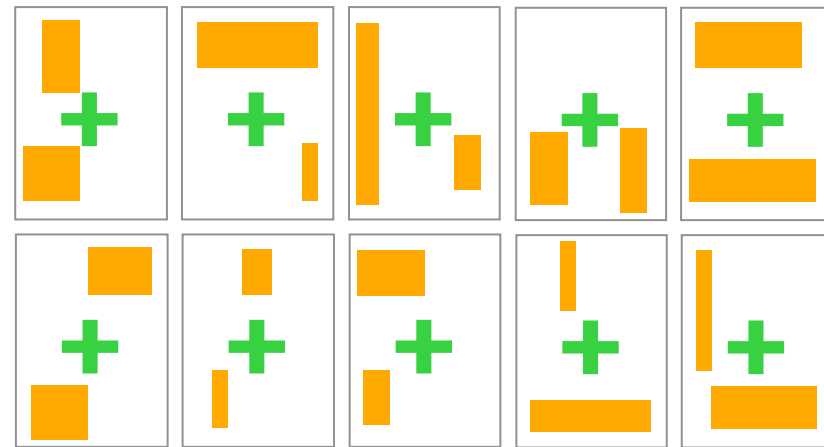
Intensité d'une séquence
ou
a priori anatomique

E Geremia, O Clatz, B H. Menze, E Konukoglu, A Criminisi, and N Ayache. *Spatial Decision Forests for MS Lesion Segmentation in Multi-Channel Magnetic Resonance Images*. *NeuroImage*, 2011.

Mesures contextuelles




Randomly generated feature set



$$\theta(x) = C(x) - \frac{1}{\text{vol}(B_1 \cup B_2)} \sum_{y \in B_1 \cup B_2} C(y)$$

Texture locale
ou
positionnement anatomique relatif

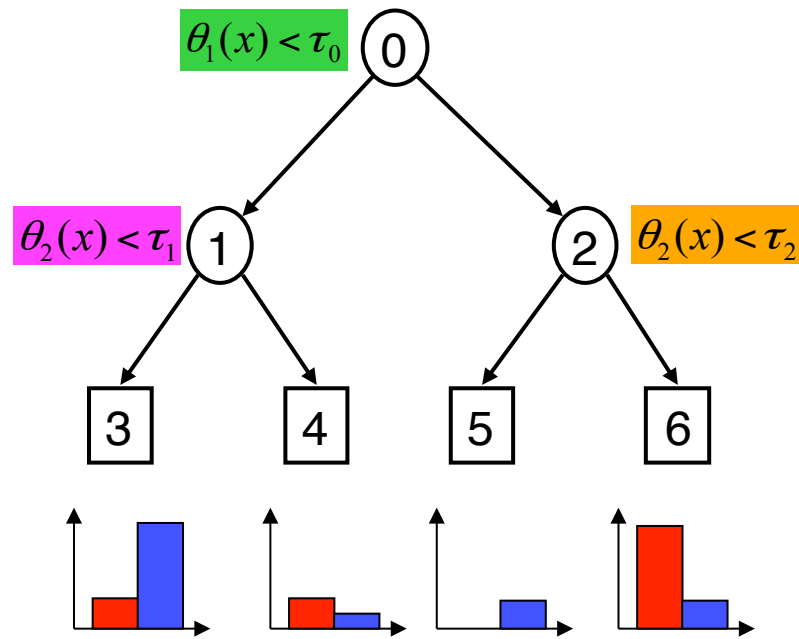
Mesures d'asymétrie




Amplitude de l'asymétrie

$$\theta(x) = \min_{y \in S} \{C(x) - C(y)\}$$

Apprentissage




Arbre de décision




Espace des mesures

Geremia et al. 2013

Classification



Arbre de décision






Espace des mesures



Geremia et al. 2013

Des arbres aux forêts

Combiner les probabilités



Effet sur la segmentation



Segmentation

vérité

Meilleure généralisation

Breiman, Random Forests, 2001

Geremia et al. 2013

Résultats typiques


Case CHB05

axial slice 46


T1 +
Ground truth




FLAIR +
Ground truth





Posterior probability
(Lesion class)





FLAIR +
segmentation



axial slice 38



Excellente sensibilité




Résultats typiques


Case CHB05

axial slice 46


T1 +
Ground truth




FLAIR +
Ground truth






Posterior probability
(Lesion class)



FLAIR +
segmentation




axial slice 38




Détection des régions suspectes

Mesures sélectionnées




mesures sélectionnées



fréquence d'utilisation


- ✓ mesures **locales** et **contextuelles** très discriminantes
- ✗ **asymétrie** : lésions periventriculaires symétriques

Ordre des tests




mesures sélectionnées

FLAIR



WM




1. Intensité FLAIR
2. Proximité matière blanche

On retrouve les deux premières étapes de l'algorithme vainqueur du *Miccai Challenge 2008*, dont les résultats sont améliorés.

Souplet et al., An Automatic Segmentation of T2-FLAIR Multiple Sclerosis Lesions, 2008


Tumeurs cérébrales

- La méthode est transposable aux IRM de gliomes



Multi-channel MRIs
T1, T2, T1+Gd, Flair

Spatial priors
GM, WM




asymmetry

Randomized context-rich features


E. Geremia, D. Zikic, O. Clatz, B.H. Menze, B. Glocker, E. Konukoglu, J. Shotton, O.M. Thomas, S.J. Price, T. Das, R. Jena, N. Ayache, and A. Criminisi, *Classification Forests for Semantic Segmentation of Brain Lesions in Multi-Channel MRI*, in *Decision Forests for Computer Vision and Medical Image Analysis*, Springer, 2013

Mesures sélectionnées


- Nouvelle répartition



41 %
mesures
contextuelles
vs. 78%



36 %
asymétrie
vs. 1%





23 %
mesures
locales
vs. 21%

Augmenter l'ensemble d'apprentissage


- Par la simulation, en utilisant un modèle de croissance de tumeurs (cours 5) et de formation d'image (**Prastawa et al.**)
- Stratégie utilisée par *Microsoft Research* pour entraîner la *Kinect*



Kinect




Croissance tumorale simulée



- matière grise
- matière blanche
- liquide CR
- nécrose
- vaisseaux
- œdème


Univ Utah
Microsoft Research

IRM Simulées 500



T1

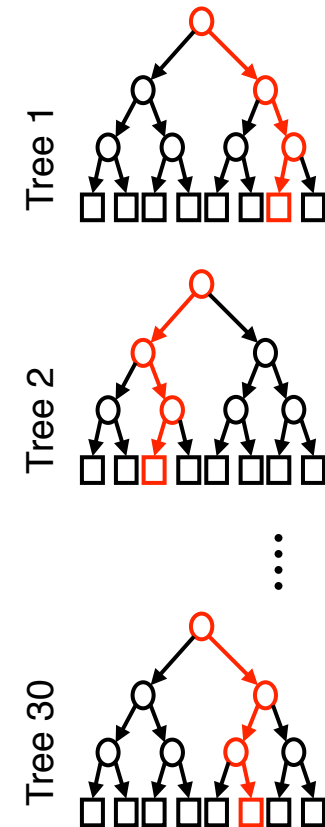
T2



T1+Gad

FLAIR


Apprentissage Statistique



Prédire




simulées




IRM Flair



T1 + Gd







prédiction



vérité

250

réelles



16

E Geremia, B H. Menze, M Prastawa, MA Weber, A Criminisi, and N Ayache. *Brain tumor cell density estimation from multi-modal MR images based on a synthetic tumor growth model*. In MICCAI Workshop on Medical Computer Vision, LNCS, 2012.






COLLÈGE
DE FRANCE
—1530—

Quelques algorithmes clefs

- Approche bayésienne
 - Algorithme E/M
- Apprentissage automatique
 - Algorithme des forêts aléatoires
- **Recalage multi-atlas**
 - **Algorithme STAPLE**

Recalage et segmentation

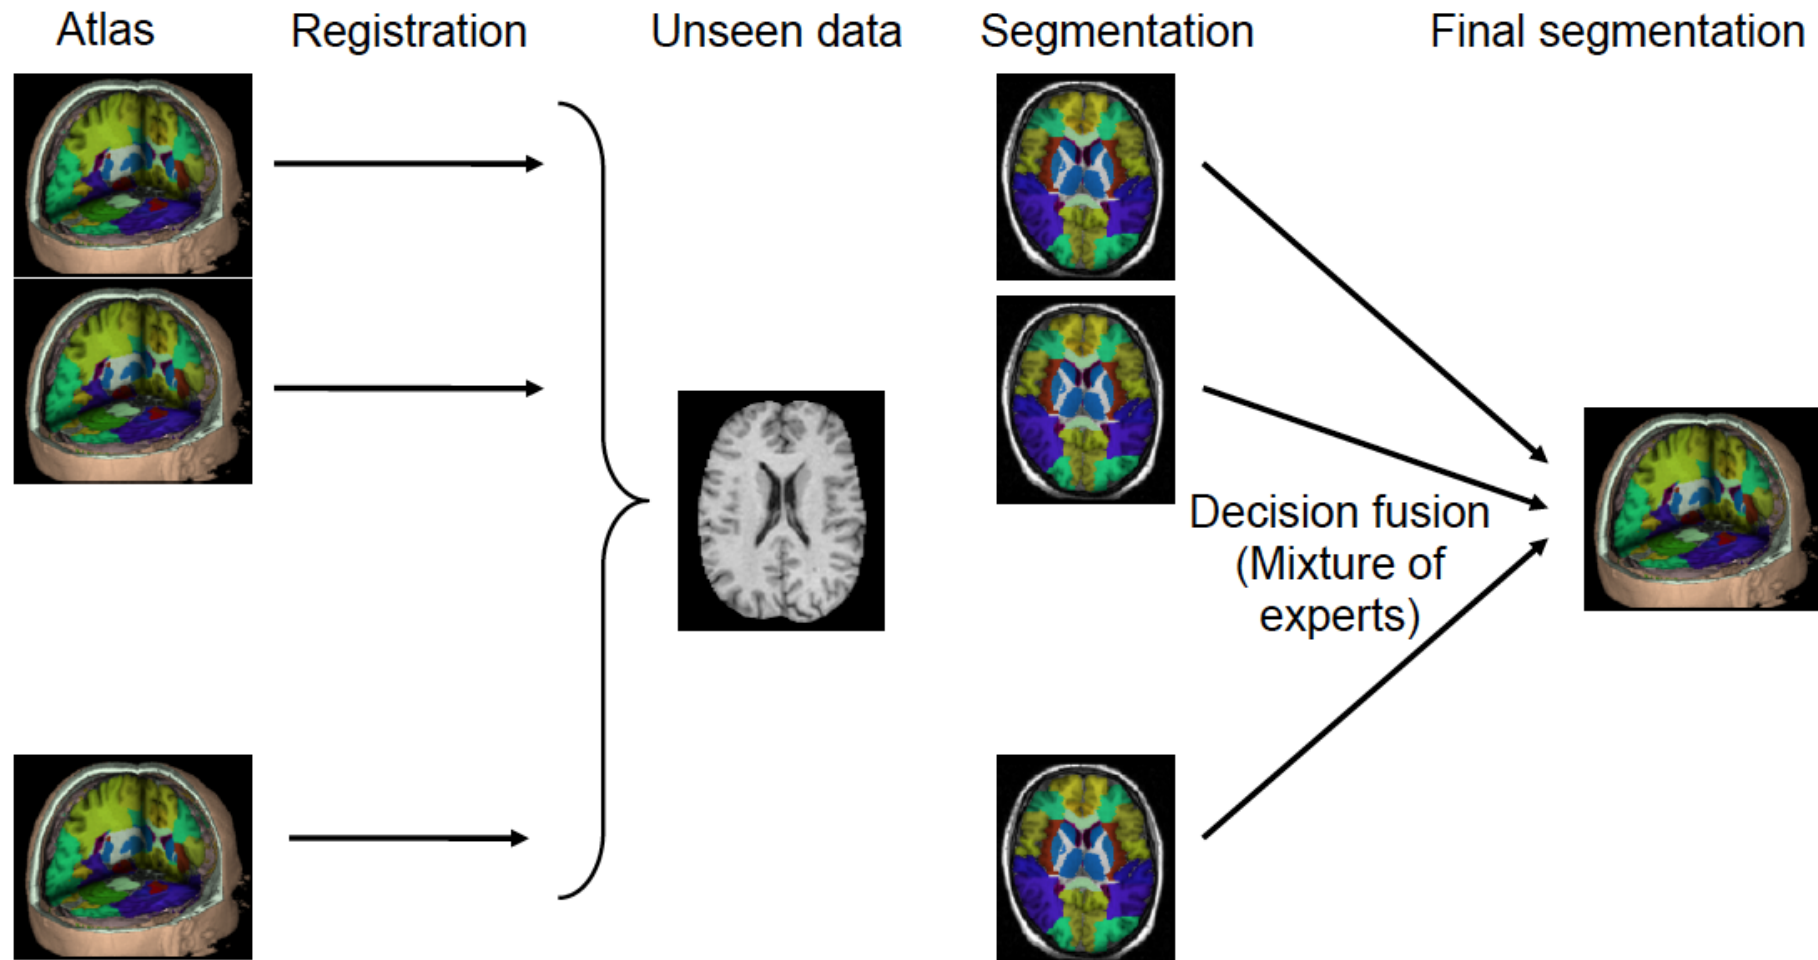
- Recaler une image segmentée (atlas) sur une nouvelle image



JP. Thirion, *Medical Image Analysis* 1998

Algorithme des démons

Atlas multiples




RA. Heckemann, JV. Hajnal, P Aljabar, D Rueckert, A Hammers, Automatic anatomical brain MRI segmentation combining label propagation and decision fusion, *Neuroimage* 2006

Comment fusionner?

- Approche démocratique
 - Majorité des votes (pondérés)
- Approche morphologique
 - Moyenne des formes
- Approche probabiliste
 - *Simultaneous Truth And Performance Level Estimation (STAPLE)*

Approche démocratique

- Des limitations



(a)


Majorité des votes

Résultat espéré

Rueckert et al.

Approche morphologique

- Utilise la moyenne des fonctions distances des segmentations



VOTE



SBA

Rueckert et al.


Approche probabiliste

- Chercher la **segmentation** la plus plausible, étant données les segmentations des experts



- Fournit aussi pour chaque expert
 - *Sensibilité* p : fraction positive vraie
 - *Spécificité* q : fraction négative vraie

(Warfield et al., 2004)




Segmentation optimale

Algorithme STAPLE


- Résolution itérative avec EM (Warfield et al., 2004)
 - p_0, q_0 :
 - **Etape E** : estimer T_1 qui maximise la probabilité $P(T | D, p_0, q_0)$
 - **Etape M** : utiliser T_1 pour mettre à jour p_1, q_1 de chaque expert

D : Segmentations à fusionner
(données)

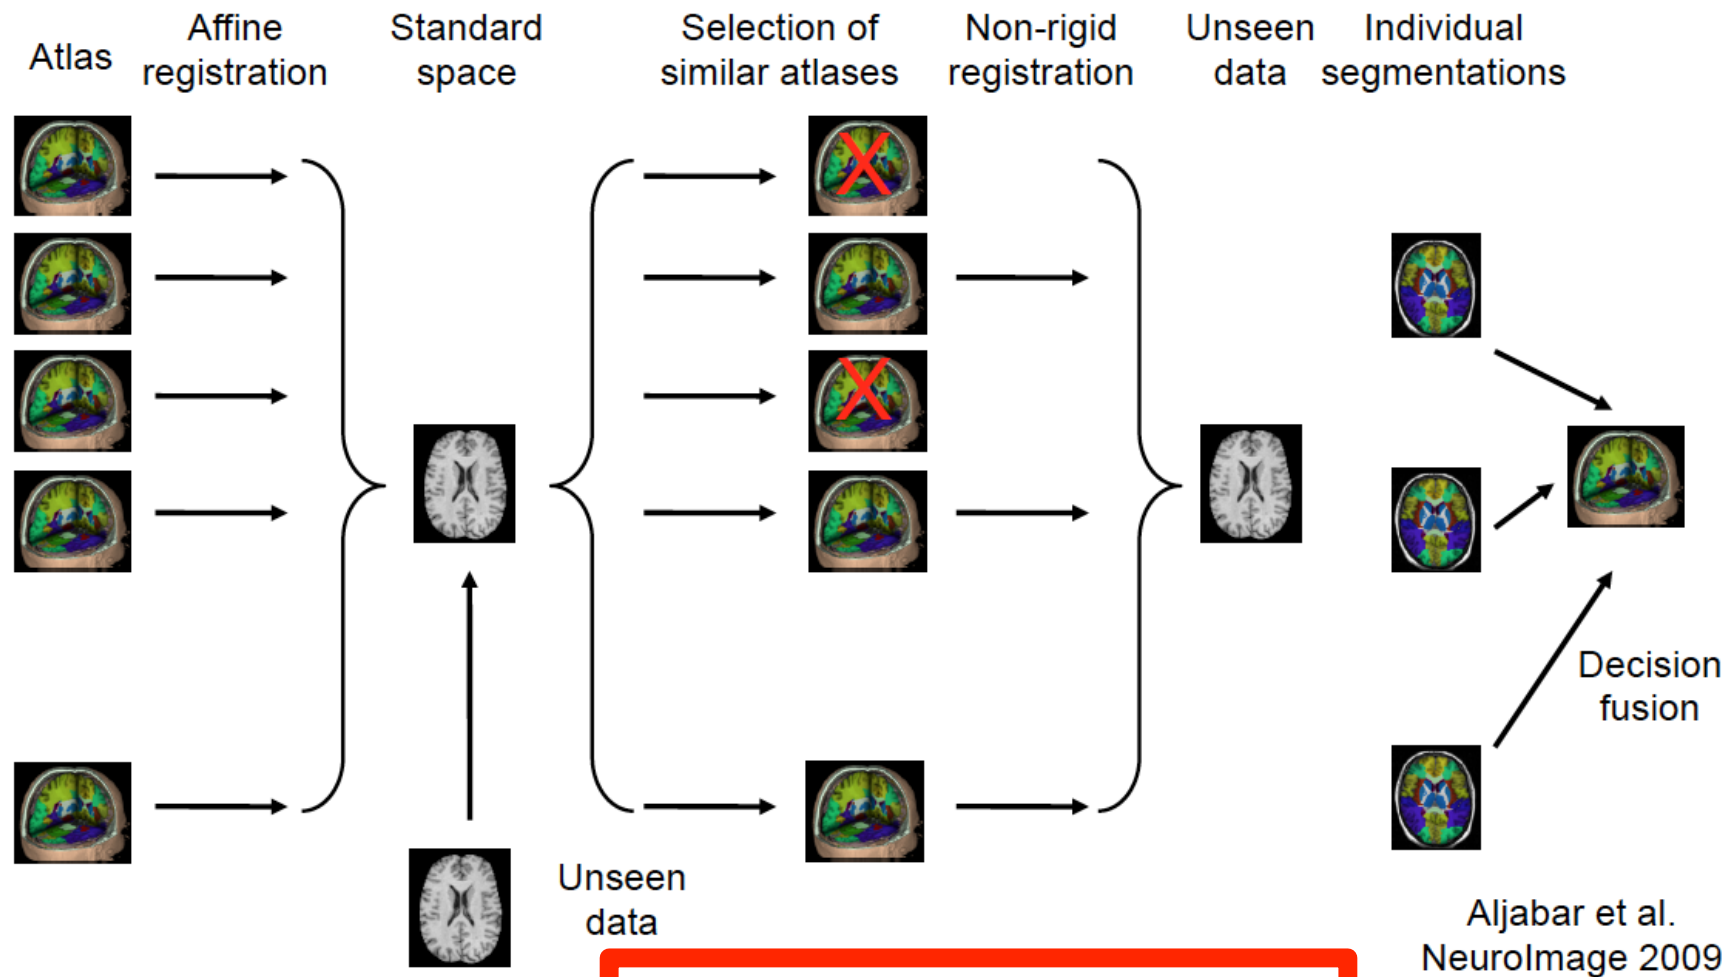


p, q : performances de chaque expert
(inconnues)

T : Segmentation optimale
(inconnue)



Fusion d'atlas « choisis »





Aljabar et al.
NeuroImage 2009

$$\text{Sim}(T(A),J) + \text{Reg}(T)$$



Fusion d'atlas « choisis »

Etat de l'art

Normal
control



Subject
with AD




Aljabar et al., 2009

Segmentation multi-atlas

- De bons résultats, mais très coûteux
 - La construction des atlas coûte très cher
- Idéalement, il faut adapter les atlas à la population choisie (patients, contrôles, etc.)
- Pour cela, il faudrait connaître la structure de variété sous-jacente aux images
 - *manifold learning*

Apprentissage de variété




D. Rueckert

Conclusion

- Premier éclairage sur la segmentation d'images
- Des algorithmes populaires pour segmenter IRM cérébrales exploitant principalement *géométrie* et *statistiques*.
- Liens étroits entre recalage et segmentation que nous retrouverons dans les prochains cours

Autres algorithmes

- Parcours de graphes
 - contours actifs (*snakes*)
 - coupures de graphes (*graph cuts*),
 - marcheur aléatoire (*random walker*)
 - chemins géodésiques (*geodesic paths*)
 - lignes de partage des eaux (*power watersheds*)
 - etc...
- Séminaires : J.F. Mangin, H. Delingette
- Colloque 24 juin : A. Criminisi, J. Duncan, D. Rueckert, ...



Thèses récentes : Sarah Parisot (N. Paragios), Raphael Prevost (L. Cohen), H. Lombaert (F. Cheriet), etc.

+

Cours de N. Paragios (Centrale Paris), Isabelle Bloch (Télécom ParisTech), etc.

Colloque 24 Juin

09h10 Biophysical Models for Cancer Imaging

Michael Brady, *University of Oxford, United Kingdom*

09h50 Learning Clinical information from Medical Images

Daniel Rueckert, *Imperial College London, United Kingdom*

10h30 Spatiotemporal Analysis of Brain Development and Disease Progression

Guido Gerig, *University of Utah, United States*

11h10 Break

11h20 Decision Forests in Medical Image Analysis

Antonio Criminisi, *Microsoft Research, United Kingdom*

12h00 Computational Physiology: Connecting Molecular Systems Biology with Clinical Medicine

Peter Hunter, *University of Auckland, New Zealand*

14h10 Toward a Statistical Neuroscience

Olivier Faugeras, *Inria, Université de Nice Sophia Antipolis*

14h50 Model-Based Biomedical Image Analysis

James Duncan, *Yale University, United States*

15h30 Multi-Scale Image-Guided Interventions

David Hawkes, *University College London, United Kingdom*





16h10 Break

16h20 Augmented Reality in the Operating Room


Nassir Navab, *Tech. Univ. Munich, Germany & J. Hopkins Univ., United States*

17h00 Towards Image-Based Personalized Medicine


Dorin Comaniciu, *Siemens Corporate Technology, United States*




29 avril 2014 **Sciences des images médicales : les grandes classes de problèmes + recalage**
Chirurgie du futur guidée par l'image numérique, Jacques Marescaux, *IHU Strasbourg, IRCAD*
Cardiologie du futur à l'ère du patient numérique, Michel Haïssaguerre, *CHU Bordeaux, Université Victor-Segalen, IHU LIRYC*



6 mai 2014 **Se repérer dans les images : recalage et segmentation**
Mesurer le cerveau numérique, Jean-François Mangin, *Neurospin Saclay*
Reconstruction d'organes dans les formes, Hervé Delingette, *Inria, Sophia Antipolis*




13 mai 2014 **Variabilité anatomique et fonctionnelle : atlas statistiques**
Phénotype, fonction et génotype, Bertrand Thirion, *Inria Saclay Île-de-France, CEA, DSV, I2BM, Neurospin*
Statistiques de formes et variétés anatomiques, Xavier Pennec, *Inria Sophia Antipolis*




20 mai 2014 **La dimension temporelle : quantifier une évolution**
La neuro-imagerie à l'ère du patient numérique, Stéphane Lehéricy, *IHU Pitié Salpêtrière*
Biomarqueurs d'imagerie dans les pathologies cérébrales, Christian Barillot, *CNRS, Inserm, Inria Rennes*

27 mai 2014 **Imagerie des tumeurs : modèles biophysiques pour mesurer et prédire**
Neurochirurgie guidée par l'image, Emmanuel Mandonnet, *Hôpital Lariboisière*
Radiothérapie guidée par l'image, Jocelyne Troccaz, *TIMC Grenoble, CNRS*



03 juin 2014 **Imagerie microscopique in vivo : mosaïques numériques et indexation**
Les enjeux médicaux de l'endomicroscopie, Stanislas Chaussade, *Hôpital Cochin*
Des étoiles aux cellules, de la recherche à l'entreprise, Sacha Loiseau, *Mauna Kea Technologies*

10 juin 2014 **Le cœur numérique personnalisé : diagnostic, pronostic et thérapie**
Images et signaux cardiaques : état de l'art et futur, Pierre Jaïs, *CHU Bordeaux, Université Victor-Segalen, IHU LIRYC*
Vers un système vasculaire numérique, Jean-Frédéric Gerbeau, *Inria UPMC*



17 juin 2014 **Réalité virtuelle, simulation, et perspectives**
Réalité augmentée en endoscopie et chirurgie, Luc Soler, *IRCAD/IHU, Strasbourg*
Simulation en médecine : présent et futur, Stéphane Cotin, *Inria*

