



HAL
open science

Segmentation 3D+t d'images IRM cérébrales par une chaîne de Markov 4D

François Lavigne, Christophe Collet, Jean-Paul Armspach

► **To cite this version:**

François Lavigne, Christophe Collet, Jean-Paul Armspach. Segmentation 3D+t d'images IRM cérébrales par une chaîne de Markov 4D. *Reconnaissance de Formes et Intelligence Artificielle (RFIA)* 2014, Jun 2014, France. hal-00988732

HAL Id: hal-00988732

<https://hal.science/hal-00988732v1>

Submitted on 9 May 2014

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Segmentation 3D+t d'images IRM cérébrales par une chaîne de Markov 4D

F. Lavigne

C. Collet

J.-P. Armspach

Université de Strasbourg - CNRS, ICube Laboratoire

300, boulevard Sébastien Brant

CS 10413, F - 67412 ILLKIRCH Cedex

f.lavigne@unistra.fr c.collet@unistra.fr jparmspach@unistra.fr

Résumé

Ces dernières années, beaucoup de méthodes semi-automatiques ont été développées afin d'aider les praticiens dans leur diagnostic des maladies cérébrales ; malgré tout le problème reste complexe. Dans cet article, nous proposons une méthode de segmentation simultanée des structures cérébrales de deux images IRM 3D multimodales prises à deux instants différents (acquisition longitudinale). Cette segmentation repose sur une Chaîne de Markov Cachée (CMC) permettant de prendre en compte la corrélation temporelle en plus de l'information de voisinage spatial, une correction du biais est réalisée. Pour augmenter la robustesse de la méthode, nous utilisons l'estimateur de vraisemblance tamisée (EVT), afin de détecter d'éventuelles lésions sans affecter la segmentation. La méthode a été validée sur des images IRM 3D+t simulées de la base BrainWeb.

Mots Clef

Segmentation statistiques, EM, chaîne de Markov 4D, IRM.

Abstract

In recent years many automatic methods have been developed to help physicians diagnose brain disorders, but the problem remains complex. In this paper we propose a method to segment brain structures on two 3D multi-modal MR images taken at different times (longitudinal acquisition). A bias field correction is performed with an adaptation of the Hidden Markov Chain (HMC) allowing us to take into account the temporal correlation in addition to spatial neighbourhood information. To improve the robustness of the segmentation of the principal brain structures the Trimmed Likelihood Estimator (TLE) is used during the process. The method is validated on 3D+t brain MR images.

Keywords

Statistical segmentation, EM, HMC, 4D-Markov chain, MRI.

1 Introduction

L'imagerie par résonance magnétique (IRM) est fréquemment utilisée pour le diagnostic des maladies évolutives du cerveau, comme la sclérose en plaques ou la maladie d'Alzheimer. La segmentation des structures cérébrales et l'analyse de leur évolution sont des étapes importantes du diagnostic de ces maladies. Des méthodes semi-automatiques ont été développées afin d'aider les praticiens ; la segmentation manuelle est toujours très couteuse en temps et est soumise à une variabilité inter-observateur. Un état de l'art des méthodes de segmentation des structures cérébrales est présenté dans [14]. Dans [6], Cabezas *et al.* présentent l'utilisation des atlas dans le processus de segmentation. Le but est de simplifier la segmentation en apportant une information anatomique *a priori* supplémentaire. Pour les méthodes plus spécifiques à la sclérose en plaques, une présentation en est faite dans [12] et [11]. Ces méthodes prennent en compte dans le processus de segmentation le fait que les lésions sclérose en plaques n'ont pas la même intensité que les tissus environnants.

Dans cet article, nous proposons une méthode permettant de segmenter en trois classes les structures cérébrales (substance blanche (SB), substance grise (SG) et liquide céphalo-rachidien (LCR)), tout en prenant en compte leurs évolutions. Nous segmentons simultanément deux images IRM 3D multi-modales prises à deux instants différents en utilisant un modèle de chaîne de Markov cachée (CMC). L'utilisation de ce modèle permet de prendre en compte l'information de voisinage à la fois spatiale et temporelle afin d'introduire une régularisation spatio-temporelle pendant le processus de segmentation. Cela permet de réduire l'influence du bruit présent dans les images IRM, tout en prenant en compte l'évolution temporelle. Le critère de segmentation ainsi que les paramètres du modèle CMC sont automatiquement estimés grâce à l'algorithme de Baum et Welch [2]. Dans les données utilisées, il existe toujours des artéfacts, qui sont dus soit aux images IRM en elles-mêmes, soit aux maladies étudiées (par exemple dans la sclérose en plaques, les lésions n'ont pas la même intensité que les trois structures recherchées). Afin de réduire l'influence des ces artéfacts et d'améliorer ainsi la

robustesse, le terme d'attache aux données sera estimé par la méthode de l'estimateur de vraisemblance tamisée [7]. L'article est organisé de la façon suivante. La section 2 décrit la méthode que nous proposons. Dans la section 3, les résultats obtenus sur des images IRM 3D de la base de fantômes BrainWeb sont présentés.

2 Chaîne de Markov spatio-temporelle

L'utilisation des chaînes de Markov cachée (CMC) afin de réaliser une régularisation spatiale pendant le processus de segmentation et donc réduire ainsi l'influence du bruit est une méthode éprouvée [9]. Dans [3], Benmiloud *et al.* propose un modèle de chaîne de Markov cachée, permettant de réaliser à la fois une régularisation spatiale et temporelle. Ce modèle est adaptable à notre problème : les structures cérébrales que nous souhaitons segmenter (SB, SG, LCR) présentent en effet une certaine cohérence spatiale au cours du temps, ce qui va permettre de réduire l'influence du bruit, tout en conservant la possibilité d'éventuels changements. L'entrée d'une CMC étant un vecteur, la première étape est donc de transformer en un vecteur les deux images 3D. Cela est réalisé grâce à un parcours d'Hilbert-Peano 3D+t (Fig. 1). A la fin du processus de segmentation, la transformation inverse est réalisée afin d'obtenir une carte de segmentation pour chacune des images. Un autre modèle de Chaîne de Markov Cachée 4D est présenté dans [13]. A une méthode de segmentation 3D par champ de Markov, ce modèle ajoute une chaîne de Markov temporelle en chaque voxel.

Considérons deux processus au temps t_1 et au temps t_2 , $X^{t_i} = (X_n^{t_i})_{n \in S}$ étant les processus cachés et $Y^{t_i} = (Y_n^{t_i})_{n \in S}$ les observations, avec $i = \{1, 2\}$ l'indice associé respectivement avec l'image au temps t_1 et au temps t_2 et l'ensemble fini de N voxels du treillis 3D S . Chaque $X_n^{t_i}$ a valeur dans un ensemble fini de K classes $\Omega = \{\omega_1, \dots, \omega_K\}$, typiquement dans cette application $K = 3$ et $\Omega = \{\omega_{LCR}, \omega_{SG}, \omega_{SB}\}$. Chaque $Y_n^{t_i}$ a valeur dans \mathbb{R}^m avec m le nombre de modalité IRM (par exemple les modalités peuvent être des images pondérées T1, pondérées T2, Flair). Soit :

$$X = [X_1^{t_1}, X_1^{t_2}, X_2^{t_2}, X_2^{t_1}, X_3^{t_1}, \dots, X_{N-1}^{t_2}, X_N^{t_2}, X_N^{t_1}] \quad (1)$$

Pour introduire une régularisation spatio-temporelle dans le processus de segmentation, nous faisons l'hypothèse que X est une chaîne de Markov, nous avons alors $P(X_{n+1} = \omega_l | X_n = \omega_k, \dots, X_1 = \omega_j) = P(X_{n+1} = \omega_l | X_n = \omega_k)$. X sera alors déterminée par une probabilité initiale $\pi_k = P(X_1^{t_1} = \omega_k)$ et les matrices de transitions spatiales :

$$\begin{cases} \mathbf{A}^{t_1, n} : a_{kl}^{t_1, n} = P(X_{n+1}^{t_1} = \omega_l | X_n^{t_1} = \omega_k) \\ \mathbf{A}^{t_2, n} : a_{kl}^{t_2, n} = P(X_{n+1}^{t_2} = \omega_l | X_n^{t_2} = \omega_k) \end{cases} \quad (2)$$

et la matrice de transition temporelle \mathbf{T}^n , qui a pour éléments $t_{kl}^n = P(X_n^{t_i} = \omega_l | X_n^{t_j} = \omega_k)$ (avec $\bar{i} = 2$ (*resp.* 1)

si $i = 1$ (*resp.* 2)). Nous faisons l'hypothèse de l'homogénéité de la chaîne de Markov, ce qui signifie que les matrices de transitions sont indépendantes de la position n : $a_{kl}^{t_1, n} = a_{kl}^{t_1}$, $a_{kl}^{t_2, n} = a_{kl}^{t_2}$, $t_{kl}^n = t_{kl}$. La chaîne de Markov cachée spatio-temporelle est présentée à la Fig. 2.




FIGURE 2 – Chaîne de Markov spatio-temporelle cachée, avec $\tilde{Y}_n^{t_i}$ les observations corrigées du biais (Eq. 3) et $f_k^{t_i}$ la loi d'attache aux données (Eq. 4)

Les images IRM présentent des inhomogénéités qui peuvent entraîner des erreurs de classification durant le processus de segmentation. Afin de corriger ce biais, nous utilisons la méthode introduite par Van Leemput *et al.* [15], dans laquelle le biais est modélisé comme une combinaison linéaire $\sum_l b_l^{t_i} \phi_l(n)$ de fonction polynomiale de base $\phi_l(n)$. Les inhomogénéités étant multiplicatives, nous utilisons le logarithme des observations afin d'avoir un biais additif. Définissons les observations corrigées du biais :

$$\tilde{Y}_n^{t_i} = \log(Y_n^{t_i}) - \sum_l b_l^{t_i} \phi_l(n) \quad (3)$$


L'estimation du paramètres du biais $b_l^{t_i}$ est fait grâce à une méthode des moindres carrés pondérés [15].

Pour chaque image, la vraisemblance est le terme d'attache aux données multimodales :


$$f_k^{t_i}(\tilde{y}_n^{t_i}; \theta_k^{t_i}) = p(\tilde{Y}_n^{t_i} = \tilde{y}_n^{t_i} | X_n^{t_i} = \omega_k) \quad (4)$$

Nous faisons l'hypothèse que ce terme suit une distribution normale multivariée de moyenne $\mu_k^{t_i}$ et de matrice de covariance $\Sigma_k^{t_i}$. L'estimation de ces paramètres $\theta_k^{t_i} = \{\mu_k^{t_i}, \Sigma_k^{t_i}\}$, ainsi que l'estimation des paramètres *a priori* $\theta_{CMC} = \{\pi, \mathbf{A}^{t_1}, \mathbf{A}^{t_2}, \mathbf{T}\}$ est décrit dans la section suivante.

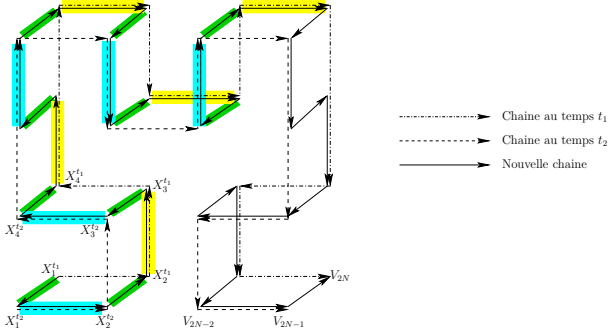
Les données segmentées sont obtenues en utilisant le critère bayésien du MPM (Mode des marginales *a posteriori*) [8] : $\hat{x}_n = \arg \max_{\omega_k} P(X_n = \omega_k | \mathbf{Y} = \mathbf{y})$ qui maximise en chaque nœud de la chaîne 4D les probabilités *a posteriori*. L'un des intérêts principaux des chaînes de Markov cachées par rapport aux champs de Markov est de connaître l'expression exacte des probabilités *a posteriori* en chaque voxel, comme montré dans la section suivante. Les techniques d'approximation étant chronophage, cela permet de réduire les temps de calcul, tout en conservant une information spatiale suffisante.




(a) Parcours d'Hilbert-Peano 3D sur une image



(b) Introduction des transitions temporelles



(b) Construction du nouveau parcours en alternant transition spatiale et temporelle



(c) Parcours final

FIGURE 1 – Parcours d'Hilbert-Peano 3D+t

3 Estimation des paramètres de la chaîne

L'algorithme de Baum et Welch [2] permet de calculer les probabilités *a posteriori* requises pour estimer le critère de segmentation et mettre à jour les paramètres *a priori* θ_{CMC} et les paramètres du bruit $\theta_k^{t_i}$. Dans cet algorithme itératif, les probabilités *a posteriori* et les paramètres du modèle CMC sont estimés de façon séquentielle. Afin d'avoir une méthode complètement non-supervisée, l'ensemble des paramètres est initialisé par une méthode des K-moyennes [5]. Soit :

$$V = [X_1^{t_1}, X_1^{t_2}, X_2^{t_2}, X_2^{t_1}, X_3^{t_1}, \dots, X_{N-1}^{t_2}, X_N^{t_2}, X_N^{t_1}] \quad (5)$$

$$Z = [\tilde{Y}_1^{t_1}, \tilde{Y}_1^{t_2}, \tilde{Y}_2^{t_2}, \tilde{Y}_2^{t_1}, \tilde{Y}_3^{t_1}, \dots, \tilde{Y}_N^{t_1}] \quad (6)$$

$$d_{kl}^n = P(V_{n+1} = \omega_l | V_n = \omega_k) \quad (7)$$

$$[g_k(\tilde{y}_1^{t_1}), \dots, g_k(\tilde{y}_N^{t_1})] = [f_k^{t_1}(\tilde{y}_1^{t_1}), f_k^{t_2}(\tilde{y}_1^{t_2}), \dots, f_k^{t_1}(\tilde{y}_N^{t_1})] \quad (8)$$

Afin de simplifier les notations, nous utiliserons z_n pour $Z_n = z_n$ dans toutes les notations faisant intervenir les données (par exemple, les probabilités marginales *a posteriori* $P(V_n = \omega_k | Z = z)$ seront notées $P(V_n = \omega_k | z)$).

L'étape de calcul des probabilités *a posteriori*. Les probabilités *a posteriori* sont calculées en parcourant la chaîne dans les deux sens. Premièrement la probabilité *forward*

$\alpha_n(k)$ est estimée :

$$\alpha_n(k) = P(V_n = \omega_k | z_1, \dots, z_n), \forall n \in [1, 2N] \quad (9)$$

$$= \begin{cases} \pi_k g_k(z_1) & \text{si } n = 1 \\ \sum_{l=1}^K \alpha_{n-1}(l) d_{lk}^{n-1} g_k(z_n) & \text{sinon} \end{cases}$$

puis ensuite la probabilité *backward* $\beta_n(k)$:

$$\beta_n(k) = \frac{P((z_{n+1}, \dots, z_{2N}) | V_n = \omega_k)}{P((z_{n+1}, \dots, z_{2N}) | z_1, \dots, z_n)}, \forall n \in [1, 2N] \quad (10)$$

$$= \begin{cases} 1 & \text{si } n = 2N \\ \sum_{l=1}^K \beta_{n+1}(l) d_{kl}^n g_l(z_{n+1}) & \text{sinon} \end{cases}$$

Finalement les probabilités *a posteriori* sont calculées [8] : $P(V_n = \omega_k | z) = \alpha_n(k) \beta_n(k), \forall k \in [1, K]$.

L'étape d'estimation des paramètres θ_{CMC} et $\theta_k^{t_i}$. Dans la seconde étape, les paramètres *a priori* et les paramètres du bruit sont estimés en utilisant les probabilités *forward* et *backward* en approchant le maximum de vraisemblance. Soient les probabilités jointes *a posteriori* $P(V_n = \omega_l, V_{n-1} = \omega_k | z) = \xi_{n-1}(k, l) = \alpha_{n-1}(k) d_{kl}^{n-1} g_l(z_n) \beta_n(l)$ et les probabilités marginales *a posteriori* $P(V_n = \omega_k | z) = \gamma_n(k) = \alpha_n(k) \beta_n(k)$. Les paramètres *a priori* sont alors estimés par :

$$\pi_k = \gamma_1(k) \quad (11)$$

$$a_{kl}^{t_1} = \frac{\sum_{n=1}^{N/2-1} \xi_{4n+1}(k, l)}{\sum_{n=1}^{N/2-1} \gamma_{4n+1}(k)} \quad (12)$$

$$a_{kl}^{t_2} = \frac{\sum_{n=1}^{N/2} \xi_{4n-1}(k, l)}{\sum_{n=1}^{N/2} \gamma_{4n-1}(k)} \quad (13)$$

$$t_{kl} = \frac{\sum_{n=1}^N \xi_{2n}(k, l)}{\sum_{n=1}^N \gamma_{2n}(k)} \quad (14)$$

et les paramètres du bruit sont estimés par :

$$\boldsymbol{\mu}_k^{t_i} = \frac{\sum_{n \in t_i} \gamma_n(k) \mathbf{z}_n}{\sum_{n \in t_i} \gamma_n(k)} \quad (15)$$

$$\boldsymbol{\Sigma}_k^{t_i} = \frac{\sum_{n \in t_i} \gamma_n(k) (\mathbf{z}_n - \boldsymbol{\mu}_k^{t_i})(\mathbf{z}_n - \boldsymbol{\mu}_k^{t_i})^t}{\sum_{n \in t_i} \gamma_n(k)} \quad (16)$$

L'estimation des paramètres du bruit peut être perturbée par des artefacts ou des valeurs aberrantes comme celles introduites par la présence de lésions sclérose en plaques. Afin de réduire cette influence, nous estimons les paramètres du bruit de façon robuste grâce à un estimateur de vraisemblance tamisée qui est introduit dans la section suivante.

4 Estimateur de vraisemblance tamisée

Dans l'algorithme de Baum et Welch, le paramètre $\theta = \{\theta_k^{t_i}, \theta_{CMC}\}$ est estimé par une méthode de l'estimateur du maximum de vraisemblance (EMV), défini par :

$$\hat{\theta}_{EMV} = \arg \max_{\theta} \prod_{n=1}^N g(\mathbf{z}_{\nu(n)}; \theta) \quad (17)$$

Nous utilisons l'estimateur de vraisemblance tamisée (EVT) afin d'estimer les paramètres du bruit $\theta_k^{t_i}$ de façon robuste vis-à-vis d'éventuelles valeurs aberrantes provenant de classes non modélisées (lésions, ...). Cet estimateur ne prend en compte que les données les plus en adéquation avec le model. Il est défini par :

$$\hat{\theta}_{EVT} = \arg \max_{\theta} \prod_{n=1}^h g(\mathbf{z}_{\nu(n)}; \theta) \quad (18)$$

où $\nu = (\nu(1), \dots, \nu(2N))$ est une permutation sur les indices et h le paramètre de tamisage. L'estimateur du maximum de vraisemblance est un cas particulier de l'estimateur de vraisemblance tamisée avec $h = N$. L'estimateur de vraisemblance tamisée a été utilisé pour la première fois dans le contexte de détection de lésions sclérose en plaques par Aït-Ali *et al.* [1] et adapté dans le cadre des chaînes de Markov cachées par Bricq *et al.* [4]. Dans l'étape d'estimation des paramètres du bruit, cet estimateur ne prend pas en compte les données \mathbf{z}_n , pour lesquelles la probabilité d'appartenance au modèle $P(\mathbf{z}_n, \theta)$ est inférieure à un seuil s fixé.

$$\begin{aligned} P(\mathbf{z}_n, \theta) &= \sum_{k=1}^K P(\mathbf{z}_n, V_n = \omega_k, \theta) \\ &= \sum_{k=1}^K P(V_n = \omega_k) P(\mathbf{z}_n, \theta | V_n = \omega_k) \\ &= \sum_{k=1}^K P(V_n = \omega_k) g_k(\mathbf{z}_n, \theta) \end{aligned} \quad (19)$$

Pour un nombre de nœuds suffisamment important, \mathbf{A}^{t_1} et \mathbf{A}^{t_2} étant en pratique presque identiques et \mathbf{T} étant proche de la matrice identité, nous pouvons considérer notre chaîne de Markov cachée comme stationnaire ($P(V_n = \omega_k) = \alpha_k$ devient constant). La probabilité d'appartenance au modèle $P(\mathbf{z}_n, \theta)$ peut alors être approchée en chaque nœud par une unique distribution de mélange de gaussiennes, définie par :

$$\begin{aligned} P(\mathbf{z}_n, \theta) &\approx \sum_{k=1}^K \alpha_k g_k(\mathbf{z}_n, \theta) \\ &= h_{MG}(\mathbf{z}_n, \theta) \end{aligned} \quad (20)$$

Nous déterminons alors numériquement le seuil s vérifiant :

$$\begin{aligned} \int_{\Phi_s} h_{MG}(\mathbf{z}, \theta) d\mathbf{z} &= p_{EVT} \\ \Phi_s &= \{\mathbf{z} | h_{MG}(\mathbf{z}, \theta) \geq s\} \end{aligned} \quad (21)$$

où p_{EVT} est une probabilité choisie par l'utilisateur. Le paramètre de tamisage h est alors défini par : $h = \text{card}(\mathbf{z}_n \in \Phi_s)$.

Les paramètres du bruit $\theta_k^{t_i} = \{\boldsymbol{\mu}_k^{t_i}, \boldsymbol{\Sigma}_k^{t_i}\}$ sont alors estimés par :

$$\boldsymbol{\mu}_k^{t_i} = \frac{\sum_{n \in t_i \cap \Phi_s} \gamma_n(k) \mathbf{z}_n}{\sum_{n \in t_i \cap \Phi_s} \gamma_n(k)} \quad (22)$$

$$\boldsymbol{\Sigma}_k^{t_i} = \frac{\sum_{n \in t_i \cap \Phi_s} \gamma_n(k) (\mathbf{z}_n - \boldsymbol{\mu}_k^{t_i})(\mathbf{z}_n - \boldsymbol{\mu}_k^{t_i})^t}{\sum_{n \in t_i \cap \Phi_s} \gamma_n(k)} \quad (23)$$

De plus, pour limiter de façon supplémentaire l'action des artefacts sur les résultats de segmentation, nous décidons de considérer comme manquantes les données marquées comme outliers lors du calcul des probabilités *forward* $\alpha_n(k)$ et *backward* $\beta_n(k)$. La probabilité *forward* $\alpha_n(k)$ est estimée par :

$$\alpha_n(k) = \begin{cases} \pi_k g_k(\mathbf{z}_1) & \text{si } n = 1 \\ \sum_{l=1}^K \alpha_{n-1}(l) d_{lk}^{n-1} & \text{si } \mathbf{z}_n \text{ est outlier} \\ \sum_{l=1}^K \alpha_{n-1}(l) d_{lk}^{n-1} g_l(\mathbf{z}_n) & \text{sinon} \end{cases} \quad (24)$$

La probabilité *backward* $\beta_n(k)$ est estimée par :

$$\beta_n(k) = \begin{cases} 1 & \text{si } n = 2N \\ \sum_{l=1}^K \beta_{n+1}(l) d_{kl}^n & \text{si } \mathbf{z}_{n+1} \text{ est outlier} \\ \sum_{l=1}^K \beta_{n+1}(l) d_{kl}^n g_l(\mathbf{z}_{n+1}) & \text{sinon} \end{cases} \quad (25)$$

5 Validation

Afin de valider notre modèle de chaîne de Markov cachée spatio-temporelle (CMCST), en particulier, l'apport de la dimension temporelle, nous comparons les segmentations d'images IRM cérébral obtenues par notre méthode et une méthode par chaîne de Markov cachée classique [4]. Pour ces tests, nous utilisons la base de données BrainWeb¹ [10], qui propose différents fantômes d'images IRM avec différents niveaux de bruit (de 0% à 9%), différents niveaux d'inhomogénéités (de 0% à 40%) et différentes charges lésionnelles. La vérité terrain associée à chacun des ces fantômes est connue. Pour comparer les performances de ces deux algorithmes, nous utilisons l'index Kappa (KI) :

$$KI = 2 \frac{SEG \cap GT}{SEG + GT} \quad (26)$$

où GT est la vérité terrain et SEG est la segmentation obtenue.

5.1 Tests sur les images BrainWeb sans lésions sclérose en plaques

Nous testons dans un premier temps notre méthode sur des images pondérées en T1 et pondérées en T2 avec 20% de biais pour différents niveaux de bruits, sans lésions. Les résultats sont présentés dans Tab.1. Pour la méthode spatio-temporelle, les deux instants différents utilisent différents niveaux de bruit. Pour cette méthode, la moyenne et la variation du KI pour différentes combinaisons de bruit sont présentées. Par exemple le résultat présenté pour le bruit 3% est la moyenne des résultats obtenues avec un bruit de 3% sur l'image t_1 et des bruits variant de 5% à 9% sur l'image au temps t_2 . Avec notre méthode, l'index Kappa moyen est toujours supérieur à 95% pour tous les niveaux de bruits et tous les structures cérébrales. De plus, quelles que soient les structures cérébrales et quel que soit le niveau de bruit, les résultats de segmentations obtenus par notre méthode sont toujours meilleurs que ceux obtenus par la méthode par chaîne de Markov cachée classique. Ces résultats confirment l'intérêt d'utiliser l'information de voisinage temporelle pour la segmentation des structures cérébrales. La régularisation spatio-temporelle apportée par notre modèle CMCST pendant le processus de segmentation permet de réduire les effets du bruit : les résultats changent en effet peu malgré l'augmentation du bruit.

5.2 Tests sur les images BrainWeb avec lésions sclérose en plaques

La seconde série de test est réalisée sur des images pondérées en T1 et pondérées en T2 avec des lésions sclérose en plaques. Nous utilisons les images de la base BrainWeb avec des charges lésionnelles dites « moyennes ». Les autres conditions restent les mêmes. Les résultats sont présentés dans Tab. 2.

bruit	méthode	LCR	SG	SB
1%	CMC	95.1	95.8	96.4
	CMCST	96.1 ± 0.2	96.5 ± 0.6	97.0 ± 0.8
3%	CMC	94.9	94.1	93.7
	CMCST	95.8 ± 0.2	95.5 ± 0.4	95.7 ± 0.5
5%	CMC	94.1	93.8	94.0
	CMCST	95.6 ± 0.5	95.5 ± 1.0	95.9 ± 1.1
7%	CMC	93.0	92.9	93.4
	CMCST	95.4 ± 0.8	95.3 ± 1.2	95.8 ± 1.4
9%	CMC	91.8	91.7	92.6
	CMCST	95.3 ± 0.7	95.1 ± 1.2	95.5 ± 1.4

TABLE 1 – Résultats obtenus sur les images de la base BrainWeb sans lésions avec 20% de biais pour différentes valeurs de bruit (de 1% à 9%). L'index Kappa (KI) est présenté pour la substance blanche (SB), la substance grise (SG) et le liquide céphalo-rachidien (LCR) pour une méthode par chaîne de Markov cachée classique (CMC) et notre méthode (CMCST)

Malgré de moins bon résultats que dans le cas sans lésions, notre méthode permet toujours d'obtenir une bonne segmentation des structures cérébrales même en présence de lésions sclérose en plaques ; ce qui montre l'efficacité de l'estimateur de vraisemblance tamisée. Cette différence de résultats entre les images avec et sans lésions peut s'expliquer par le fait que les méthodes (aussi bien notre méthode que la méthode comparative) ne détectent pas totalement les lésions comme des outliers. De plus notre méthode obtient toujours de meilleurs résultats que la méthode de chaîne de Markov cachée classique.

bruit	méthode	LCR	SG	SB
1%	CMC	82.1	89.4	93.8
	CMCST	92.34 ± 1.7	93.1 ± 0.5	94.0 ± 1.5
3%	CMC	83.9	88.9	92.7
	CMCST	92.3 ± 1.5	93.1 ± 0.4	94.2 ± 1.3
5%	CMC	88.1	88.5	91.5
	CMCST	92.2 ± 1.2	93.1 ± 0.3	94.4 ± 1.0
7%	CMC	88.4	87.4	90.2
	CMCST	92.1 ± 0.5	92.9 ± 0.5	94.1 ± 1.2
9%	CMC	87.6	85.9	88.9
	CMCST	92 ± 0.1	92.6 ± 0.8	93.7 ± 1.3

TABLE 2 – Résultats obtenus sur les images de la base BrainWeb avec lésions avec 20% de biais pour différentes valeurs de bruit (de 1% à 9%). L'index Kappa (KI) est présenté pour la substance blanche (SB), la substance grise (SG) et le liquide céphalo-rachidien (LCR) pour une méthode par chaîne de Markov cachée classique (CMC) et notre méthode (CMCST)

6 Conclusion et perspectives

Dans cet article, nous avons introduit et validé une méthode robuste pour segmenter de façon simultanée les

1. <http://www.bic.mni.mcgill.ca/brainweb/>

structures cérébrales (substance blanche, substance grise, liquide céphalo-rachidien) de deux images IRM cérébrales 3D multimodales obtenues à deux instants différents, et ce malgré la présence d'artéfacts comme des lésions sclérose en plaques. Nous utilisons une chaîne de Markov cachée spatio-temporelle pour prendre en compte dans le processus l'information de voisinage à la fois spatiale et temporelle afin de réduire l'influence du bruit présent dans les images IRM. Nous avons ajouté une dimension temporelle aux chaînes de Markov 3D, habituellement utilisées. Pour améliorer la robustesse, en particulier en présence de tissus cérébraux modifiés comme les lésions sclérose en plaques, nous utilisons l'estimateur de vraisemblance tamisée. Cette méthode a été testée sur des fantômes IRM 3D de la base BrainWeb avec ou sans lésions sclérose en plaque. Dans le futur, nous pourrions appliquer cette méthode pour détecter les lésions sclérose en plaques ou estimer l'atrophie cérébrale.

Références

- [1] Laure S. Aït-Ali, Sylvain Prima, Pierre Hellier, Béatrice Carsin, Gilles Edan, and Christian Barillot. Strem : a robust multidimensional parametric method to segment MS lesions in MRI. In *Medical Image Computing and Computer-Assisted Intervention*, pages 409–416, 2005.
- [2] Leonard E. Baum, Ted Petrie, George Soules, and Norman Weiss. A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains. *The Annals of Mathematical Statistics*, 41(1) :164–171, 1970.
- [3] Btissam Benmiloud and Wojciech Pieczynski. Estimation des paramètres dans les chaînes de Markov cachées et segmentation d'images. *Traitement du Signal*, 12(5) :465–475, 1995.
- [4] Stephanie Bricq, Christophe Collet, and Jean-Paul Armspach. 3D brain MRI segmentation based on robust Hidden Markov Chain. In *IEEE International Conference on Acoustics, Speech, and Signal Processing*, 2008.
- [5] Stephanie Bricq, Christophe Collet, and Jean-Paul Armspach. Unifying framework for multimodal brain MRI segmentation based on hidden Markov chains. *Medical Image Analysis*, 12(6) :639–652, 2008.
- [6] Mariano Cabezas, Arnau Oliver, Xavier Lladó, Jordi Freixenet, and Meritxell Bach Cuadra. A review of atlas-based segmentation for magnetic resonance brain images. *Computer methods and programs in biomedicine*, 104 :158–177, 2011.
- [7] Daniel Garcia-Lorenzo, Sylvain Prima, Douglas L. Arnold, D. Louis Collins, and Christian Barillot. Trimmed-likelihood estimation for focal lesions and tissue segmentation in multisequence MRI for multiple sclerosis. *IEEE Transactions On Medical Imaging*, 30 :1455–1467, 2011.
- [8] Andrew Gelman, John B. Carlin, Hal S. Stern, David B. Dunson, Aki Vehtari, and Donald B. Rubin. *Bayesian data analysis*. Chapman & Hall/CRC, 2013.
- [9] Nathalie Giordana and Wojciech Pieczynski. Estimation of generalized multisensor hidden markov chains and unsupervised image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5) :465–475, 1997.
- [10] Remi K.-S. Kwan, Alan C. Evans, and G. Bruce Pike. An extensible MRI simulator for post-processing evaluation. In KarlHeinz Höhne and Ron Kikinis, editors, *Visualization in Biomedical Computing*, volume 1131 of *Lecture Notes in Computer Science*, pages 135–140. Springer Berlin Heidelberg, 1996.
- [11] Xavier Lladó, Arnau Oliver, Mariano Cabezas, Jordi Freixenet, Joan C. Vilanova, Ana Quiles, Laia Valls, Lluís Ramió-Torrentà, and Àlex Rovira. Segmentation of multiple sclerosis lesions in brain MRI : A review of automated approaches. *Information Sciences*, 186(1) :164–185, 2012.
- [12] Daryoush Mortazavi, Abbas Z. Kouzani, and Hamid Soltanian-Zadeh. Segmentation of multiple sclerosis lesions in MR images : a review. *Neuroradiology*, 54 :299–320, 2012.
- [13] Jeffrey Solomon, John A. Butman, and Arun Sood. Segmentation of brain tumors in 4D MR images using the hidden Markov model. *computer methods and programs in biomedicine*, 84 :76–85, 2006.
- [14] Jasjit S. Suri, Singh Sameer, and Laura Reden. Computer vision and pattern recognition techniques for 2-d and 3-d MR cerebral cortical segmentation : A state-of-the-art review. *Pattern Analysis and applications*, 5 :46–98, 2002.
- [15] Koen Van Leemput, Frederik Maes, Dirk Vandermeulen, and Paul Suetens. Automated model-based bias field correction of MR images of the brain. *IEEE Transactions On Medical Imaging*, 18(10) :885–896, 1999.