

Optimisation de critères statistiques pour la segmentation, l'évaluation ou la fusion de données

Présentation de la méthodologie et étude des GITCs en IRM multimodale

S. Jehan-Besson

Chercheur CNRS
LITO U1288 INSERM Institut Curie

Réunion LITO, 7 Avril 2021

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Introduction

Compétences

- **Postes occupés**

- Maître de Conférence ENSICAEN (école d'ingénieurs, option Traitement des Images), Caen
- Chercheur CNRS LIMOS, Clermont-Ferrand
- Chercheur CNRS GREYC, Caen
- depuis janvier 2021 : Chercheur CNRS mise à disposition au LITO

- **Domaines de compétences**

- Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation**
- **Suivi/Segmentation**
- **Filtrage, Restauration d'images**
- **Évaluation/Fusion**

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation**

- **Variable à optimiser** : Une région $\Omega \in \mathcal{R}^n$ de frontière $\partial\Omega$ dans une image I .
- **Critère à optimiser** : Exemple segmentation d'une région homogène

$$J(\Omega) = \int_{\Omega} (I(\mathbf{x}) - \mu(\mathbf{x}))^2 d\mathbf{x} + \int_{\partial\Omega} ds$$

- **Méthode d'optimisation** : Gradients de forme, optimisation de domaines

$$\langle J'(\Omega), V \rangle = ?$$

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation**

- **Variable à optimiser** : Une région $\Omega \in \mathcal{R}^n$ de frontière $\partial\Omega$ dans une image I .
- **Critère à optimiser** : Exemple segmentation d'une région homogène

$$J(\Omega) = \int_{\Omega} (I(\mathbf{x}) - \mu(\mathbf{x}))^2 d\mathbf{x} + \int_{\partial\Omega} ds$$

- **Méthode d'optimisation** : Gradients de forme, optimisation de domaines

$$\langle J'(\Omega), V \rangle = ?$$

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation**

- **Variable à optimiser** : Une région $\Omega \in \mathcal{R}^n$ de frontière $\partial\Omega$ dans une image I .
- **Critère à optimiser** : Exemple segmentation d'une région homogène

$$J(\Omega) = \int_{\Omega} (I(\mathbf{x}) - \mu(\mathbf{x}))^2 d\mathbf{x} + \int_{\partial\Omega} ds$$

- **Méthode d'optimisation** : Gradients de forme, optimisation de domaines

$$\langle J'(\Omega), V \rangle = ?$$

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation**

- **Variable à optimiser** : Une région $\Omega \in \mathcal{R}^n$ de frontière $\partial\Omega$ dans une image I .
- **Critère à optimiser** : segmentation d'une région homogène (Chan et Vese)
- **Méthode d'optimisation** : Gradients de forme, optimisation de domaines



Contour initial

Contour en évolution

Contour final

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Filtrage**

- **Variable à optimiser** : L'image débruitée u estimée à partir d'une image f
- **Critère à optimiser** : Exemple minimisation de la variation totale + norme L^1 ou L^2

$$J(u) = \int g(\mathbf{x}) |\nabla u| + \lambda \int (f(\mathbf{x}) - u(\mathbf{x}))^T d\mathbf{x}$$

- **Méthode d'optimisation** : optimisation convexe, approches duales, Lagrangien augmenté, méthodes de relaxation par blocs d'Uzawa

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Filtrage**

- **Variable à optimiser** : L'image débruitée u estimée à partir d'une image f
- **Critère à optimiser** : Exemple minimisation de la variation totale + norme L^1 ou L^2

$$J(u) = \int g(\mathbf{x}) |\nabla u| + \lambda \int (f(\mathbf{x}) - u(\mathbf{x}))^T d\mathbf{x}$$

- **Méthode d'optimisation** : optimisation convexe, approches duales, Lagrangien augmenté, méthodes de relaxation par blocs d'Uzawa

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Filtrage**

- **Variable à optimiser** : L'image débruitée u estimée à partir d'une image f
- **Critère à optimiser** : Exemple minimisation de la variation totale + norme L^1 ou L^2

$$J(u) = \int g(\mathbf{x}) |\nabla u| + \lambda \int (f(\mathbf{x}) - u(\mathbf{x}))^T d\mathbf{x}$$

- **Méthode d'optimisation** : optimisation convexe, approches duales, Lagrangien augmenté, méthodes de relaxation par blocs d'Uzawa

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

- **Filtrage** : Exemple en utilisant la Variation Totale (TV) pondérée ou non par une fonction dépendant du gradient avec la norme L^1 ou L^2

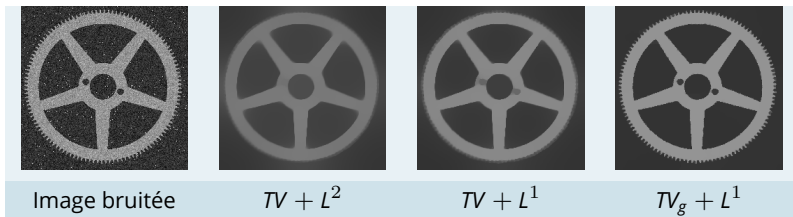


Figure 1: Filtrage/débruitage d'images par approches continues

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

- **Filtrage** : Exemple de filtrage géométrique interactif sur des images couleur en utilisant les moments couleur

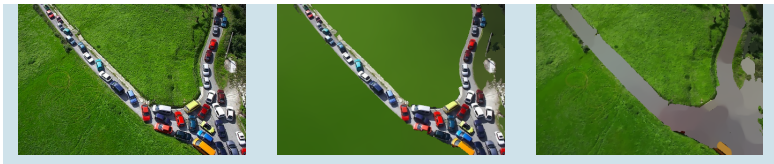


Figure 2: Exemple de filtrage géométrique sur une image couleur

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation** [4 chapitres de livres, IRBM 2014, IPTA 2016, SIAM 2003 ...]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE, segmentation de tumeurs 3D en IRM multimodale
- **Suivi / Mouvement** [IRBM 2014, EMBS 2009, VLSI 2008, JMIV 2006...]
→ Travaux en perspectives ANR VOCALISE, échographie des cordes vocales
- **Filtrage, Restauration d'images** [CAIP 2013, CPCV 2012, VISAPP 2010, JMIV 2010...]
→ Filtrage à étudier pour l'imagerie médicale / preprocessing
- **Évaluation/Fusion** [ArXiv2021, ICIP 2014]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation** [4 chapitres de livres, IRBM 2014, IPTA 2016, SIAM 2003 ...]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE, segmentation de tumeurs 3D en IRM multimodale
- **Suivi / Mouvement** [IRBM 2014, EMBS 2009, VLSI 2008, JMIV 2006...]
→ Travaux en perspectives ANR VOCALISE, échographie des cordes vocales
- **Filtrage, Restauration d'images** [CAIP 2013, CPCV 2012, VISAPP 2010, JMIV 2010...]
→ Filtrage à étudier pour l'imagerie médicale / preprocessing
- **Évaluation/Fusion** [ArXiv2021, ICIP 2014]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation** [4 chapitres de livres, IRBM 2014, IPTA 2016, SIAM 2003 ...]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE, segmentation de tumeurs 3D en IRM multimodale
- **Suivi / Mouvement** [IRBM 2014, EMBS 2009, VLSI 2008, JMIV 2006...]
→ Travaux en perspectives ANR VOCALISE, échographie des cordes vocales
- **Filtrage, Restauration d'images** [CAIP 2013, CPCV 2012, VISAPP 2010, JMIV 2010...]
→ Filtrage à étudier pour l'imagerie médicale / preprocessing
- **Évaluation/Fusion** [ArXiv2021, ICIP 2014]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE

Introduction

Optimisation de critères continus pour la segmentation, le suivi d'objets, le filtrage et l'évaluation

Le point commun de ces approches consiste en la modélisation du problème par un critère à optimiser. La **variable à optimiser**, le **critère** ainsi que la **méthode d'optimisation** vont dépendre du problème posé.

- **Segmentation** [4 chapitres de livres, IRBM 2014, IPTA 2016, SIAM 2003 ...]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE, segmentation de tumeurs 3D en IRM multimodale
- **Suivi / Mouvement** [IRBM 2014, EMBS 2009, VLSI 2008, JMIV 2006...]
→ Travaux en perspectives ANR VOCALISE, échographie des cordes vocales
- **Filtrage, Restauration d'images** [CAIP 2013, CPCV 2012, VISAPP 2010, JMIV 2010...]
→ Filtrage à étudier pour l'imagerie médicale / preprocessing
- **Évaluation/Fusion** [ArXiv2021, ICIP 2014]
→ méthodologie présentée dans cet exposé / Projet BIOMEDE

Introduction

Difficultés de la Segmentation en imagerie médicale

- Complexité d'analyse et d'interprétation des niveaux de gris de l'image (bruit complexe, différentes caractéristiques tissulaires, absence de gradient ...)
 - nécessité de pouvoir intégrer des modélisations statistiques avancées
- Diversité et complexité des données à traiter et analyser (2D, 2D+t, 3D, 3D+t, multimodalité ...)
 - nécessité d'avoir un modèle de contour ou de surface précis, + appréhender l'aspect multidimensionnel (2D ou 3D), l'aspect temporel et l'aspect multimodalité
- Des technologies en constante évolution
 - nécessité de développer des modèles génériques et flexibles
- Faible quantité de données expertisées pour certaines pathologies rares (exemple: GITC, Projet BIOMEDE)
 - Intérêt des approches hybrides combinant apprentissage et modélisations intrinsèques
- Utilisation de ces outils dans un contexte clinique par des experts en médecine
 - nécessité de développer des indices de variabilité, de confiance et repositionnement

Difficultés de la Segmentation en imagerie médicale

- Complexité d'analyse et d'interprétation des niveaux de gris de l'image (bruit complexe, différentes caractéristiques tissulaires, absence de gradient ...)
 - nécessité de pouvoir intégrer des modélisations statistiques avancées
- Diversité et complexité des données à traiter et analyser (2D, 2D+t, 3D, 3D+t, multimodalité ...)
 - nécessité d'avoir un modèle de contour ou de surface précis, + appréhender l'aspect multidimensionnel (2D ou 3D), l'aspect temporel et l'aspect multimodalité
- Des technologies en constante évolution
 - nécessité de développer des modèles génériques et flexibles
- Faible quantité de données expertisées pour certaines pathologies rares (exemple: GITC, Projet BIOMEDE)
 - Intérêt des approches hybrides combinant apprentissage et modélisations intrinsèques
- Utilisation de ces outils dans un contexte clinique par des experts en médecine
 - nécessité de développer des indices de variabilité, de confiance et repositionnement

Introduction

Difficultés de la Segmentation en imagerie médicale

- Complexité d'analyse et d'interprétation des niveaux de gris de l'image (bruit complexe, différentes caractéristiques tissulaires, absence de gradient ...)
 - nécessité de pouvoir intégrer des modélisations statistiques avancées
- Diversité et complexité des données à traiter et analyser (2D, 2D+t, 3D, 3D+t, multimodalité ...)
 - nécessité d'avoir un modèle de contour ou de surface précis, + appréhender l'aspect multidimensionnel (2D ou 3D), l'aspect temporel et l'aspect multimodalité
- Des technologies en constante évolution
 - nécessité de développer des modèles génériques et flexibles
- Faible quantité de données expertisées pour certaines pathologies rares (exemple: GITC, Projet BIOMEDE)
 - Intérêt des approches hybrides combinant apprentissage et modélisations intrinsèques
- Utilisation de ces outils dans un contexte clinique par des experts en médecine
 - nécessité de développer des indices de variabilité, de confiance et repositionnement

Difficultés de la Segmentation en imagerie médicale

- Complexité d'analyse et d'interprétation des niveaux de gris de l'image (bruit complexe, différentes caractéristiques tissulaires, absence de gradient ...)
 - nécessité de pouvoir intégrer des modélisations statistiques avancées
- Diversité et complexité des données à traiter et analyser (2D, 2D+t, 3D, 3D+t, multimodalité ...)
 - nécessité d'avoir un modèle de contour ou de surface précis, + appréhender l'aspect multidimensionnel (2D ou 3D), l'aspect temporel et l'aspect multimodalité
- Des technologies en constante évolution
 - nécessité de développer des modèles génériques et flexibles
- Faible quantité de données expertisées pour certaines pathologies rares (exemple: GITC, Projet BIOMEDE)
 - Intérêt des approches hybrides combinant apprentissage et modélisations intrinsèques
- Utilisation de ces outils dans un contexte clinique par des experts en médecine
 - nécessité de développer des indices de variabilité, de confiance et repositionnement

Introduction

Difficultés de la Segmentation en imagerie médicale

- Complexité d'analyse et d'interprétation des niveaux de gris de l'image (bruit complexe, différentes caractéristiques tissulaires, absence de gradient ...)
 - nécessité de pouvoir intégrer des modélisations statistiques avancées
- Diversité et complexité des données à traiter et analyser (2D, 2D+t, 3D, 3D+t, multimodalité ...)
 - nécessité d'avoir un modèle de contour ou de surface précis, + appréhender l'aspect multidimensionnel (2D ou 3D), l'aspect temporel et l'aspect multimodalité
- Des technologies en constante évolution
 - nécessité de développer des modèles génériques et flexibles
- Faible quantité de données expertisées pour certaines pathologies rares (exemple: GITC, Projet BIOMEDE)
 - Intérêt des approches hybrides combinant apprentissage et modélisations intrinsèques
- Utilisation de ces outils dans un contexte clinique par des experts en médecine
 - nécessité de développer des indices de variabilité, de confiance et repositionnement

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Segmentation

Optimisation d'un critère : 2 Aspects

1. Modélisation continue : **Introduction d'un critère à optimiser**
2. **Résolution du problème d'optimisation :**

Optimisation d'un critère

1. Modélisation continue : **Introduction d'un critère à optimiser**

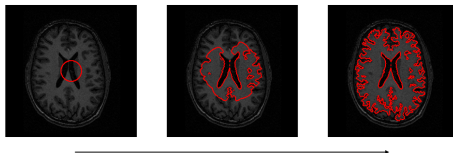
$$J(\Omega) = \int_{\Omega} k(\mathbf{x}, \Omega) d\mathbf{x} + \int_{\partial\Omega} k(s) ds$$

- Critère incluant des termes basés régions ou contour qui vont nous permettre d'introduire des informations sur le domaine recherché
- Différentes fonctions $k(\mathbf{x}, \Omega)$ peuvent être étudiés pour différentes applications : segmentation et suivi d'objets dans les images et les vidéos, segmentation de régions couleur, segmentation de régions 2D ou 3D, modèle de bruit, a priori sur la forme, segmentation ou suivi de régions non homogènes en utilisant des densités de probabilité non paramétriques ...

Optimisation d'un critère

2. Résolution du problème d'optimisation :

- Calcul de l'équation d'évolution en utilisant les fonctions des ensembles de niveaux régularisées [Chan et Vese 2001]
- Outils d'optimisation de domaines [Delfour et Zolesio] : dérivation par rapport au domaine pour obtenir l'équation d'évolution d'un contour [Jehan-Besson, Barlaud, Aubert IJCV 2003]

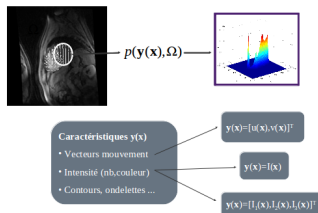


- Approches duales, optimisation convexe : recherche du domaine par seuillage d'une fonction u optimale [Esedoglu et al SIAM 2006, Bresson et al JMIV 2007]

Segmentation

Cadre statistique pour la segmentation et le suivi

De nombreux critères peuvent être modélisés sous la forme de l'optimisation de fonctions de densités de probabilités en prenant $k(x, \Omega) \rightarrow \varphi(p(y(x), \Omega))$ (changement du domaine d'intégration pour la fonctionnelle).



NB : Les densités de probabilités utilisées vont permettre de tirer bénéfice de la répartition (fréquence) de caractéristiques de l'image scalaires ou vectorielles.

Cadre statistique pour la segmentation et le suivi

Dépendant de la nature de la région et de la physique d'acquisition du signal, la pdf pourra être paramétrique ou non paramétrique :

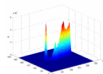
$$k(\mathbf{x}, \Omega) = \varphi(p(\mathbf{y}(\mathbf{x}), \Omega))$$

pdf paramétrique



famille exponentielle (modèle de bruit)
Impact de la méthode d'estimation

pdf non paramétrique

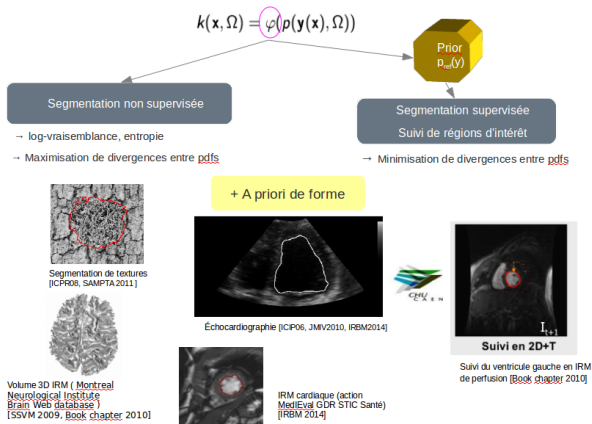


fenêtre de Parzen

- pdfs paramétriques (famille exponentielle) : [Martin et al 2004; Galland et al 2005], [Lecellier et al 2006/2010]
- pdfs non paramétriques (parzen) : [Aubert et al SIAM 2003]; [Kim et al 2003]; [Rougon, Petitjean, et al 2005]; [Rathi et al 2006]; [Herbulot et al 2006]; [Michailovich, Rathi, Tannenbaum, 2007] ...

Segmentation

Cadre statistique pour la segmentation et le suivi



Optimisation de divergences entre pdfs

Pour la segmentation supervisée ou non supervisée, nous pouvons introduire l'optimisation de **divergences entre deux pdfs** :

$$\int_{D_y} \varphi(p(y, \Omega), q(y)) dy$$

avec y une caractéristique scalaire ou vectorielle de l'image (exemple : $y=I$ l'intensité) et D_y le domaine de définition de y (exemple $D_y = [0, 255]$ pour $y = I$).

- La pdf $p(y, \Omega)$ représente la densité de probabilité de la caractéristique y à l'intérieur de la région Ω (paramétrique ou non paramétrique)
- La pdf $q(y)$ densité de probabilité connue ou inconnue
- La fonction φ permet de comparer les deux pdfs (e.g $\varphi(a, b) = (\sqrt{a} - \sqrt{b})^2$: Hellinger).

Références : [Lecellier et al SSVM 2009, IRBM 2014], [Jehan-Besson et al chapitre de livre 2010]

Maximisation de divergences entre pdfs

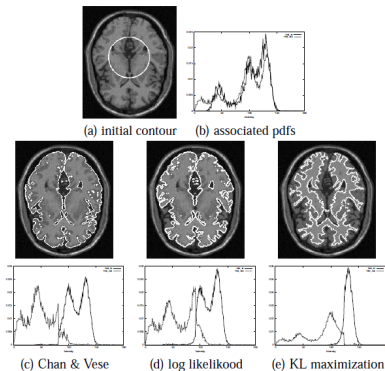
La segmentation **non supervisée** peut être formulée en **maximisant** le critère suivant :

$$F(\Omega_{int}, \Omega_{out}, C) = \int_{D_y} \varphi(p(y, \Omega_{int}), q(y, \Omega_{out})) dy$$

Cela signifie que l'on va partager l'image en deux régions de telle sorte à maximiser la distance entre les histogrammes associés.

Segmentation

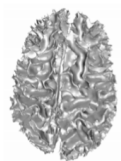
Segmentation non supervisée : comparaison de critères



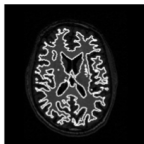
Référence : [IRBM14,SSVM09]

Segmentation

Segmentation 3D non supervisée avec KL



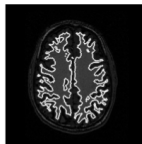
(a) 3D rendering of the volume WM



(b) slice 72



(c) slice 75



(d) slice 84

Référence : [Book Chapter 2010]

Minimisation de divergences entre pdfs pour la segmentation supervisée en utilisant une pdf de référence

Une autre application (**supervisée**) va consister à rechercher une région dans l'image connaissant son histogramme de référence q_{ref} . Nous cherchons alors à **minimiser** le critère suivant :

$$F(\Omega_{in}) = \int_{D_y} \Psi(p(y, \Omega_{in}), q_{ref}(y)) dy$$

Ce critère peut être utilisé pour :

- le suivi d'une région d'intérêt dans une image
- la segmentation supervisée de textures
- éventuellement l'utilisation d'un a priori sur la densité de probabilité (issue d'une méthode apprentissage)

Segmentation avec a priori de forme

Exemple : Utilisation des moments de Legendre [Foulonneau et al PAMI 2006] (possibilité d'introduire des invariances aux changements affines de la forme de référence) et d'un système de minimisations alternées pour la segmentation en échocardiographie [Lecellier et al ICIP 2006] :

- Évolution en utilisant un a priori de bruit pendant n itérations
- Évolution en utilisant l'a priori de forme pour retrouver la forme de référence



(a) Rayleigh avec a priori de forme



(b) tracé expert

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Plan

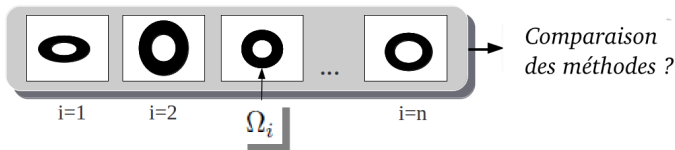
- Introduction
- Méthodologie pour la segmentation
- **Méthodologie pour la fusion et l'évaluation**
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Évaluation et fusion

Mise en place d'un cadre méthodologique

L'évaluation ou la fusion des méthodes de segmentation consiste à classer, comparer ou fusionner différentes méthodes de segmentation.

Notation : $\{\Omega_i\}_{i \in [1,n]}$, les régions calculées en utilisant différents résultats de segmentation pour une image donnée ou différents résultats de segmentation pour plusieurs images dans des modalités différentes.



Contexte initial de l'étude : Action IMPEIC (Initiative Multicentrique pour une Plateforme d'évaluation en Imagerie Cardiaque) dirigée par F. Frouin (LITO INSERM Paris) du GDR STIC Santé

Apports scientifiques

De manière classique, dans la littérature, c'est **STAPLE** [Warfield et al TMI 2004] qui est utilisé pour l'évaluation des méthodes de segmentation sans gold standard.

Nous proposons ici d'estimer une "forme mutuelle" permettant de combiner et classifier différentes méthodes de segmentation [ICIP2014,ArXiv2021].

Nos contributions :

- Proposition d'un **critère original à optimiser** utilisant une métrique entre les formes basée sur **la théorie de l'information**
- Modélisation continue du critère afin de pouvoir calculer **le gradient de forme** en utilisant les outils d'optimisation de domaines
- Application à l'évaluation et à la fusion pour différentes problématiques (IRM cardiaque, images couleur, **IRM multimodale**)

Modélisation mathématique

- A partir de n formes segmentées $\{\Omega_1, \dots, \Omega_n\}$, l'objectif est de calculer une forme de référence μ qui permet de mutualiser les informations des segmentations en entrée tout en étant robuste aux segmentations aberrantes :



- Notons t et d_i les réalisations des variables aléatoires $T(X)$ et $D_i(X)$

$$d_i(x) = \begin{cases} 1 & \text{si } x \in \Omega_i \\ 0 & \text{si } x \in \overline{\Omega_i} \end{cases} \rightarrow \text{forme de référence ?} \quad t(x) = \begin{cases} 1 & \text{si } x \in \mu \\ 0 & \text{si } x \in \overline{\mu} \end{cases}$$

Forme mutuelle variationnelle :

$$\min_{\mu} \sum_{i=1}^n d(\Omega_i, \mu) = \min_{\mu} \sum_{i=1}^n H(D_i, T) - I(D_i, T)$$

avec la somme des entropies jointes $JH(T) = \sum_{i=1}^n H(D_i, T)$ et la somme des informations mutuelles $MI(T) = \sum_{i=1}^n I(D_i, T)$.

Ce critère se justifie par le fait que $\varphi(D_i, T) = (H(D_i, T) - I(D_i, T))$ est une métrique qui satisfait les propriétés suivantes :

1. $\varphi(X, Y) \geq 0$
2. $\varphi(X, Y) = \varphi(Y, X)$
3. $\varphi(X, Y) = 0$ si et seulement si $X = Y$
4. $\varphi(X, Y) + \varphi(Y, Z) \geq \varphi(X, Z)$

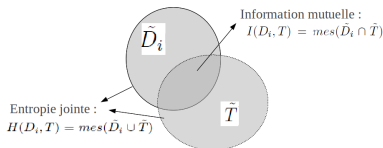
De plus nous pouvons donner une justification géométrique à ce critère statistique.

Forme mutuelle variationnelle :

- **Interprétation statistique du critère :**

$$J(T) = \sum_{i=1}^n (H(D_i, T) - I(D_i, T)) = JH(T) + MI(T)$$

utilisation des analogies entre la théorie de l'information et les mesures d'aires



Nous recherchons la forme mutuelle qui va maximiser l'information mutuelle (une mesure statistique de l'intersection) tout en minimisant l'entropie jointe (une mesure statistique de l'union).

→ Cela correspond à la minimisation d'une différence symétrique statistique.

Comparaison avec d'autres critères

- **Forme moyenne variationnelle basée sur la différence symétrique classique**
[Soatto et al IJCV 2002, Charpiat et al ICIP 2003, Berkels et al JMIV 2010]

$$\min_{\mu} \sum_{i=1}^n d(\Omega_i, \mu) = \min_{\mu} \sum_{i=1}^n |\Omega_i \triangle \mu|$$

en utilisant $|\Omega_i \triangle \mu|$ la différence symétrique classique (union privée de l'intersection).

- **Forme mutuelle variationnelle basée sur une différence symétrique statistique**
[Jehan-Besson et al ICIP2014, ArXiv2021]:

$$\min_{\mu} \sum_{i=1}^n d(\Omega_i, \mu) = \min_{\mu} \sum_{i=1}^n H(D_i, T) - I(D_i, T)$$

→ Comparaison proposée dans la publication ArXiv

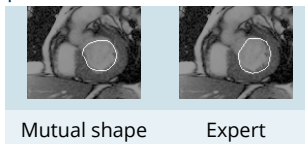
Evaluation et fusion

Exemple de résultat obtenu sur une coupe d'IRM cardiaque :

→ Différentes méthodes de segmentation m_1 à m_5



→ Forme mutuelle et tracé expert :



Paramètres de sensibilité et spécificité, $p_i = TP / (TP + FN)$ et $q_i = TN / (TN + FP)$.

→ Table de classification :

i	m_1	m_2	m_3	m_4	m_5
p_i	0.998	0.992	0.843	0.995	0
q_i	0.844	0.956	0.983	0.945	0.801

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Projet BIOMEDE

Analyse des GITC en IRM multimodale

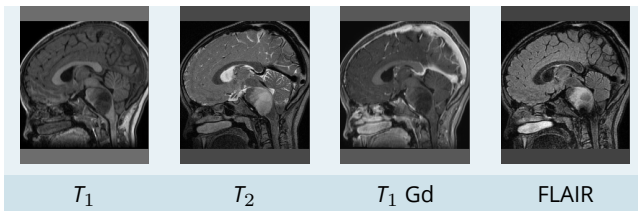
Dans le cadre des projets PHRC BIOMEDE (2014-2019) et BIOMEDE-2 (2020-2023) (direction F. Frouin pour le LITO), le laboratoire LITO (Institut Curie) et ses partenaires (NeuroSpin, Hôpital Necker, Gustave Roussy) s'intéressent à l'analyse et au suivi des tumeurs **GITC (Gliome Infiltrant du Tronc Cérébral)**, qui sont des tumeurs pédiatriques rares de très mauvais pronostic.

Objectifs concernant la partie analyse des images :

- La localisation et la segmentation des tumeurs sur des images **IRM 3D multiparamétriques** (images pondérées T1 sans et avec agent de contraste, images pondérées T2 et FLAIR, images de diffusion)
- La caractérisation des tumeurs par des indices radiomiques (thèse de Doctorat de Jessica Goya Outi encadrée par F. Frouin et soutenue en 2019)
- Le suivi de l'évolution de la tumeur et des indices associés au cours du traitement

Analyse des GTC en IRM multimodale

Exploration de la segmentation des GTC dans les **IRM multimodales recalées dans un même repère et standardisées** par l'équipe radiomique du LITO [référence : J. Goya Outi et al, Physics in Medicine & Biology, 2018] :



- **Problématique de la segmentation** : tumeurs non homogènes, 3D, surface complexe, tumeur parfois disséminée autour de la zone principale, nécessité de combiner des informations multimodales, faible volume des données expertisées en raison de la rareté de la pathologie

Projet BIOMEDE

Expertise proposée et études en cours

Nos études concernent :

1. **Modélisation de la segmentation comme un problème d'optimisation continu afin d'obtenir la segmentation 2D ou 3D sur chaque image,**
 - Test de différents critères statistiques
2. **Modélisation de la fusion de différentes méthodes de segmentation en utilisant la théorie de l'information**
 - La segmentation est obtenue de manière indépendante sur chaque image et chaque modalité par différentes méthodes, le but est alors de fusionner les informations de manière robuste

Segmentation 3D : Critères statistiques testés

3 critères ont été utilisés :

- Minimisation de l'anti-log vraisemblance **MV** (Maximum de Vraisemblance)

$$J_{MV}(\Omega_{in}, \Omega_{out}) = - \int_{\Omega_{in}} \log p(I(\mathbf{x}); \mu_{in}, \sigma_{in}^2) d\mathbf{x} - \int_{\Omega_{out}} \log p(I(\mathbf{x}), \mu_{out}, \sigma_{out}^2) d\mathbf{x}$$

- Minimisation d'une fonction de la variance **VA**

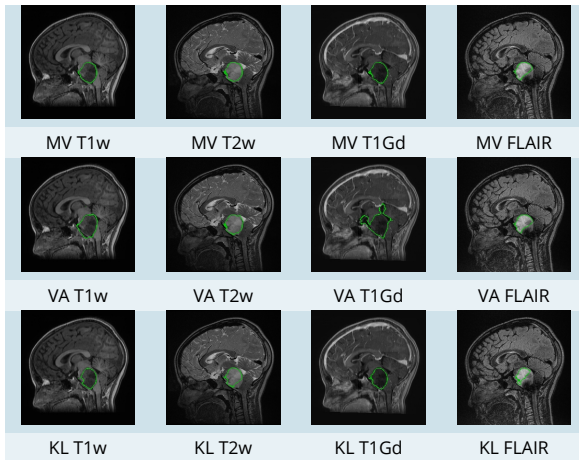
$$J_{VA}(\Omega_{in}, \Omega_{out}) = \int_{\Omega_{in}} \varphi(\sigma_{in}^2) d\mathbf{x} + \int_{\Omega_{out}} \varphi(\sigma_{out}^2) d\mathbf{x}$$

avec $\varphi(r) = \log(1 + r)$.

- Maximisation de la divergence de Kullback-Leibler **KL**

$$J_{KL}(\Omega_{in}, \Omega_{out}) = \int KL(p(y; \mu_{in}, \sigma_{in}^2), p(y; \mu_{out}, \sigma_{out}^2)) dy$$

Projet BIOMEDE



NB : La forme initiale 3D est basée sur l'hyper signal de la modalité FLAIR. La même initialisation est utilisée pour toutes les méthodes.

Evaluation des différentes segmentations 3D obtenues

Table 1: Évaluation des différentes segmentations (méthodes MV, VA, KL) obtenues par rapport à la forme de référence 3D. Calcul du coefficient de dice (DC).

MV	T1w	T2w	T1Gd	FLAIR
DC	0.869	0.866	0.898	0.770

VA	T1w	T2w	T1Gd	FLAIR
DC	0.833	0.869	0.766	0.771

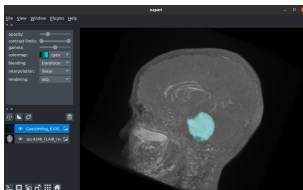
KL	T1w	T2w	T1Gd	FLAIR
DC	0.833	0.843	0.869	0.771

NB : les méthodes sont ici utilisées pour illustrer l'algorithme de fusion. Il existe de nombreuses méthodes permettant la segmentation d'images d'IRM multimodales [J. Lapuyade-Lahorgue et al TMI 2017, Urien et al ISBI 2016, thèse Telecom Paris 2019 , T. Henry et al Challenge Brats 2020 ...]

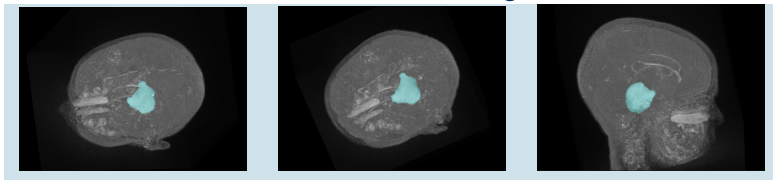
Projet BIOMEDE

Représentation 3D des différentes segmentations

Visualisation simple en utilisant le logiciel napari (python) :

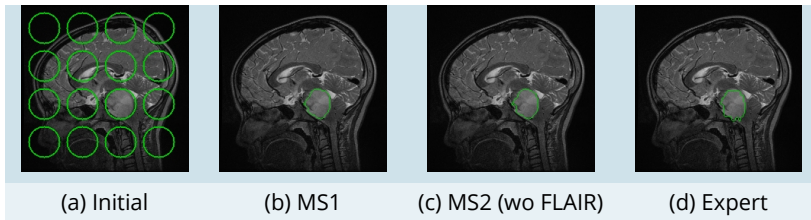


Visualisation 3D : GITC sur image FLAIR



Estimation de la forme mutuelle

- **en entrée** : les résultats de segmentation obtenus avec différentes méthodes et différentes modalités (recommandation RAPNO (Response Assessment in Pediatric Neuro-Oncology 2020) : extraction d'une slice 2D où la tumeur a une surface maximale pour analyser la tumeur DIPG).
- **en sortie** : estimation d'une forme mutuelle MS1 calculée à partir des 12 segmentations en entrée et d'une forme mutuelle calculée sans la modalité FLAIR soit 8 segmentations.



- Démo de l'algorithme

La forme mutuelle : un consensus robuste ?

Comparaison des résultats de segmentation au tracé expert :

Table 2: Calcul du coefficient DC en se basant sur la segmentation de l'expert pour les différentes méthodes m_1 à m_{12} et pour MS1 et MS2 en 2D

i	m_1	m_2	m_3	m_4	m_5	m_6	m_7
DC	0.920	0.887	0.915	0.731	0.865	0.881	0.740
i	m_8	m_9	m_{10}	m_{11}	m_{12}	MS1	MS2
DC	0.740	0.881	0.841	0.911	0.594	0.913	0.921

- Pour les formes mutuelles MS1 et MS2, le coefficient DC est au-dessus de 0.91
- Le coefficient DC de MS2 est légèrement au-dessus des autres

La forme mutuelle semble donc être pertinente afin d'estimer un consensus robuste à un ensemble de segmentations en entrée. De plus la forme mutuelle semble robuste aux segmentations aberrantes (outliers).

La forme mutuelle : évaluation sans gold standard pertinente ?

Classement des méthodes de segmentation par comparaison à la forme mutuelle :

Table 3: Calcul du coefficient DC en se basant sur la forme mutuelle MS1 pour les différentes méthodes de segmentation m_1 à m_{12}

i	m_1	m_2	m_3	m_4	m_5	m_6
DC	0.971	0.956	0.960	0.799	0.875	0.951
i	m_7	m_8	m_9	m_{10}	m_{11}	m_{12}
DC	0.767	0.809	0.919	0.887	0.935	0.621

Le classement sans gold standard évalue m_1, m_3, m_2 comme les meilleures méthodes ce qui est cohérent avec le classement donné par le tracé expert.

Le classement nous indique que m_{12}, m_4, m_7 et m_8 sont moins performantes (segmentations obtenues sur les images FLAIR notamment).

Publications

Publication conférence GSI 2021 LNCS 8 pages (**International Geometric Science on Information**) : the objective of this GSI'21 conference is to bring together pure/applied mathematicians and engineers, with common interest for Geometric tools and their applications for Information analysis.

Optimization of a shape metric based on information theory applied to segmentation fusion and evaluation in multimodal MRI for DIPG tumor analysis

S. Jehan-Besson¹, R. Clouard², N. Boddaert³, J. Grill⁴, and F. Frouin¹

¹ Institut Curie, Université PSL, Inserm U1288, Laboratoire d'Imagerie Translationnelle en Oncologie LITO, 91400 Orsay, France

² Normandie Univ, UNICAEN, ENSICAEN, CNRS, GREYC, Caen, France

³ Pediatric Radiology Department, Hôpital Necker Enfants Malades, AP-HP; IMAGINE Institute, INSERM UMR 1163, Université de Paris, Paris, France

⁴ Department of Pediatric and Adolescent Oncology, Gustave Roussy, Inserm, Université Paris Saclay, Villejuif, France

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Plan

- Introduction
- Méthodologie pour la segmentation
- Méthodologie pour la fusion et l'évaluation
- Résultats pour le projet BIOMEDE
- Conclusion et Perspectives

Conclusion et Perspectives

Différentes idées à approfondir

- Segmentation 3D en utilisant un critère à optimiser
 - Analyse approfondie du signal et des images multimodales
 - Plusieurs modèles paramétriques ou non paramétriques avec des densités de probabilités isolées ou jointes peuvent être étudiés
- Évaluation/Fusion des différentes méthodes de segmentation en utilisant la théorie de l'information
 - Passage au 3D de la forme mutuelle
 - Évaluation sur la base de données BIOMEDE, 85 patients
 - Extension à une étude multi-régions en utilisant d_i
 - Intégrer des méthodes de deep learning 2D ou 3D afin d'évaluer et de fusionner des données
 - Étude d'autres métriques de forme pour estimer la forme mutuelle.

Perspectives à plus long terme

- Étude de l'évolution des tumeurs au cours du temps pour estimer l'impact du traitement (étude de modèles mathématiques de formes permettant de **décrire et d'apprendre les déformations**)

référence : *Deep Functional Maps: Structured Prediction for Dense Shape Correspondence*, O. Litany, T. Remez, E. Rodolà, A. M. Bronstein and M.M. Bronstein, ICCV, 2017.

- **Classification de la zone tumorale** (nécrose, tumeur viable, inflammation)

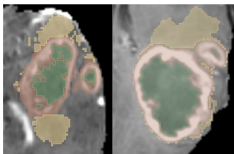


Fig. 4. Zoomed version of the first two vignettes of Figure 3. Left: ground truth example from the training set. Right: generated segmentations from our solution for the best mean dice score patient on the validation set. **Red:** enhancing tumor (ET), **Green:** non enhancing tumor/ necrotic tumor (NET/NCR), **Yellow:** peritumoral edema (ED). It is interesting to note that both exhibit the same pattern: central non enhancing tumor core with surrounding enhancing ring and diffuse peritumoral edema.

référence : *Brain tumor segmentation with self-ensembled, deeply-supervised 3D U-net neural networks: a BraTS 2020 challenge solution*, T. Henry et al, BraTS 2020 proceedings (LNCS) paper.