

# Recalage variationnel non rigide statistique référencé région

Nicolas ROUGON, Antoine DISCHER, Françoise PRÊTEUX

GET / INT - Unité de Projets ARTEMIS  
9, Rue Charles Fourier - 91011 Evry Cedex, France

Nicolas.Rougon@int-evry.fr, Antoine.Discher@int-evry.fr, Francoise.Preteux@int-evry.fr

**Résumé** – Les mesures de similarité statistiques classiquement utilisées en recalage non rigide iconique exploitent des statistiques de luminance globales n’intégrant aucune information géométrique. Cette absence de prise en compte du contexte spatial peut conduire dans certains cas à un appariement imprécis voire incohérent de structures géométriques homologues, rendant ces critères mal adaptés à la segmentation par propagation d’atlas. Nous proposons de résoudre cette limitation en injectant dans la mesure de similarité un a priori spatial sous forme d’un modèle étiqueté de scène associé à l’image cible. Ce dernier induit un critère régionalisé fondé sur des densités de probabilité régionales, estimées via des noyaux de Parzen spécifiques sur chaque région du modèle. Nous formalisons ainsi les notions de rapport de corrélation et de  $f$ -information régionalisés, dont nous calculons les flots de gradient sur des espaces de transformations non paramétriques et paramétriques. L’application au modèle de scène de la transformation optimale inverse induit de facto une segmentation de l’image source. Nous illustrons les performances de cette approche pour la compensation de mouvements respiratoires et cardiaques complexes lors du transit d’un produit de contraste en IRM de perfusion.

**Abstract** – Classical statistical similarity measures used in intensity-based non rigid registration rely on global luminance statistics and do not incorporate geometrical information. Ignoring spatial correlations may lead to inaccurate or geometrically inconsistent alignment of homologous geometric structures, making these criteria unreliable for atlas-based segmentation purposes. This paper addresses this limitation and presents a region-driven approach to statistical non rigid registration based on regional non-parametric estimates of luminance distributions. The latter are derived from a regional segmentation of the target image which is used as a fixed object/scene template and induces regionalized statistical similarity measures. We provide their expressions in the case of  $f$ -informations and correlation ratio, and derive the corresponding gradient flows over parametric and non-parametric transforms spaces. The relevance of this approach is illustrated for the joint respiratory/cardiac motion artifacts compensation and heart segmentation in short-axis cardiac perfusion MR sequences. using a bi-ventricular heart template.

## 1 Introduction

Le recalage non rigide d’images a suscité de nombreux travaux en imagerie médicale [1] et en vision par ordinateur. Parmi ceux-ci, les approches iconiques, qui visent à maximiser la similarité inter-image au niveau pixel, ont reçu une attention particulière en raison de leur capacité à générer des cartes d’appariement denses sans pré-segmentation [4, 15]. Dans ce contexte, les mesures de similarité statistiques ont démontré leur pertinence pour la mise en correspondance robuste de données non stationnaires, hétérogènes (multimodales) ou incommensurables. Cette classe de mesures inclut notamment le rapport de corrélation, dont l’optimalité pour des signaux présentant une dépendance fonctionnelle non-linéaire a été suggérée [10], et les  $f$ -informations [6], applicables dans l’hypothèse plus faible d’une dépendance statistique et dont l’information mutuelle (IM) constitue un cas particulier très étudié [14, 5, 12, 7, 3, 9].

Dans ces approches, les images sont modélisées comme des variables aléatoires (VA) et manipulées via leurs densités de probabilité marginales et conjointes, généralement estimées de manière globale sur l’intégralité du domaine image. Le recalage s’effectue en maximisant itérativement la similarité statistique entre distributions de luminance, sans exploiter aucune information géométrique. L’absence de prise en compte du contexte spatial peut conduire dans certains cas à un appariement imprécis voire incohérent (bien que visuellement satisfaisant) de structures géométriques analogues, rendant ces critères mal adaptés à la segmentation par propagation d’atlas [11]. En outre, s’ils se révèlent très performants pour des densités conjointes

présentant des classes individualisées ou correspondant à des mélanges simples, ces critères peuvent atteindre leurs limites dans le cas de mélanges complexes, tels que ceux générés par des objets texturés sur un arrière-plan complexe.

Afin de résoudre ces limitations, diverses approches visant à enrichir la description statistique par l’apport d’informations spatiales ont été suggérées dans la littérature :

- Une première voie consiste à pondérer le critère statistique par un terme mesurant la similarité des dérivées spatiales des images à recalier. Ce programme a été appliqué à l’IM et à l’IM normalisée [12] avec prise en compte du gradient de luminance, et résolu par maximisation directe sur un espace de transformations paramétriques [8]. L’optimisation variationnelle du critère composite, requise pour traiter le cas de transformations non paramétriques, se révèle complexe.
- Une autre piste consiste à adapter spatialement l’estimation des densités de probabilité impliquées dans le critère statistique. Cette idée peut être mise en œuvre : (i) par le biais d’une partition du domaine image associée à une transformation paramétrique par morceaux [2]; limitée au seul cadre paramétrique, cette approche présente l’inconvénient de recourir à une géométrie extrinsèque aux données, à savoir une grille rectangulaire irrégulière non adaptée aux régions de l’image; (ii) en utilisant des estimées de Parzen locales [3]; outre le fait d’être mono-échelle, cette approche bas-niveau souffre d’une complexité numérique élevée du fait de son caractère local.

- Une dernière possibilité consiste à intégrer une information de support sous forme d’une VA supplémentaire, et à recourir à une mesure de similarité statistique multivariée. Cette idée a été développée dans [11] pour une IM trivariée impliquant les images à recaler ainsi qu’un étiquetage de l’image cible. Elle se heurte toutefois à des difficultés théoriques liées à la généralisation multivariée de critères statistiques définis dans le cas bivarié.

Effectuant une synthèse des précédentes idées, nous proposons dans cet article d’injecter dans le critère de similarité un *a priori* spatial sous forme d’un modèle étiqueté de scène associé à l’image cible. Ce dernier induit un critère de similarité régionalisé fondé sur des densités de probabilité régionales, estimées via des noyaux de Parzen spécifiques sur chaque région du modèle. Nous formalisons ainsi les notions de *rapport de corrélation régionalisé* et de *f-information régionalisée*, dont nous calculons les flots de gradient sur des espaces de transformations non paramétriques et paramétriques. L’application au modèle de scène de la transformation optimale inverse induit alors une segmentation de l’image source. Nous illustrons les performances de cette approche pour la compensation de mouvements respiratoires et cardiaques complexes lors du transit d’un produit de contraste en IRM de perfusion.

## 2 Recalage non rigide statistique régionalisé

Soient  $I_1$  et  $I_2$ , des images définies sur un domaine  $D \subset \mathbb{R}^n$  et à valeurs dans un intervalle  $\Omega$ . Recaler  $I_2$  sur  $I_1$  consiste à identifier une transformation  $\phi : D \rightarrow D$  au sein d’un espace  $\mathcal{T}$  de fonctions régulières, telle que  $I_2 \circ \phi$  soit similaire à  $I_1$  au sens d’un critère prédéfini. Ceci équivaut à trouver un champ de déplacement  $\mathbf{u} = \phi - \text{Id} \in \mathcal{T}$  tel que  $I_2^{\mathbf{u}}(\mathbf{x}) := I_2(\mathbf{x} + \mathbf{u}(\mathbf{x}))$  soit similaire à  $I_1(\mathbf{x})$  en tout point  $\mathbf{x} \in D$ . Ce problème est mal-posé et doit être régularisé.

Une approche classique définit une solution comme un minimiseur  $\mathbf{u}^*$  d’une fonctionnelle  $\mathcal{J}(\mathbf{u}) := \mathcal{S}(I_1, I_2, \mathbf{u}) + \alpha \mathcal{R}(\mathbf{u})$  sur  $\mathcal{T}$ , combinant un terme de similarité  $\mathcal{S}$  quantifiant l’écart entre  $I_1$  et  $I_2^{\mathbf{u}}$ , et un stabilisateur  $\mathcal{R}$  garantissant des solutions p.p. régulières, pondérés par un hyperparamètre  $\alpha > 0$ .

La minimisation variationnelle de  $\mathcal{J}$  sur  $\mathcal{T}$  s’effectue en intégrant par descente de gradient les équations d’Euler obtenues en annulant sa dérivée de Gâteaux. Deux cas sont à distinguer selon la nature de l’espace  $\mathcal{T}$  :

- *Transformations non-paramétriques*: le cas d’un espace de fonctions régulières arbitraires conduit à un problème de minimisation dense :  $\mathbf{u}^* = \arg \min_{\mathbf{u} \in \mathcal{T}} \mathcal{J}(\mathbf{u})$ , générant un flot sur  $D$  :  $\frac{\partial \mathbf{u}}{\partial t}(\mathbf{x}) = -\partial_{\mathbf{u}} \mathcal{J}(\mathbf{u}(\mathbf{x}))$  ( $\mathbf{u}(\cdot, 0) = \mathbf{0}$ ) où  $\partial_{\mathbf{u}} \mathcal{J}$  est la 1<sup>ère</sup> variation de  $\mathcal{J}$  sur  $\mathcal{T}$ .
- *Transformations paramétriques*: lorsque  $\mathbf{u} := \mathbf{u}^\Theta$  appartient à un espace de fonctions régulières dépendant d’un paramètre  $\Theta \in \mathbb{R}^p$ , l’optimum  $\mathbf{u}^*$  est recherché comme la solution  $\mathbf{u}^{\Theta^*}$  d’un problème de minimisation épars :  $\Theta^* = \arg \min_{\Theta} \mathcal{J}(\mathbf{u}^\Theta)$ , induisant un flot sur  $\mathbb{R}^p$  :  $\Theta_t = -\partial_{\Theta} \mathcal{J}(\mathbf{u}^{\Theta(t)})$  ( $\Theta(0) = \mathbf{0}$ ) où  $\partial_{\Theta} \mathcal{J}$  est la 1<sup>ère</sup> variation de  $\mathcal{J}$  sur  $\mathcal{T}$ . Nous nous restreindrons dans la suite à des modèles linéaires pour lesquels  $\mathbf{u}^\Theta(\mathbf{x}) = \mathbf{B}(\mathbf{x})\Theta$ ,

$\mathbf{B}(\mathbf{x})$  désignant une matrice encodant une base locale de  $\mathcal{T}$  au point  $\mathbf{x} \in D$ .

### 2.1 Recalage non rigide statistique global

Nous considérons ici le cas de mesures de similarité statistiques pour lesquelles  $I_1$  et  $I_2^{\mathbf{u}}$  sont modélisées comme des VA sur l’espace d’état  $\Omega$ , de densités respectives  $p^{I_1}$  et  $p^{I_2^{\mathbf{u}}}$  et de densité jointe  $p^{I_1, I_2^{\mathbf{u}}}$ . Sans perte de généralité, nous envisageons spécifiquement les cas suivants :

- $\mathcal{S}(I_1, I_2, \mathbf{u}) = \text{CR}(I_2^{\mathbf{u}}|I_1)$  où CR est le rapport de corrélation [10] défini par :

$$\text{CR}(I_2^{\mathbf{u}}|I_1) := 1 - \frac{E[\text{Var}(I_2^{\mathbf{u}}|I_1)]}{\text{Var}(I_2^{\mathbf{u}})} \quad (1)$$

- $\mathcal{S}(I_1, I_2, \mathbf{u}) = -I_f(I_1, I_2^{\mathbf{u}})$  où  $I_f$  est une  $f$ -information intégrale [13] telle que :

$$I_f(I_1, I_2^{\mathbf{u}}) := \int_{\Omega^2} p^{I_1}(i_1) p^{I_2^{\mathbf{u}}}(i_2) f(\rho^{\mathbf{u}}(i_1, i_2)) di_1 di_2 \quad (2)$$

$f$  désignant une fonction continue convexe sur  $\mathbb{R}^+$  et  $\rho^{\mathbf{u}}(i_1, i_2) := \frac{p^{I_1, I_2^{\mathbf{u}}}(i_1, i_2)}{p^{I_1}(i_1) p^{I_2^{\mathbf{u}}}(i_2)}$ . La mesure de Kullback  $f_{\text{KL}}(x) := x \log x$  conduit à l’IM, notée  $I$ . La fonction  $f(x) = \frac{x^\alpha - \alpha x + \alpha - 1}{\alpha(\alpha - 1)}$  ( $\alpha \neq \{0, 1\}$ ) définit la  $I_\alpha$ -information, notée  $I_\alpha$ , qui vérifie :  $\lim_{\alpha \rightarrow 1} I_\alpha = I$ .

Le point central réside dans le calcul de la dérivée de Gâteaux du critère de similarité  $\mathcal{S}(\mathbf{u})$ . Dans ce but, nous utilisons des estimateurs de Parzen pour exprimer analytiquement les densités  $p^{I_1, I_2^{\mathbf{u}}}$  et  $p^{I_2^{\mathbf{u}}}$ . La densité  $p^X$  d’une VA  $X$  sur  $D$  est ainsi approchée par :

$$p^X(X_0) = \frac{1}{\mu(D)} \int_D \mathcal{K}^d(X(\mathbf{x}) - X_0) d\mathbf{x}$$

où  $\mathcal{K}^d$  est un noyau de même dimension  $d$  que  $X$  et  $\mu(D) := \int_D d\mathbf{x}$  est le volume de  $D$  [14, 3]. Dans le cas de transformations non paramétriques, on montre alors que [3, 6] :

$$\partial_{\mathbf{u}} \mathcal{S} = -V^{I_1, I_2^{\mathbf{u}}}(\mathbf{x}) \nabla I_2^{\mathbf{u}}(\mathbf{x}) \quad (\mathbf{x} \in D) \quad , \quad (3)$$

où  $V^{I_1, I_2^{\mathbf{u}}}$  désigne un terme statistique fonction des densités  $p^{I_1, I_2^{\mathbf{u}}}$  et  $p^{I_2^{\mathbf{u}}}$ , décrivant la variation du couplage statistique entre images induite par la transformation  $\mathbf{u}$ . Il s’exprime sous la forme générale suivante :

$$V^{I_1, I_2^{\mathbf{u}}}(\mathbf{x}) := \frac{1}{\mu(D)} \left\{ \left[ \mathcal{K}_2 \star \frac{\partial L_1^{\mathbf{u}}}{\partial i_2} \right] (I_1(\mathbf{x}), I_2^{\mathbf{u}}(\mathbf{x})) + E_{I_1} \left( \left[ \mathcal{K}_1 \star \frac{\partial L_2^{\mathbf{u}|i_1}}{\partial i_2} \right] (I_2^{\mathbf{u}}(\mathbf{x})) \right) \right\} \quad (4)$$

où  $E_{I_1}(\cdot)$  est l’espérance par rapport à  $I_1$ ,  $\star$  désigne la convolution 2D (resp. 1D) sur l’espace d’intensité  $\Omega^2$  (resp.  $\Omega$ ), et  $L_2^{\mathbf{u}|i_1}(\cdot) := L_2^{\mathbf{u}}(i_1, \cdot)$  pour  $i_1 \in \Omega$  donné. La forme analytique des termes  $L_1^{\mathbf{u}}$  et  $L_2^{\mathbf{u}}$  dépend du critère  $\mathcal{S}$  utilisé, et ai précisé dans les Tableaux 1 et 2, respectivement pour le rapport de corrélation et les  $f$ -informations intégrales.

Dans le cas de transformations paramétriques, le flot associé dans l’espace des paramètres prend la forme [6] :

$$\partial_{\Theta} \mathcal{S} = - \int_D V^{I_1, I_2^{\mathbf{u}^\Theta}}(\mathbf{x}) \left[ \left( \nabla I_2^{\mathbf{u}^\Theta} \right)^t \mathbf{B} \right] (\mathbf{x}) d\mathbf{x} \quad (5)$$

TAB. 1: Structure analytique de la dérivée variationnelle du rapport de corrélation [3].

$L_1^u$	$\frac{i_2}{\text{Var}(I_2^u)} [i_2 - 2E(I_2^u I_1 = i_1) + (\text{CR}(I_2^u I_1) - 1)(i_2 - 2E(I_2^u))]$
$L_2^u$	0

TAB. 2: Structure analytique de la dérivée variationnelle des  $f$ -informations intégrales [6].

$L_1^u$	$f'(\rho^u)$
$L_2^u$	$f(\rho^u) - \rho^u f'(\rho^u)$

## 2.2 Introduction d'un a priori régional

Supposons donnée une segmentation de l'image cible  $I_1$  sous la forme d'une partition  $\mathcal{D} := (D_l)_{0 \leq l \leq L}$  du domaine  $D$  en  $L$  régions d'intérêt,  $D_0$  correspondant par convention à l'arrière-plan. La projection triviale (injection canonique) de  $\mathcal{D}$  dans l'image  $I_2^u$  induit une partition  $\mathbf{u}^{-1}(\mathcal{D})$  de l'image source  $I_2$ : celle-ci s'interprète comme la pseudo-segmentation de  $I_2$  prédite par le modèle de scène  $\mathcal{D}$  pour la transformation courante  $\mathbf{u}$  (Figure 1). La restriction de  $I_1$  (resp.  $I_2^u$ ) au domaine  $D_l$ , notée  $I_{1|l}$  (resp.  $I_{2|l}^u$ ), définit la région image de support  $D_l$ . Mathématiquement,  $I_{1|l}$  et  $I_{2|l}^u$  sont des VA sur  $\Omega$ , de densités respectives  $p_l^{I_1}$  et  $p_l^{I_2^u}$  et de densité jointe  $p_l^{I_1, I_2^u}$ . Leur similarité peut donc être quantifiée au moyen d'une métrique statistique usuelle  $S$ . En effectuant cette mesure paire à paire, nous définissons un critère de similarité statistique régionalisé référencé par le modèle de scène  $\mathcal{D}$ , noté  $\mathcal{S}_{\mathcal{D}}$ , en posant :

$$\mathcal{S}_{\mathcal{D}}(I_1, I_2, \mathbf{u}) := \sum_{l=0}^L S(I_{1|l}, I_{2|l}^u, \mathbf{u}) \quad . \quad (6)$$

Appliquée aux identités (1) et (2), l'équation (6) permet de définir respectivement le *coefficient de corrélation régionalisé* et la *f-informations régionalisée*. Comme dans le cas global, les densités de probabilités intervenant dans ces critères peuvent être estimées par une méthode de Parzen, en recourant cette fois-ci à des noyaux régionalisés  $\mathcal{K}_l^d$  de support  $D_l$  :

$$p_l^X(X_0) = \frac{1}{\mu(D_l)} \int_{D_l} \mathcal{K}_l^d(X(\mathbf{x}) - X_0) d\mathbf{x} \quad .$$

La minimisation de  $\mathcal{S}_{\mathcal{D}}$  sur un espace de transformations non paramétriques conduit alors au flot :

$$\partial_{\mathbf{u}} \mathcal{S}_{\mathcal{D}} = -V_l^{I_1, I_2^u}(\mathbf{x}) \nabla I_2^u(\mathbf{x}) \quad (\mathbf{x} \in D_l) \quad (7)$$

où  $V_j^{I_1, I_2^u}$  désigne un terme statistique fonction des densités  $p_l^{I_1, I_2^u}$  et  $p_l^{I_2^u}$ , dont l'expression est identique au cas global (4). Ce terme décrit la variation du couplage statistique entre régions homologues induit par la transformation  $\mathbf{u}$ . Dans le cas de transformations paramétriques, le flot associé au critère  $\mathcal{S}_{\mathcal{D}}$  dans l'espace des paramètres prend la forme :

$$\partial_{\Theta} \mathcal{S}_{\mathcal{D}} = - \sum_{l=0}^L \int_{D_l} V_j^{I_1, I_2^u}(\mathbf{x}) \left[ \left( \nabla I_2^u \right)^t \mathbf{B} \right](\mathbf{x}) d\mathbf{x} \quad . \quad (8)$$

L'image  $(\mathbf{u}^*)^{-1}(\mathcal{D})$  du modèle de scène  $\mathcal{D}$  par la transformation optimale inverse  $(\mathbf{u}^*)^{-1}$  induit finalement une segmentation de l'image source  $I_2$ . L'approche proposée permet ainsi

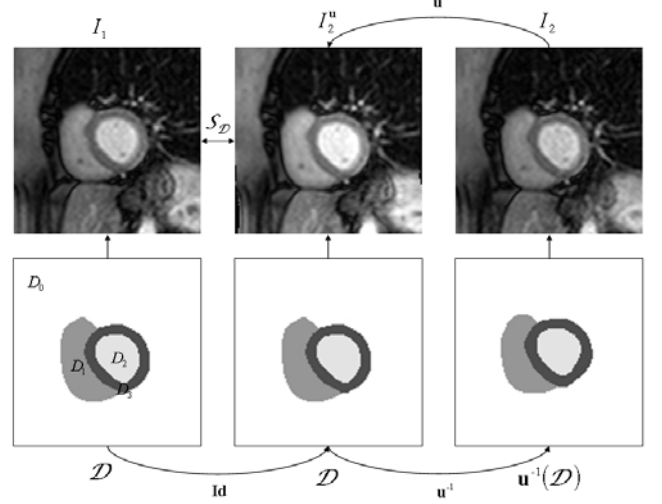


FIG. 1: Principe du recalage non rigide statistique référencé région : l'image source  $I_2$  est recalée sur l'image cible  $I_1$  en maximisant la similarité statistique  $\mathcal{S}_{\mathcal{D}}$  entre régions homologues de  $I_1$  et  $I_2^u$ , spécifiées par un modèle étiqueté de scène  $\mathcal{D}$  associé à  $I_1$  (ici, un modèle bi-ventriculaire du cœur en coupe petit-axe). La projection triviale  $\text{Id}(\mathcal{D})$  de  $\mathcal{D}$  sur  $I_1$  constitue une prédiction du modèle de scène dans l'image recalée par la transformation  $\mathbf{u}$  estimée.  $\mathbf{u}^{-1}(\mathcal{D})$  détermine une pseudo-segmentation de  $I_2$ .

de réaliser conjointement un recalage et une segmentation non rigides de l'image  $I_2$  par propagation du modèle de scène  $\mathcal{D}$ . Notons qu'elle procède par adaptation itérative des données au modèle, ce dernier demeurant fixe. Elle s'oppose en cela au schéma classique de recalage orienté modèle où la mise en correspondance est réalisée par adaptation progressive du modèle aux données. De façon remarquable, cette stratégie permet de traiter la segmentation non rigide comme un problème d'optimisation à frontières fixes, la segmentation de  $I_2$  étant obtenue par calcul direct une fois  $\mathbf{u}^*$  estimée.

## 3 Résultats expérimentaux

Cette approche a été appliquée à la compensation de mouvements respiratoires et cardiaques dans des séquences d'images IRM à des fins d'estimation quantitative de la perfusion myocardique pour le diagnostic de pathologies cardiovasculaires. Dans ces séquences, le transit sanguin d'un produit de contraste (Gadolinium-DTPA) induit des variations de luminosité très importantes dans les structures anatomiques et tissulaires irriguées, rendant le recalage complexe et intrinsèquement multimodal. Dans ce cadre, le modèle de scène  $\mathcal{D}$  retenu est un modèle bi-ventriculaire de cœur segmenté en coupe petit-axe comprenant 4 régions : thorax (arrière-plan), cavité ventriculaire gauche, myocarde gauche et ventricule droit (Figure 1). A ce stade, ce modèle est obtenu par segmentation interactive d'une image de la séquence choisie comme référence. Deux mesures de similarité ont été évaluées : le rapport de corrélation régionalisé et la  $I_\alpha$ -information régionalisée, et calculées via des noyaux de Parzen gaussiens dont les variances ont été automatiquement estimées sur chaque région du modèle par une méthode de cross-validation par maximum de vraisemblance.

Nous avons eu recours à un stabilisateur  $\mathcal{R}$  de Nagel-Enkelmann [3, 6] et à une stratégie multirésolution par pyramides gaussiennes pour les images et les déplacements [6].

L'approche a tout d'abord été validée en recalant des images natives avec des versions de synthèse générées par transformation non linéaire de contraste puis déformation par un champ prédéfini. Des tests approfondis ont démontré que le recalage par rapport de corrélation et  $I_\alpha$ -information régionalisée fournissent des résultats précis et de qualité comparables, tout en autorisant une accélération de convergence significative par rapport aux mesures globales analogues.

La Figure 2 présente un exemple de compensation de mouvements respiratoires et cardiaques sur quelques images au niveau de coupe basal, échantillonnées lors du passage du bolus de contraste, d'un examen IRM d'un patient post-opéré d'un infarctus du myocarde. Afin d'illustrer la précision du recalage, les contours du modèle bi-ventriculaire dans l'image de référence ont été superposés aux images natives avant et après recalage non rigide. On constate que l'approche proposée permet d'obtenir une segmentation précise de la cavité cardiaque, malgré des variations de contraste fortement non-linéaires et des déformations thoraciques importantes.

## 4 Conclusion et perspectives

Nous avons présenté un cadre variationnel générique pour le recalage non rigide statistique référencé région, fondé sur l'utilisation d'un modèle de scène étiqueté associé à l'image cible, couplé à une estimation non-paramétrique régionale des densités de probabilité des données. Ce cadre permet de disposer d'un moyen simple et flexible pour enrichir une mesure de similarité statistique par une information géométrique relative au support des objets imagés. Nous avons pu ainsi formaliser les concepts de rapport de corrélation et de  $f$ -information régionalisés, dont nous avons illustré la pertinence pour la compensation de mouvements respiratoires et cardiaques lors du transit d'un produit de contraste en IRM de perfusion. Les travaux en cours visent à étendre ce cadre en vue d'intégrer des contraintes de frontières. Les développements applicatifs concernent la génération automatique du modèle bi-ventriculaire.

## Remerciements

Ces recherches ont été effectuées dans le cadre d'une convention CIFRE entre GET/INT et Philips Medical Systems, en partenariat médical étroit avec le Service de Radiologie du CHU Pitié-Salpêtrière (Pr. Philippe Cluzel).

## Références

- [1] J. Gee, J.B.A. Maintz, M. Vannier (Eds.), *Biomedical Image Registration*, Proceedings 2nd International Workshop on Biomedical Image Registration (WBIR'03), Philadelphia, PA - LNCS 2717, Springer-Verlag, Berlin, June 2003.
- [2] P. Hellier, *Recalage non rigide en imagerie cérébrale: méthodes et validation* Thèse de Doctorat Université de Rennes 1, Décembre 2000.
- [3] G. Hermosillo, *Variational methods for multimodal image matching*, Thèse de Doctorat Université de Nice Sophia-Antipolis, Mai 2002.
- [4] H. Lester, S.R. Arridge, "A survey of hierarchical non-linear medical image registration", *Pattern Recognition*, 32(1), Janvier 1999, 129:149.

- [5] F. Maes, A. Collignon, D. Vandermeulen, G. Marchal, P. Suetens, "Multimodality image registration by maximization of mutual information", *IEEE Transactions on Medical Imaging*, 16(2), Avril 1997, 187:198.
- [6] C. Petitjean, *Recalage non rigide d'images par approches variationnelles statistiques. Application à l'analyse et à la modélisation de la fonction myocardique en IRM*, Thèse de Doctorat Université Paris V - René Descartes, Septembre 2003.
- [7] J.P.W. Pluim, *Mutual information based registration of medical images*, Ph.D. Dissertation Utrecht University, 2000.
- [8] J.P.W. Pluim, J.B.A. Maintz, M.A. Viergever, "Image registration by maximization of combined mutual information and gradient information", *Computer Vision and Image Understanding*, 77(2), Février 2000, 211:232.
- [9] J.P.W. Pluim, J.B.A. Maintz, M.A. Viergever, "Mutual-information-based registration of medical images: a survey" *IEEE Transactions on Medical Imaging*, 22(7), Juillet 2003, 986:1004.
- [10] A. Roche, *Recalage d'images médicales par inférence statistique* Thèse de Doctorat Université de Nice Sophia-Antipolis, Février 2001.
- [11] C. Studholme, D.L. Hill, D.J. Hawkes, "Incorporating connected region labelling into automated image registration using mutual information", *Proceedings IEEE Workshop on Mathematical Methods in Biomedical Image Analysis (MMBIA'96)*, San Francisco CA, Juin 1996, 23:31.
- [12] C. Studholme, D.L. Hill, D. Hawkes, "An overlap invariant entropy measure of 3D medical image alignment", *Pattern Recognition*, 32(1), Janvier 1999, 71:86.
- [13] I. Vajda, *Theory of Statistical Evidence and Information*, Kluwer Academic Publishers, Dordrecht, 1989.
- [14] P. Viola, W.M. Wells III, "Alignment by maximization of mutual information", *IJCV*, 24(2), 1997, 137:154.
- [15] B. Zitová, J. Flusser, "Image registration methods: a survey", *Image and Vision Computing*, 21, 2003, 977:1000.




FIG. 2: Compensation de mouvements respiratoires et cardiaques en IRM de perfusion par recalage non rigide par  $I_\alpha$ -information régionalisée ( $\alpha = 1.1$ ) utilisant un modèle bi-ventriculaire de cœur en coupe petit-axe présenté (cf. Figure 1). Rangées supérieures : séquence native. Rangées inférieures : séquence compensée. L'image cible de référence est l'image #26. Les frontières du modèle bi-ventriculaire ont été superposées afin de mettre en évidence l'effet du recalage.