

CHAÎNES DE MARKOV CACHÉES FLOUES ET SEGMENTATION NON SUPERVISEE D'IMAGES

FUZZY HIDDEN MARKOV CHAINS AND UNSUPERVISED IMAGE SEGMENTATION

C. Carincotte,¹ S. Derrode,¹

J.M. Boucher²

¹ Groupe des Signaux Multi-dimensionnels, Institut Fresnel (CNRS UMR 6133)

² Département Signal et Communications, TAMCIC (CNRS FRE 2658)

EGIM, Domaine Universitaire de St Jérôme, F-13397 Marseille Cedex 20
cyril.carincotte@fresnel.fr, stephane.derrode@fresnel.fr
GET/ENST Bretagne, Technopôle Brest-Iroïse, CS 83818, F-29238 Brest Cedex
jm.boucher@enst-bretagne.fr

Résumé :

Dans ce travail, nous utilisons le modèle récent des « chaînes de Markov cachées floues » pour la segmentation non supervisée d'images. L'originalité de ce modèle repose sur l'utilisation simultanée de mesures de Dirac et de la mesure de Lesbegue au niveau même de la chaîne de Markov. Ce modèle autorise alors la coexistence de pixels durs (issus de la segmentation Markovienne classique) et *flous* (issus de la mesure floue) dans la même image. L'intégration d'une mesure floue dans un modèle statistique permet d'ajouter une mesure d'imprécision sur les données, à la mesure d'incertitude du modèle initial. Le modèle est illustré et analysé à l'aide de résultats comparatifs de segmentation non supervisée obtenus sur différents types d'images. La comparaison est effectuée avec d'une part, le modèle classique des chaînes de Markov cachées, et d'autre part, un algorithme aveugle flou.

Mots-clés :

Chaînes de Markov cachées, mesure floue, segmentation d'images, incertitude, imprécision.

Abstract:

In this paper, we propose to study a recent technic, called « fuzzy Hidden Markov Chain », for the unsupervised segmentation of images. The main characteristic of this recent model is to simultaneously use Dirac and Lesbegue measures at the class chain level. This model allows the coexistence of hard pixels (obtained with the classical HMC segmentation) and fuzzy pixels (obtained with the fuzzy measure) in the same picture. The integration of a fuzzy measure in a statistical model allows to add a measure of imprecision to the measure of uncertainty of the initial model. The model is illustrated and analyzed with comparative results of unsupervised segmentation for different types of images. The comparison is done one the one hand, with the classical HMC model, and, on the other hand, with a blind fuzzy model.

Keywords:

Hidden Markov chains, fuzzy measure, image segmentation, uncertainty, imprecision.

1 Introduction

La segmentation d'images est un problème majeur en traitement d'images. L'objectif est d'essayer de restituer une image segmentée (x), à partir d'une observation bruitée (y). Dans ce contexte, les chaînes de Markov cachées (CMC) ont été utilisées avec succès [6, 2], grâce à l'utilisation du parcours de Hilbert-Peano [10], qui convertit une image $2D$ en vecteur $1D$ (voir Fig. 1).

Le succès des CMC est principalement dû au fait que, lorsque le processus caché X peut être représenté par une chaîne de Markov finie et lorsque la structure du bruit n'est pas trop complexe, alors X peut être reconstruit à partir du processus observé Y à l'aide de différents critères bayésiens de classification tels que le MAP (« Maximum A Posteriori ») ou le MPM (« Maximal Posterior Mode »). De plus, il a été récemment montré que les CMC peuvent concurrencer les champs de Markov cachés en terme de précision de classification, tout en étant bien plus rapide, même si ces derniers fournissent une modélisation plus intuitive des relations spatiales dans les images [4].

Il est parfois intéressant de prendre en compte, non pas l'incertitude sur les obser-




Figure 1 – Construction du parcours de Peano pour une image 8×8 (initialisation, étapes intermédiaire et finale).

vations (mesure de probabilité), mais leur imprécision (mesure floue). Dans ce cas, différents modèles Markoviens flous ont été récemment développés [5, 1].

Cependant, l'intégration d'une mesure floue dans un modèle statistique classique permet de conserver les propriétés (mesure d'incertitude) de robustesse des CMC et d'enrichir le modèle avec une caractéristique floue (mesure d'imprécision). Cette intégration a déjà été réalisée en segmentation non supervisée d'images dans les contextes aveugle et contextuel [2], mais aussi pour les champs de Markov cachés (HMRF) [9]. Ceux-ci ont d'ailleurs été utilisés avec succès en imagerie médicale pour modéliser l'effet de volume partiel [8]. Bien que nous illustrions ce modèle dans le cadre de la segmentation d'images, il faut cependant signaler que le modèle des CMC flous reste valable dans les domaines d'application classiques des CMC, tels que le traitement de la parole, l'automatisme, ...

Dans ce travail, nous nous intéressons au modèle très récent qui adapte ce point de vue au contexte des CMC [3], et nous proposons de comparer les résultats de segmentation de ce modèle avec ceux issus du modèle classique des CMC, ainsi qu'avec ceux issus de la version aveugle floue proposée dans [2].

Ce papier est organisé de la manière suivante : un bref rappel sur les CMC est fait dans la section 2. Le modèle des CMC flous pour la segmentation d'images est détaillé dans la sec-

tion 3. L'estimation des paramètres, effectuée avec une extension de l'algorithme « Iterative Conditional Estimation » (ICE) [6, 2] est brièvement présentée dans la section 4. Les sections 5 et 6 illustrent le modèle en présentant des résultats comparatifs de segmentation non supervisée d'images. Enfin, la section 7 dresse le bilan théorique et expérimental de ce travail et propose quelques perspectives.

2 Modèle classique des CMC

On notera dans la suite $\mathbf{X}_{1 \rightarrow n}$ pour représenter le processus $\{X_1, \dots, X_n\}$ et \mathbf{x} pour désigner une réalisation du processus \mathbf{X} .

2.1 Principe des chaînes de Markov

Le processus $\mathbf{X} = \{X_n\}_{n \in \{1, \dots, N\}}$ est une chaîne de Markov finie d'ordre 1, de longueur N , à K états si et seulement si :

$$P(X_n = x_n \mid \mathbf{X}_{1 \rightarrow n-1} = \mathbf{x}_{1 \rightarrow n-1}) = P(X_n = x_n \mid X_{n-1} = x_{n-1}), \quad (1)$$

avec chaque X_n à valeur dans l'ensemble des états $\Omega = \{0, \dots, K-1\}$.

Nous ne considérons ici que le cas de la chaîne stationnaire, pour laquelle l'Eq. (1) ne dépend pas de la position n . On définit ainsi la matrice des probabilités de transition sur Ω :

$$\mathbf{T} = \{t_{i,j}\}, t_{i,j} = P(x_n = j \mid x_{n-1} = i), \\ \forall i, j \in \Omega \text{ et } \forall n \in \{2, \dots, N\}, \\ \text{avec } t_{i,j} \geq 0 \text{ et } \sum_{j=0}^{K-1} t_{i,j} = 1.$$

Le vecteur de probabilité initial est défini par :

$$\pi_i = P(X_1 = i), \forall i \in \Omega.$$

2.2 Mise en oeuvre des CMC

Dans le contexte des CMC, on considère que \mathbf{x} est caché, et qu'il doit être retrouvé à partir du seul processus \mathbf{Y} .

De façon classique, les méthodes de segmentation d'images basées sur les CMC considèrent les deux hypothèses suivantes :

- H_1 : les variables aléatoires Y_1, \dots, Y_N sont indépendantes conditionnellement à \mathbf{X}
- H_2 : la distribution de chaque Y_n conditionnellement à \mathbf{X} est égale à sa distribution conditionnellement à X_n .

Notons $\mathbf{x} = \mathbf{x}_{1 \rightarrow N}$, la réalisation d'une chaîne de Markov stationnaire ; on peut alors calculer la probabilité de \mathbf{x} :

$$P(\mathbf{X} = \mathbf{x}) = \pi_{x_1} \prod_{n=2}^N t_{x_{n-1}, x_n}.$$

En supposant que la distribution de (X_n, Y_n) est indépendante de n , chaque valeur x_n de l'espace des états est associée à une distribution, qui caractérise la répartition des observations y_n conditionnellement à x_n :

$$f_{x_n}(y_n) = P(Y_n = y_n | X_n = x_n). \quad (2)$$

Étant donné une séquence d'observation $\mathbf{y} = \mathbf{y}_{1 \rightarrow N}$, on peut alors calculer la probabilité conjointe de $(\mathbf{X} = \mathbf{x}, \mathbf{Y} = \mathbf{y})$ comme :

$$P(\mathbf{X} = \mathbf{x}, \mathbf{Y} = \mathbf{y}) = \pi_{x_1} f_{x_1}(y_1) \prod_{n=2}^N t_{x_{n-1}, x_n} f_{x_n}(y_n).$$

La distribution $P(\mathbf{X} = \mathbf{x} | \mathbf{Y} = \mathbf{y})$ est inconnue et doit être estimée avant de pouvoir appliquer une technique de classification bayésienne. Par conséquent, il est nécessaire d'estimer les deux ensembles de paramètres suivants, à partir des seules données \mathbf{y} :

1. L'ensemble Γ constitué des paramètres de la chaîne de Markov stationnaire, i.e. le vecteur de probabilité initial $\boldsymbol{\pi} = (\pi_i)_{\forall i \in \Omega}$ et la matrice de transition \mathbf{T} .
2. L'ensemble Δ caractérisant les K densités de probabilités présentées dans l'Eq. (2). Dans le cas gaussien, Δ est uniquement constitué de la moyenne et de la variance associées à chaque classe.

Cette estimation peut être réalisée avec les algorithmes d'estimation tels que EM (Expectation-Maximization), SEM (Stochastic EM) ou ICE (Iterative Conditional Estimation) [6].

3 Modèle des CMC floues

Considérons maintenant l'exemple de la segmentation d'une image satellite en deux classes : « terre » et « mer ». Il paraît évident qu'il y aura des pixels correspondant uniquement à la « terre » et d'autres correspondant uniquement à la « mer ». Mais, compte-tenu de la méthode d'acquisition et de la configuration de la scène observée, il peut aussi exister de nombreux pixels, sur la côte notamment, pour lesquels la « terre » et la « mer » seront simultanément présents. L'introduction d'une mesure floue va permettre de prendre en compte les caractéristiques spécifiques de ces pixels.

On peut donc considérer que l'on a dans l'image 2 classes « pures », numérotées 0 pour la « terre » et 1 pour la « mer », qui correspondent aux pixels uniquement constitués de « terre » ou de « mer ». Dorénavant, nous qualifierons ces classes de « dures ». On peut aussi considérer qu'il y a une troisième classe dans l'image, une classe floue, correspondant aux pixels « mixtes », constitués à la fois de « terre » et de « mer ». En introduisant la mesure floue \bar{A} : « Le pixel appartient à la classe « dure 0 » », ainsi que sa fonction d'appartenance $\mu_{\bar{A}}$, nous pouvons maintenant donner, pour chaque pixel, un degré d'appartenance à la classe « mer ».

3.1 Représentation

Comme détaillé dans [2, 9], une façon d'introduire une classe floue dans un modèle statistique de ce type est de considérer que X_n ne prend plus ses valeurs dans l'ensemble $\{0, 1\}$, mais dans l'intervalle continu $[0, 1]$.

La nouvelle représentation de $X_n = \varepsilon_n$ est alors la suivante :

- $\varepsilon_n = 0$ si le pixel est de classe 0,
- $\varepsilon_n = 1$ si le pixel est de classe 1,
- $\varepsilon_n \in]0, 1[$ si le pixel est flou.

Chaque élément X_n peut maintenant être de deux types :

- de type discret (composante « dure »)
- ou de type continu (composante « floue »).

3.2 Expression des probabilités

La nouvelle approche requiert donc la définition des probabilités de la chaîne sur $\Omega = [0, 1]$. En notant δ_0, δ_1 les mesures de Dirac en 0 et 1 et μ la mesure de Lebesgue sur $]0, 1[$ et en prenant $\nu = \delta_0 + \delta_1 + \mu$ comme mesure sur $[0, 1]$, la distribution de X_n peut alors être définie par une densité h sur $[0, 1]$ selon la mesure ν .

En supposant que \mathbf{X} est homogène et que la distribution de chaque X_n est uniforme sur la classe floue, $P(X_n = \varepsilon_n)$ peut s'écrire :

$$P(X_n = \varepsilon_n) = \begin{cases} h(0) = \pi_0 & \text{si } \varepsilon_n = 0, \\ h(1) = \pi_1 & \text{si } \varepsilon_n = 1, \\ h(\varepsilon_n) = 1 - \pi_0 - \pi_1 & \text{sinon.} \end{cases}$$

L'expression des probabilités de transition de la chaîne de Markov floue est la suivante :

$$\begin{aligned} P(X_n = \varepsilon_n | X_{n-1} = \varepsilon_{n-1}) = \\ P(X_n = 0 | \varepsilon_{n-1}) \delta_0(\varepsilon_n) \\ + P(X_n = \varepsilon_n | \varepsilon_{n-1}) 1_{]0,1[}(\varepsilon_n) \\ + P(X_n = 1 | \varepsilon_{n-1}) \delta_1(\varepsilon_n). \end{aligned}$$

4 Estimation des paramètres

Avant de pouvoir appliquer un quelconque critère de classification bayésien et de façon similaire aux CMC classiques, il reste maintenant à définir $\mathbf{X} | \mathbf{Y}$. Nous considérons toujours les deux hypothèses \mathbf{H}_1 et \mathbf{H}_2 évoquées ci-dessus, et les deux ensembles de paramètres identifiés dans le cas classique $\{\Gamma, \Delta\}$ demeurent inchangés.

4.1 Principe de l'algorithme ICE

Pour l'estimation des paramètres de $\Theta = \{\Gamma, \Delta\}$, nous avons utilisé une extension de l'algorithme ICE [6] qui peut être considéré comme une alternative à l'algorithme EM (Estimation-Maximization). En fait, ICE ne se réfère pas à la vraisemblance, une notion qui est difficile à tenir dans le contexte de notre étude, mais est basé sur l'espérance conditionnelle des estimateurs à partir des données

complètes (\mathbf{x}, \mathbf{y}) . Il s'agit d'une méthode itérative qui produit une séquence d'estimations θ^q des paramètres θ selon le principe suivant :

1. Initialisation : θ^0 obtenue à l'aide d'un algorithme de classification initiale (K -moyennes par exemple),
2. Induction : $\theta^{q+1} = E_q[\hat{\theta}(\mathbf{X}, \mathbf{Y}) | \mathbf{Y} = \mathbf{y}]$, où $\hat{\theta}(\mathbf{X}, \mathbf{Y})$ est un estimateur de θ .
3. Arrêt : En pratique, on arrête l'algorithme à l'itération Q si $\theta^{Q-1} \approx \theta^Q$.

Cette procédure conduit à deux situations différentes détaillées ci-dessous.

4.2 Estimation des paramètres de Γ

Comme dans le cas classique, les paramètres de Γ peuvent être calculés analytiquement en utilisant l'algorithme normalisé de Baum-Welch [7]. Dans ce nouveau contexte, les probabilités forward et backward sont définies par :

$$\begin{aligned} \alpha_{n+1}(\xi) &\propto \int_{]0,1[} \alpha_n(\zeta) t_{\zeta,\xi} f_{\xi}(y_{n+1}) d\zeta, \\ \beta_n(\xi) &\propto \int_{]0,1[} \beta_{n+1}(\zeta) t_{\xi,\zeta} f_{\zeta}(y_{n+1}) d\zeta. \end{aligned} \quad (3)$$

Les intégrales mises en jeu lors de l'estimation des paramètres de la chaîne ne peuvent pas être calculées de façon analytique. Une intégration numérique doit être effectuée en discrétisant l'intervalle $]0, 1[$. On obtient ainsi F classes floues « discrètes », dont la valeur floue correspond à la valeur médiane du sous-intervalle considéré. Par exemple, $F = 2$ implique $\varepsilon \in \{0.25, 0.75\}$, $F = 3$ implique $\varepsilon \in \{0.165, 0.5, 0.825\}$, ... Plus F est grand, plus l'estimation des paramètres est précise.

4.3 Estimation des paramètres de Δ

L'ensemble Δ doit lui aussi être estimé dans ce nouveau contexte. Il s'agit en fait des paramètres des lois de l'Eq. (2).

En supposant que la répartition des observations de chaque état suit une loi gaussienne et

en notant $\mathcal{N}(m, \sigma^2)$ la distribution normale de moyenne m et de variance σ^2 , les densités de probabilité des classes « dures » de l'Eq. (2) peuvent s'écrire :

$$\begin{aligned}\varepsilon_n = 0 &: \mathcal{N}(m_0, \sigma_0^2), \\ \varepsilon_n = 1 &: \mathcal{N}(m_1, \sigma_1^2).\end{aligned}$$

Pour les paramètres des classes « dures » $\{m_0, m_1, \sigma_0, \sigma_1\}$ de Δ , θ^{q+1} n'est pas calculable directement. Cependant, ces paramètres peuvent être estimés en calculant la moyenne empirique de plusieurs estimations obtenues à partir de réalisations avec $\theta^{q+1} = \frac{1}{L} \sum_{l=1}^L \hat{\theta}(\mathbf{x}^l, \mathbf{y})$, où \mathbf{x}^l est une réalisation *a posteriori* de $\mathbf{X} | \mathbf{Y}$. Il a été montré que $\mathbf{X} | \mathbf{Y}$ est une chaîne de Markov non stationnaire, dont les paramètres peuvent être calculés à partir des probabilités Forward-Backward de l'Eq. (3).

Revenons sur l'exemple d'introduction du modèle flou. En définissant la mesure floue \bar{A} : « Le pixel appartient à la classe « dure 0 » », et la fonction d'appartenance μ_A qui lui est associée, on peut alors estimer les paramètres « flous » de Δ . Prenons comme fonction d'appartenance μ_A la fonction présentée ci-dessous :

$$\mu_A(m) = \begin{cases} 1 - \frac{m_1 - m}{m_1 - m_0} & \forall m \in [m_0, m_1], \\ 0 & \text{sinon.} \end{cases}$$

La définition des moments associés aux classes floues est maintenant implicite :

$$\varepsilon_n \in]0, 1[: \mathcal{N}\left(\frac{(1 - \varepsilon_n)m_0 + \varepsilon_n m_1}{(1 - \varepsilon_n)^2 \sigma_0^2 + \varepsilon_n^2 \sigma_1^2}\right).$$

En fait, l'intégration d'une notion floue sur l'espace des états de la chaîne de Markov revient à l'introduction d'une mesure floue sur l'espace des moments associés à chaque état. La Fig. 2 présente la fonction d'appartenance μ_A de la mesure floue \bar{A} sur l'espace des moments qui lui est associé. De fait, on peut facilement imaginer une fonction d'appartenance différente (non linéaire) sur l'espace des moments, et par conséquence, obtenir une répartition du flou différente sur l'espace des états.




Figure 2 – Fonction d'appartenance μ_A de la mesure floue \bar{A} .

5 Segmentation d'un nuage



Figure 3 – Extrait d'une image optique (432×208) provenant de la navette spatiale, acquise le 2 février 1984, près de la rivière Parana dans le sud du Brésil.




Figure 4 – Résultats de segmentation obtenus avec (a) le modèle des CMC (3 classes) et (b) des CMC floues ($F = 1$).

Le modèle des CMC floues a été testé sur une image optique de nuage, présentée sur la Fig. 3. Cette image est bien adaptée au nouveau modèle flou, dans la mesure où, le ciel opaque et le coeur de nuage (nuage dense) peuvent être considérés comme les 2 classes « dures » de l'image, et le dégradé entre les deux comme la zone floue. On peut tout de suite constater que la segmentation en 2 classes (ciel/nuage) est loin d'être évidente, même pour un observateur humain.




Figure 5 – Résultats de segmentation obtenus avec (a), (b) et (c) le modèle aveugle ICE flou et (d), (e) et (f) le modèle des CMC floues pour différentes valeurs de F .

5.1 Comparaison CMC / CMC floues

La Fig. 4 présente les résultats de segmentation obtenus avec le modèle des CMC classiques à 3 classes et avec le modèle des CMC floues à 2 classes dures et 1 classe floue.

L'estimation des paramètres a été effectuée avec 100 itérations ICE pour les deux modèles (cas gaussien). La segmentation a été obtenue avec le critère du MPM pour le modèle des CMC, et le critère du MPM flou détaillé dans [9] pour le modèle des CMC floues.

On peut constater que la forme globale du nuage et de la zone correspondant au nuage dense semblent être segmentées de façon beaucoup plus précise avec les CMC floues. En effet, en observant la partie droite du nuage, on se rend compte que celui-ci se scinde en deux nuages distincts. De fait, la zone de scission est moins dense, et correspond plutôt à une zone floue, qu'au coeur du nuage. Le modèle flou a bien caractérisé cette zone, alors que le modèle classique n'en a pas tenu compte. Ces résultats semblent confirmer l'intérêt du nouveau modèle.

La prise en compte d'un nombre plus élevé de classes dans le modèle classique des CMC n'a pas beaucoup d'intérêt. En effet, dans ce type d'application, les classes supplémentaires

ont tendance à se spécialiser sur des pixels isolés, produisant ainsi des segmentations très peu différentes de celle présentée sur la Fig. 4-(a). C'est pourquoi dans la suite, nous limiterons notre comparaison du modèle flou avec le modèle classique à 3 classes.

5.2 Comparaison ICE flou aveugle / CMC floues

La Fig. 5 présente les résultats de segmentation obtenus avec le modèle des CMC floues (ligne inférieure), et avec le modèle aveugle de l'algorithme ICE flou détaillé dans [2] (ligne supérieure). Pour les deux cas, les résultats présentés correspondent à la segmentation avec 2 classes dures et différentes valeurs F de classes floues.

On peut constater que les deux modèles n'ont pas le même comportement. L'algorithme d'estimation des paramètres étant le même, cette différence est en fait due à la Markoviannité du processus mis en jeu dans les CMC. On peut aussi observer que le modèle ICE flou aveugle a tendance à identifier les zones floues sur peu de pixels, alors que le modèle des CMC floues est capable d'identifier des zones floues plus étendues et spatialement homogènes. De plus, le fait que le modèle ICE flou aveugle soit un modèle local (qui n'utilise pas de mémoire) ex-

plique le type de segmentation qu'il fournit. On peut aussi constater que l'augmentation du nombre de classes floues améliore la segmentation, et ceci plus spécialement dans le cas des CMC floues. Une interprétation possible du flou dans ce cas précis, pourrait être de faire correspondre à chaque niveau de flou donné, une densité de nuage donnée.

En fait, le modèle des CMC floues semble être utile dans les situations où l'objectif est de détecter et caractériser des frontières qui ne sont pas clairement définies, alors que la plupart des algorithmes de segmentation en sont incapables.

6 Segmentation d'une galaxie

La Fig. 6 présente une image de la galaxie du tourbillon M51 (NGC 5194) acquise avec le télescope WHT. Cette galaxie, de type spirale, est en interaction avec une autre galaxie plus petite (NGC 5195) (coin supérieur gauche de l'image). Les galaxies spirales comportent deux éléments principaux : un disque, aplati et très étendu et un bulbe de forme ellipsoïdale.



Figure 6 – Image de la Galaxie M51 (dite du tourbillon) (490×900) acquise avec le télescope WHT (îles Canaries) le 1 juin 2000.

La Fig. 7 présente les résultats de segmentation obtenus à l'aide du modèle des CMC classique (a) et du nouveau modèle des CMC floues (b) ($F = 1$) pour 50 itérations ICE.

Elle montre clairement les différences entre les deux modèles. En comparant les deux résultats de segmentation, on peut constater que le modèle des CMC floues a identifié les deux




Figure 7 – Résultats de segmentation obtenus à l'aide (a) du modèle des CMC classique et (b) du nouveau modèle des CMC floues ($F = 1$).

bulbes des galaxies, ainsi que le bras spiral qui les relie, alors que le modèle classique non, et ceci pour un temps de calcul comparable.

La Fig. 8 présente les résultats de segmentation obtenus avec le modèle des CMC floues pour différentes valeurs F de classes floues.

Comme précédemment, plus on augmente le nombre de classes floues, plus la segmentation est précise. L'augmentation du nombre de classes floues permet ainsi d'améliorer la segmentation des bulbes, des disques et des bras associés à chaque galaxie. Une application possible de ce type de segmentation serait de servir de pré-traitement aux algorithmes de classification et d'identification automatique de galaxies.

Le modèle des CMC floues permet donc de segmenter, de façon non supervisée, des images présentant de forts dégradés, et pour lesquelles le modèle classique des CMC semble inadapté.

7 Conclusion

Dans ce travail, nous avons présenté l'application du modèle des CMC floues pour la segmentation non supervisée d'images. L'originalité du modèle réside dans l'intégration d'une mesure floue dans un modèle de chaînes de Markov cachées, et sur l'utilisation d'une extension floue de l'algorithme de Baum-Welch pour l'estimation des paramètres.

Les expériences menées sur différents types d'images ont montré que les CMC floues semblent être utiles dans les situations où l'objectif est de détecter et caractériser des

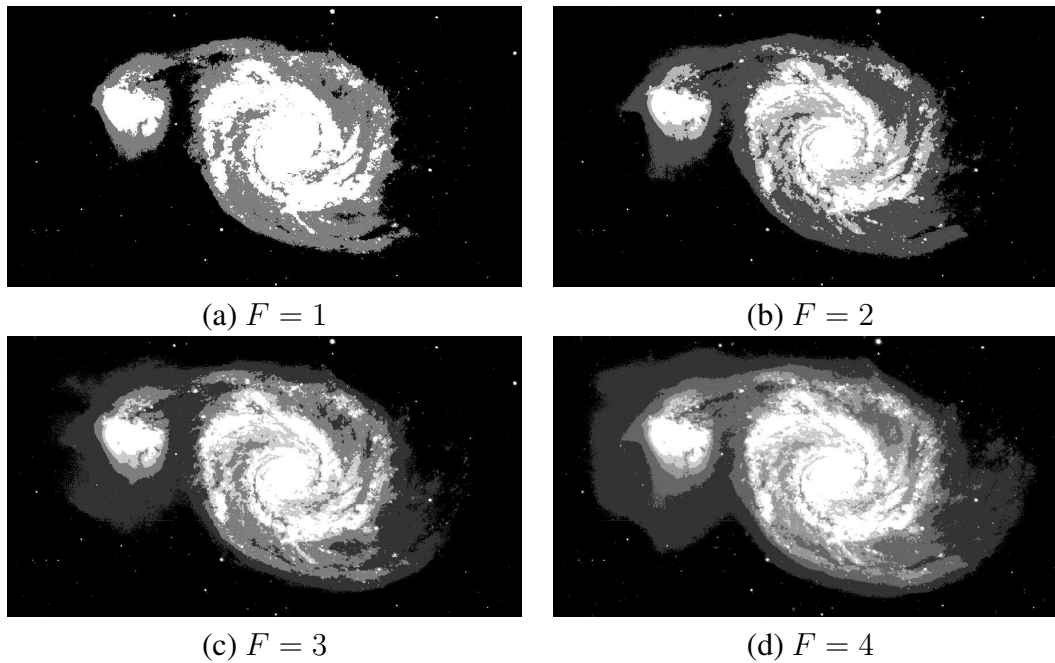


Figure 8 – Résultats de segmentation obtenus avec le modèle des CMC floues pour différents nombres de classes floues F .

frontières qui ne sont pas clairement définies, ou présentant un fort dégradé. Nous avons aussi pu constater que la prise en compte de la mesure d'imprécision sur les données, en complément de la mesure d'incertitude propre aux CMC, permet d'améliorer la qualité de la segmentation. Il faut cependant noter qu'il n'y a pas de rivalité entre les segmentations dures et floues, mais qu'elles correspondent à des situations différentes. En ce sens, le modèle des CMC floues est capable de traiter des situations dans lesquelles les CMC classiques sont inefficaces.

Comme perspectives à ce travail, nous pouvons citer l'utilisation d'autres fonctions d'appartenance associée à la mesure floue, ce qui reviendrait à l'utilisation de densités h non uniformes. Une autre perspective en cours d'étude est l'extension du modèle au cas général à K classes dures, qui est plus délicat.

Références

- [1] K.E. Avrachenkov, E. Sanchez. Fuzzy Markov chains. *Fuzzy Optimization and Decision Making*, 1(2) : 143-159, 2002.
- [2] H. Caillol, W. Pieczynski, A. Hillion. Estimation of fuzzy Gaussian mixture and unsupervised statistical image segmentation. *IEEE Trans. on Im. Proc.*, 6(3) : 425-440, 1997.
- [3] C. Carincotte, S. Derrode, G. Sicot, J.M. Boucher. Unsupervised image segmentation based on a new fuzzy HMC model. *IEEE ICASSP, Montréal, Canada, 17-21 Mai 2004*.
- [4] R. Fjørtoft, Y. Delignon, W. Pieczynski, M. Sigelle, F. Tupin. Unsupervised segmentation of radar images using HMC and HMRF. *IEEE Trans. Geosci. Rem. Sens.*, 41(3) : 675-686, 2003.
- [5] M.A. Mohamed, P. Gader. Generalized hidden Markov models-Part I : Theoretical frameworks. *IEEE Trans. on Fuzzy Syst.*, 8(1) : 67-81, 2000.
- [6] W. Pieczynski. Statistical image segmentation. *Mach. Graph. and Vis.*, 1 : 261-268, 1992.
- [7] L. Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition. *Proc. IEEE*, 77 : 257-286, 1989.
- [8] S. Ruan, B. Moretti, J. Fadili, D. Bloyet. Fuzzy Markovian segmentation in application of magnetic resonance images. *Comp. Vis. and Im. Under.*, 85(1) : 54-69, 2002.
- [9] F. Salzenstein, W. Pieczynski. Parameter estimation in hidden fuzzy Markov random fields and image segmentation. *Graph. Mod. and Im. Proc.*, 59(4) : 205-220, 1997.
- [10] W. Skarbek. Generalized Hilbert scan in image printing. *Theoretical Foundations of Computer Vision*. R. Klette and W. G. Kropetsh, Akademik Verlag, Berlin, 1992.