



HAL
open science

Débruitage et correction du biais non multiplicatif en IRM pondérée T1

Guylaine Collewet, Jérôme Idier

► **To cite this version:**

Guylaine Collewet, Jérôme Idier. Débruitage et correction du biais non multiplicatif en IRM pondérée T1. 16ème Congrès Francophone AFRIF-AFIA Reconnaissance des Formes et Intelligence Artificielle, Jan 2008, Amiens, France. pp.286-294. hal-00678544

HAL Id: hal-00678544

<https://hal.science/hal-00678544>

Submitted on 13 Mar 2012

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.

Débruitage et correction du biais non multiplicatif en IRM pondérée T_1

Denoising and correction of the non-multiplicative bias in T_1 -weighted MRI

Guylaine Collewet¹

Jérôme Idier²

¹ Cemagref

² IRCCyN (ECN, UMR CNRS 6597, Nantes)

17, av de Cucillé, CS 64427, 35044, Rennes, France

guylaine.collewet@cemagref.fr

Résumé

Nous proposons une méthode pour réduire le bruit dans les images IRM et éliminer les effets des inhomogénéités spatiales des antennes d'émission et de réception de la radiofréquence (RF). Nous traitons particulièrement le cas des images pondérées T_1 acquises en IRM bas-champ. Le biais engendré par l'inhomogénéité spatiale de la RF en émission dépend du tissu imagé. Il ne peut être considéré comme purement multiplicatif et indépendant du contenu de l'image. Afin de le corriger, nous considérons que chaque voxel contient un mélange des tissus susceptibles d'être présents dans l'image. Le signal IRM est modélisé par la somme pondérée des signaux de chaque tissu. Le nombre de tissus ainsi que certaines caractéristiques RMN des tissus sont supposés connus. Plusieurs images, acquises avec des paramètres d'acquisition différents, sont nécessaires. Un critère des moindres carrés pénalisé est utilisé afin d'estimer les inhomogénéités de la RF en émission, en réception ainsi que la proportion des tissus. La minimisation de ce critère est réalisée à l'aide du gradient conjugué utilisé dans un schéma itératif de type Gauss-Seidel par blocs. Des résultats obtenus sur des images simulées puis réelles sont présentés.

Mots Clef

IRM, débruitage, correction d'inhomogénéités, pondération T_1 , Gauss-Seidel, gradient conjugué

Abstract

We propose a method to reduce the noise and to eliminate the effects of the inhomogeneity of the (RF) pulses and of the sensitivity of the Radio-Frequency (RF) reception, particularly in the case of MR T_1 -weighted images acquired with a low-field MRI system. In T_1 -weighted images the effects of the pulse inhomogeneities vary with the tissues. Consequently the bias field is not strictly multiplicative and depends on the content of the image. In our approach, the MR signal is modeled as a sum of contributions of all the

tissues present in the object. For the sake of generality, each pixel is assumed to contain an unknown proportion of each tissue. The number of tissues composing the object as well as the MR characteristics of each tissue are assumed known. Several images with different acquisition parameter values are also needed. A penalized least-square criterion is proposed to estimate the RF emitted field, the RF sensitivity reception and the proportion of each tissue. We solve the optimization problem using conjugate gradient within a block coordinate descent iterative scheme. Results based on simulated and real MR images are presented.

Keywords

MRI, denoising, inhomogeneity correction, T_1 -weighted, Gauss-Seidel, conjugate gradient

1 Introduction

L'imagerie par résonance magnétique nucléaire (IRM) est une technique de choix pour les applications cliniques. Elle permet de visualiser les différents organes, de différencier les tissus, de détecter les lésions et ainsi d'établir un diagnostic. Toutefois, il existe de nombreux autres domaines d'application de cette technique tels que, par exemple, la caractérisation des produits alimentaires [13] ou l'étude du transport des fluides dans les matériaux poreux [3]. De plus, au-delà de la simple visualisation, des informations quantitatives peuvent être obtenues à partir des images, par segmentation (calcul de volume de différents organes ou tissus) ou par mesure directe de l'intensité du signal. Cependant, les images IRM sont entachées de nombreux artefacts liés aux imperfections du système d'acquisition. Ces artefacts doivent être corrigés afin d'obtenir des informations quantitatives avec une précision acceptable.

L'application visée ici est la quantification de la distribution anatomique des tissus gras chez le poisson. Ces tissus sont directement reliés à la qualité du produit et des données précises sur leur répartition sont recherchées [24]. L'IRM est une technique tout à fait adaptée à ce type de me-

sure puisqu'elle fournit des informations 3D et est capable de différencier le tissu gras du tissu musculaire par l'utilisation d'un protocole particulier produisant des images dites pondérées en T_1 où le contraste inter-tissus est maximal.

Cette étude a été réalisée à l'aide d'un IRM bas-champ. L'utilisation d'IRM bas-champ n'est pas largement répandue pour les applications cliniques. Cependant, même si le rapport signal à bruit (RSB) est plus faible que pour les appareils haut-champ, il a été démontré que l'IRM bas-champ a un pouvoir diagnostique comparable dans un grand nombre de cas [20]. Outre son coût de fabrication et de fonctionnement plus faible, cette technique possède l'avantage de pouvoir proposer des architectures ouvertes qui améliorent le confort des patients et permet également de réaliser des examens interventionnels [8, 25]. Enfin, les artefacts liés à la force du champ magnétique ont des effets moins importants à bas-champ qu'à haut champ.

Rappelons brièvement le principe d'acquisition d'une image IRM : le signal IRM est la somme des signaux radio-fréquence issus de l'ensemble des protons, positionnés dans un champ magnétique permanent B_0 et soumis à des séquences d'impulsions de champ magnétique RF, impulsions basculant les protons d'un angle prédéfini par rapport à leur position d'équilibre. Le signal émis par les protons lors de leur retour à l'équilibre est acquis par une antenne. Un gradient linéaire de champ magnétique $G(r)$ dépendant de la position r est ajouté au champ B_0 . Selon la loi de Larmor, la fréquence du signal des protons localisés à la position r est proportionnelle à $B_0 + G(r)$, ce qui permet de reconstruire la densité spatiale des protons par transformée de Fourier du signal [12].

Ainsi, toutes les causes de modification de $B_0 + G(r)$ introduisent des erreurs de localisation du signal. C'est le cas (i) des inhomogénéités intrinsèques de B_0 , (ii) des différences de susceptibilité magnétique entre tissus, qui induisent des variations locales de B_0 , (iii) ou des non-linéarités du gradient $G(r)$. De plus, le déplacement chimique entre les protons de gras et les protons de l'eau induit une différence de fréquence indépendante de la position. Tous ces phénomènes peuvent être négligés dans notre cadre applicatif : le champ magnétique B_0 n'est pas intense, les images sont acquises dans une zone où B_0 est quasiment homogène, et la séquence classique d'impulsions RF utilisée, dite « écho de spin », offre une faible sensibilité aux inhomogénéités de champ B_0 . C'est pourquoi nous avons uniquement considéré dans ce travail les inhomogénéités de la RF, qui sont la source principale de variation artefactuelle du signal. Celles-ci sont induites par deux causes principales :

- La sensibilité en réception de la RF (RFR) n'est pas homogène.
- Les inhomogénéités spatiales de la RF émise, couplées avec des phénomènes d'off-résonance liés aux inhomogénéités de B_0 , induisent des variations spatiales des impulsions émises (RFE) qui à leur tour influencent l'intensité du signal [28].

Les inhomogénéités dues à RFR et RFE influencent dif-

féremment le signal. L'effet de RFR peut être considéré comme multiplicatif tandis que l'effet de RFE dépend du temps de relaxation longitudinal T_1 , en particulier dans les images pondérées T_1 [35]. Ce type d'images est largement utilisé dans les applications car acquises avec des temps de mesure plutôt courts et elles fournissent de bons contrastes entre les tissus avec différents T_1 tels que le muscle et le gras ou les différents tissus cérébraux.

Différentes approches pour la correction des inhomogénéités RF ont été proposées dans la littérature. Une revue des méthodes peut être trouvée dans [1, 14, 34]. Certains auteurs proposent de supprimer les variations lentes du signal en les attribuant aux inhomogénéités. Cela peut être fait par filtrage homomorphique [15, 4], ou de façon plus sophistiquée en estimant itérativement la distribution de l'intensité des tissus et le biais [29]. Ces approches ne conviennent pas au cas où les variations lentes du signal sont éventuellement dues à des variations réelles dans l'objet d'étude. Dans le but d'incorporer des informations *a priori*, plusieurs auteurs ont proposé de coupler l'estimation du biais avec la segmentation des tissus. L'algorithme EM est utilisé dans [36] afin d'estimer alternativement le biais et les caractéristiques statistiques de chacun des tissus. Cet algorithme a été amélioré dans [11] par la modélisation des volumes partiels. L'EM a également été utilisé dans [23], où des informations morphologiques additionnelles ont été intégrées à l'aide d'un atlas. Enfin, certains auteurs utilisent un modèle à base de champ de Markov pour décrire les corrélations spatiales [37, 33]. Ces méthodes conviennent au cas où les images sont susceptibles d'être segmentées en zones homogènes, ce qui est effectivement le cas pour les applications cérébrales. Cependant cette hypothèse n'est pas valable dans d'autres types d'applications tels que les examens de muscle [18] ou l'analyse de produits agroalimentaires tels que le poisson [32] ou le pain [10].

Enfin, plusieurs auteurs proposent l'utilisation d'images additionnelles. Dans [7, 31, 19, 30] des images de fantômes ont été utilisées et considérées comme des images exactes du biais. Une approche hybride a été proposée dans [9] dans le cas particulier des antennes de surface. Une image additionnelle, acquise à l'aide d'une antenne corps, moins bien résolue mais supposée non biaisée, est utilisée. Cependant, comme dans toutes les méthodes précédemment citées, les auteurs modélisent les inhomogénéités par un biais multiplicatif variant lentement. Ils négligent ainsi la dépendance entre le T_1 des tissus et les inhomogénéités RFE.

Dans cet article nous présentons une méthode qui ne fait aucune hypothèse sur la morphologie de l'objet observé. De plus nous prenons en compte l'effet des inhomogénéités de la RFE liée au T_1 . Nous sommes amenés à utiliser plusieurs images mesurées soit sur l'objet d'intérêt soit sur des fantômes. De plus, les tissus composant l'objet sont supposés connus. Le signal est modélisé comme la somme des contributions de chaque tissu, ce qui permet également

de prendre en compte les voxels en volume partiel, c'est-à-dire comprenant un mélange de tissus. La méthode estime les cartes d'inhomogénéité RFR et RFE ainsi que les proportions de chaque tissu. Elle est basée sur l'estimation d'un critère qui prend en compte la fidélité du modèle aux données ainsi que des termes de régularisation assurant des solutions à variation spatiale douce pour RFE, RFR et les cartes de proportion. Pour ces dernières, une régularisation préservant les bords est proposée. L'utilisation de termes de régularisation permet en outre de réduire le bruit et ainsi corriger et débruiter les images dans une approche unifiée. L'article est organisé comme suit : Section 2, le modèle mathématique sur lequel s'appuie notre méthode est présenté. Il est ensuite étendu au cas général des voxels en volume partiel et une approche des moindres carrés pénalisée est proposée pour estimer les variables inconnues. En Section 3 la solution du problème d'optimisation est détaillée. La Section 4 détaille les conditions de simulation et d'expérimentation et la Section 5 est dédiée aux résultats. Nous présentons d'abord des résultats de simulation et ensuite des résultats obtenus sur des images réelles acquises sur un poisson avec un IRM bas champ. Ces résultats prouvent l'efficacité de la méthode pour quantifier la distribution des tissus indépendamment de la position dans l'IRM. Enfin, quelques perspectives sont proposées en Section 6.

2 Formulation du problème

2.1 Modélisation du signal IRM

Cas d'un objet avec un seul tissu. Le schéma de base d'une séquence « écho de spin » est l'application successive de deux impulsions RF basculant les protons de deux angles : un angle de bascule α puis un angle de refocalisation β . Ce schéma de base est répété et le temps de répétition est noté TR . Ainsi, dans le cas simple d'un objet composé d'un seul tissu et sous les hypothèses détaillées dans [5], en notant L le nombre de voxels, le signal d'une séquence écho de spin en l'absence de bruit s_ℓ au voxel $\ell = 1, \dots, L$ est modélisé par :

$$s_\ell = R_\ell Of(\eta_\ell, \theta, T_1)$$

avec $\theta = (\alpha, \beta, TR)$,

$$f(\eta_\ell, \theta, T_1) = \frac{1}{2} \frac{\sin \eta_\ell \alpha (1 - \cos \eta_\ell \beta) (1 - E_1)}{1 - E_1 \cos \eta_\ell \alpha \cos \eta_\ell \beta}, \quad (1)$$

où $E_1 = \exp(-TR/T_1)$. $\mathbf{R} = (R_\ell)$ représente la sensibilité de l'antenne RF en réception, $\boldsymbol{\eta} = (\eta_\ell)$ le facteur d'atténuation des angles de bascule et de refocalisation, lié à l'inhomogénéité RF en émission, O une constante, que nous appellerons *signal de référence*, telle que le signal pour $(\mathbf{R}, \boldsymbol{\eta}, \alpha, \beta) = (\mathbf{1}, \mathbf{1}, 90^\circ, 180^\circ)$ est égal à $O(1 - E_1)$, et T_1 le temps de relaxation longitudinal caractéristique du tissu.

\mathbf{R} et $\boldsymbol{\eta}$ représentent respectivement la sensibilité de l'antenne RF de réception RFR, et l'inhomogénéité spatiale des impulsions RF, RFE.

Le signal s_ℓ en l'absence d'inhomogénéité s'écrit :

$$s_\ell^* = Of(1, \theta, T_1).$$

On peut alors écrire s_ℓ sous la forme :

$$s_\ell = s_\ell^* R_\ell \frac{f(\eta_\ell, \theta, T_1)}{f(1, \theta, T_1)} = s_\ell^* M_\ell N_\ell,$$

avec

$$M_\ell = R_\ell \frac{\sin \eta_\ell \alpha (1 - \cos \eta_\ell \beta)}{\sin \alpha (1 - \cos \beta)} \quad (2)$$

qui correspond à un biais multiplicatif qui ne dépend pas du tissu, tandis que

$$N_\ell = \frac{1 - E_1 \cos \alpha \cos \beta}{1 - E_1 \cos \eta_\ell \alpha \cos \eta_\ell \beta} \quad (3)$$

forme un biais non-multiplicatif puisque sa valeur dépend du T_1 et par conséquent du tissu lui-même.

En réalité, \mathbf{R} et $\boldsymbol{\eta}$ dépendent de la géométrie et de la composition de l'objet imagé. Cependant, dans le cas des IRM bas-champ, cette dépendance est faible [27] et nous avons choisi de la négliger par la suite.

Les valeurs du biais non-multiplicatif N_ℓ sont représentées Figure 1 en fonction de η_ℓ et du rapport TR/T_1 , dans le cas d'images pondérées T_1 avec $TR/T_1 < 1.5$, pour $\alpha = 90^\circ$ et $\beta = 180^\circ$. Une étude préliminaire a permis d'établir que la gamme de variation pour η dans un IRM 0.2-T équipé d'une antenne tête était de 0.85 à 1.15. Pour $\eta = 1$, il n'y a pas d'inhomogénéité induite par une variation spatiale de RFE, donc pas de biais ($N_\ell = 1$). Pour $\eta > 1$, le biais N_ℓ augmente jusqu'à 1.15 pour de faibles valeurs de TR/T_1 . Pour $\eta < 1$, N_ℓ décroît jusqu'à 0.9 et atteint sa valeur la plus faible pour les plus faibles valeurs de TR/T_1 . En présence de plusieurs tissus avec des valeurs différentes de TR/T_1 , comme ce sera le cas dans la suite, ceci correspond bien à un comportement non-multiplicatif puisque ces différents tissus vont être affectés par des biais $N_{\ell i}$ différents. C'est le cas par exemple pour le gras et le muscle, pour lesquels TR/T_1 est égal respectivement à 1.4 et 0.28, pour $TR = 140$ à $0.2T$.




FIG. 1 – Courbes de niveau du biais non-multiplicatif N_ℓ en fonction de η_ℓ et TR/T_1 pour $\alpha = 90^\circ$ et $\beta = 180^\circ$.

Selon la précision recherchée, il peut être nécessaire de corriger ce biais non-multiplicatif. Cependant il dépend du T_1

du tissu inclus dans chaque voxel. De plus, plusieurs tissus (deux dans la plupart des cas) peuvent être présents dans un seul voxel. C'est pourquoi, il est nécessaire d'étendre le modèle au cas où l'objet est composé de plusieurs tissus.

Cas général d'un objet composé de plusieurs tissus.

Soit un objet composé de I tissus (*e.g.*, gras, muscle, matière blanche, matière grise, ...), imagé en écho de spin. Avec ce type de séquence, le signal d'un voxel est la somme des contributions de chaque tissu à l'intérieur du voxel. Pour chaque voxel ℓ , on peut écrire :

$$s_\ell = R_\ell \sum_{i=1}^I k_{\ell i} O_i f(\eta_\ell, \theta, T_{1i}) + n_\ell$$

où f est définie par (1), $k_{\ell i} \in [0, 1]$ est la proportion du tissu i dans le voxel ℓ , O_i le signal de référence du tissu i , T_{1i} le temps de relaxation longitudinal du tissu i et n_ℓ le bruit. $\theta = (\alpha, \beta, TR)$ est un vecteur qui correspond aux paramètres de la séquence IRM. Ils sont connus et choisis par l'opérateur IRM.

Enfin, si on considère que chaque voxel est rempli de tissus, c'est-à-dire si on exclut le cas de volumes partiels avec l'air, la relation suivante est vérifiée :

$$\sum_{i=1}^I k_{\ell i} = 1, \quad \forall \ell = 1, \dots, L. \quad (4)$$

Notre but est de retrouver le signal s^* qui serait mesuré par un IRM sans artefacts, c'est-à-dire, en notant $\mathbf{n} = (n_\ell)$, pour $(\mathbf{R}, \boldsymbol{\eta}, \mathbf{n}) = (\mathbf{1}, \mathbf{1}, \mathbf{0})$:

$$s_\ell^* = \sum_{i=1}^I k_{\ell i} O_i f(1, \theta, T_{1i}).$$

\mathbf{R} et $\mathbf{O} = (O_i)$ sont liés multiplicativement. Ainsi, tous les couples $(C\mathbf{R}, \mathbf{O}/C)$ (avec $C > 0$) donnent des mesures équivalentes. Afin de lever cette indétermination, nous proposons de considérer que les quantités O_i sont connues. En effet, elle peuvent être mesurées lors d'une procédure de calibration. Nous nous appuyons également sur une connaissance *a priori* des valeurs des T_{1i} . En effet ces valeurs peuvent être mesurées préalablement par RMN. Ainsi, les variables inconnues sont \mathbf{R} , $\boldsymbol{\eta}$ et $\mathbf{k} = (k_{\ell i})$, ce qui correspond à $I + 2$ images, *i.e.*, $(I + 1) \times N$ scalaires inconnus étant donnée la contrainte (4). Afin d'estimer ces variables, nous proposons d'acquérir $J \geq I + 1$ images $\mathbf{s}_j = (s_{j\ell})$, en utilisant des valeurs différentes pour les triplets θ . Une telle procédure augmente le temps d'acquisition, puisque plusieurs images sont nécessaires. Il y a plusieurs façons de remédier à ce problème. D'une part, une partie des images peut être acquise une fois pour toute sur un fantôme ; ou alors, il est possible de diminuer le nombre d'accumulations du signal. En effet, le moyennage du signal est typiquement utilisé en IRM et, comme il sera montré par la suite dans l'article, l'utilisation d'une régularisation peut permettre l'utilisation d'images plus bruitées et donc acquises dans un temps plus court.

2.2 Définition de la fonction de coût

\mathbf{R} et $\boldsymbol{\eta}$ dépendent de la géométrie de l'antenne. Ils suivent la loi de Biot et Savart et on peut considérer qu'ils varient lentement dans l'espace. Dans l'optique de réduire le bruit dans les images, une régularisation sur les cartes de proportion des tissus \mathbf{k} peut également être introduite. Cependant il est souhaitable de conserver les discontinuités apparaissant aux frontières séparant des tissus, c'est pourquoi nous proposons d'utiliser une régularisation préservant les bords pour \mathbf{k} .

Ainsi nous proposons d'estimer \mathbf{R} , \mathbf{k} et $\boldsymbol{\eta}$ en utilisant une approche des moindres carrés pénalisés : $(\hat{\mathbf{R}}, \hat{\mathbf{k}}, \hat{\boldsymbol{\eta}}) = \arg \min_{\mathbf{R}, \mathbf{k}, \boldsymbol{\eta}} \mathcal{J}(\mathbf{R}, \mathbf{k}, \boldsymbol{\eta})$ sous la contrainte (4), où

$$\begin{aligned} \mathcal{J}(\mathbf{R}, \mathbf{k}, \boldsymbol{\eta}) = & \sum_{j=1}^J \lambda_j \sum_{\ell=1}^L \left(\mathbf{s}_{j\ell} - R_\ell \sum_{i=1}^I O_{ji} k_{\ell i} f(\eta_\ell, \theta_j, T_{1i}) \right)^2 \\ & + \gamma_R \|\mathbf{D}\mathbf{R}\|^2 + \gamma_\eta \|\mathbf{D}\boldsymbol{\eta}\|^2 + \gamma_k \sum_{c \in \mathcal{C}} \phi(\|\mathbf{d}_c^t \mathbf{k}\|). \end{aligned} \quad (5)$$

avec $\phi(u) = \sqrt{\delta^2 + u^2}$ et $\|\cdot\|$ la norme L_2 usuelle. O_{ji} correspond au signal de référence du tissu i pour le signal j . Les paramètres λ_j , γ_R , γ_η et γ_k sont des poids positifs, et δ un scalaire. \mathcal{C} représente l'ensemble des paires de voxels adjacents $c = \{r, s\}$, avec $r < s$ selon un ordre arbitraire. \mathbf{d}_c est le vecteur des différences finies, de taille $L \times 1$, et tel que $\mathbf{d}_c^t \mathbf{k} = [k_{r1} - k_{s1}, \dots, k_{rI} - k_{sI}]^t$. Enfin, $\mathbf{D} = [d_1, \dots, d_C]^t$ est une matrice de taille $C \times L$, où $C = \text{Card}\mathcal{C}$.

Le premier terme de (5) traduit la fidélité des données au modèle, les deux suivants assurent une solution spatialement régulière pour \mathbf{R} et $\boldsymbol{\eta}$, et le dernier terme tend à décroître le bruit sur \mathbf{k} tout en permettant des variations rapides du signal. En effet, la fonction ϕ a un comportement quadratique près de 0 et un comportement asymptotique linéaire (voir Figure 2). Pour de grandes valeurs de $\|\mathbf{d}_c^t \mathbf{k}\|$, c'est-à-dire pour de grandes valeurs de différence de proportions entre des voxels adjacents, le terme de régularisation est plus petit que dans le cas où une régularisation quadratique est utilisée.




FIG. 2 – Variations de $\phi(u) = \sqrt{\delta^2 + u^2}$, $\delta > 0$.

3 Minimisation de la fonction de coût

Nous sommes en présence de trois groupes de variables, $\hat{\mathbf{R}}$, $\hat{\boldsymbol{\eta}}$ et $\hat{\mathbf{k}}$, qui correspondent à des propriétés physiques distinctes et qui ont un comportement différent vis-à-vis de la fonctionnelle à minimiser. C'est pourquoi nous avons choisi d'utiliser une approche itérative de type Gauss-Seidel par blocs, avec un bloc par groupe de variables, pour les estimer. Ce type d'algorithme converge vers un minimum local du critère, sous réserve de conditions mathématiques larges [2].

1. $\boldsymbol{\eta}$ et \mathbf{k} étant fixés à leur valeur courante, un nombre fixe d'itérations du gradient conjugué (GC) est appliqué à \mathcal{J} en fonction de \mathbf{R} .
2. \mathbf{R} et \mathbf{k} étant fixés à leur valeur courante, un nombre fixe d'itérations de GC est appliqué à \mathcal{J} en fonction de $\boldsymbol{\eta}$.
3. \mathbf{R} et $\boldsymbol{\eta}$ étant fixés à leur valeur courante, un nombre fixe d'itérations de GC est appliqué à \mathcal{J} en fonction de \mathbf{k} sous la contrainte (4).

Les étapes 1, 2 et 3 sont répétées, jusqu'à ce que la norme du gradient de \mathcal{J} par rapport à $(\mathbf{R}, \boldsymbol{\eta}, \mathbf{k})$ devienne suffisamment petite, *i.e.*, $\|\nabla \mathcal{J}(\mathbf{R}, \boldsymbol{\eta}, \mathbf{k})\| \leq \varepsilon$.

3.1 Etape 1 : minimisation en fonction de \mathbf{R}

L'étape 1 est simple puisque (5) est une fonction quadratique de \mathbf{R} . Nous avons implémenté une version sur-relaxée afin d'accélérer la convergence de l'algorithme. Ainsi à la fin de chaque étape 1, \mathbf{R} est mis à jour de la façon suivante :

$$\mathbf{R}^{(n)} = \omega \hat{\mathbf{R}}^{(n)} + (1 - \omega) \mathbf{R}^{(n-1)},$$

où n est le numéro de l'itération, $\hat{\mathbf{R}}^{(n)}$ (respectivement, $\mathbf{R}^{(n)}$) le résultat de la version non-relaxée (resp. relaxée) de l'étape 1, et ω le paramètre de relaxation. La convergence est assurée si $\omega \in]0, 2[$, et est accélérée si $\omega \in]1, 2[$ [22]. Nous avons choisi de fixer $\omega = 1.8$ empiriquement.

3.2 Etape 2 : minimisation en fonction de $\boldsymbol{\eta}$

\mathcal{J} est une fonction complexe de $\boldsymbol{\eta}$, potentiellement multimodale. Le résultat de la minimisation peut dépendre du point d'initialisation. Les valeurs des composantes de $\boldsymbol{\eta}$ varient entre 0.6 et 1.3, il est donc raisonnable de les initialiser à 1. L'algorithme GC est utilisé pour calculer la direction de descente. Le calcul du pas dans la direction de descente est non trivial et détaillé dans [6]. On peut démontrer que le Hessien de \mathcal{J} suivant $\boldsymbol{\eta}$ est borné. Une telle condition assure que \mathcal{J} admet une approximation supérieure quadratique sur laquelle s'appuie le calcul du pas.

3.3 Etape 3 : minimisation en fonction de \mathbf{k}

L'étape 3 correspond à la minimisation de \mathcal{J} en fonction de \mathbf{k} . Etant donné que ϕ est strictement convexe, il peut être facilement montré que \mathcal{J} est strictement convexe en fonction de \mathbf{k} , et donc est une fonction unimodale de \mathbf{k} . Nous

avons utilisé l'algorithme GC. La stratégie de recherche de pas dans la direction de descente est celle proposée dans [16]. De plus, afin de prendre en compte la contrainte (4), le vecteur gradient $\nabla \mathcal{J}_{\mathbf{k}}$ est remplacé par sa projection sur l'hyperplan défini par (4) [17].

4 Matériel

L'algorithme proposé a été testé à la fois sur des images simulées et sur des images réelles. Les conditions de génération des images simulées et d'acquisition des images réelles sont présentées. Ensuite les valeurs des paramètres de l'algorithme sont données.

4.1 Conditions d'acquisition

Nous avons utilisé des images de poissons gras (de type saumon ou truite) pour évaluer les performances de notre algorithme. La chair de poisson est constituée de deux tissus, le tissu musculaire et le tissu gras. Leurs T_1 sont connus approximativement. Ils ont été mesurés par RMN : $T_1 \approx 110$ ms pour le tissu gras et $T_1 \approx 500$ ms pour le muscle. Dans le cas de deux tissus, le nombre minimal d'images à acquérir est de trois.

- Une seule image s_1 a été acquise sur l'objet d'intérêt, avec pour paramètres d'acquisition $\theta_1 = (\alpha_1, \beta_1, TR_1) = (90^\circ, 180^\circ, 140 \text{ ms})$. Ces paramètres fournissent une image pondérée en T_1 où le contraste entre le gras et le muscle est élevé.
- Deux autres images (s_2, s_3) ont été acquises une fois pour toutes sur un cylindre rempli d'huile. Les paramètres d'acquisition étaient respectivement : $\theta_2 = (\alpha_2, \beta_2, TR_2) = (60^\circ, 180^\circ, 700 \text{ ms})$ et $\theta_3 = (\alpha_3, \beta_3, TR_3) = (120^\circ, 180^\circ, 700 \text{ ms})$.

Remarque : Les pixels du fond ne satisfont pas à la contrainte (4). Ils peuvent être facilement détectés par un simple seuillage et exclus de l'analyse.

4.2 Paramètres de l'algorithme

\mathbf{R} , $\boldsymbol{\eta}$, \mathbf{k}_1 et \mathbf{k}_2 ont été initialisés de la façon suivante : $\mathbf{R}^{(0)} = \boldsymbol{\eta}^{(0)} = \mathbf{1}$, and $\mathbf{k}_1^{(0)} = \mathbf{k}_2^{(0)} = 1/2$. Ces initialisations, suffisamment proches de la solution, permettent d'éviter les éventuels minima locaux. Un nombre fixe de 5 itérations a été choisi pour les trois étapes où intervient l'algorithme GC.

Un point clé de notre méthode est le choix des hyperparamètres λ_j , γ_R , γ_η , γ_k et δ . Selon l'interprétation probabiliste du critère \mathcal{J} , λ_j correspond à l'inverse de la variance du bruit de la j ème image. La variance du bruit peut facilement être estimée à partir des images IRM en utilisant par exemple la méthode proposée par [21]. Afin de choisir les autres paramètres, γ_R , γ_η , γ_k et δ nous avons effectué un ensemble de simulations avec γ_R et $\gamma_\eta \in \{0, 1e^1, 1e^2, 1e^3, 1e^4, 1e^5, 1e^6, 1e^7, 1e^8\}$, $\gamma_k \in \{0, 1, 1e^1, 1e^2, 1e^3\}$ et $\delta \in \{0.1, 0.2, 0.3, 0.4, 0.5, 0.6\}$. L'ensemble des valeurs choisies pour γ_R , γ_η et γ_k a été choisi empiriquement car aucune de ces valeurs ne peut être déterminée *a priori*. Par contre, la valeur de δ peut

être comparée à $\|d_c \mathbf{k}\|$, et considérée comme un seuil au-dessous duquel la fonction ϕ n'a plus un comportement quadratique. \mathbf{k}_i représentant une proportion de tissu $\in \{0, 1\}$, nous avons choisi pour δ des valeurs entre 0.1 et 0.6.

En ce qui concerne les simulations, le critère d'arrêt de l'algorithme est un seuil sur l'évolution de l'erreur d'estimation. Nous avons défini l'erreur d'estimation ϵ_k comme la norme L_1 entre la valeur réelle \mathbf{k}^{act} et la valeur estimée \mathbf{k}^{est} exprimée en % :

$$\epsilon_k = 100 \sum_{\ell=1}^L \sum_{i=1}^I |k_{\ell i}^{\text{act}} - k_{\ell i}^{\text{est}}|.$$

Nous avons arrêté l'algorithme quand $|(\epsilon_k(n) - \epsilon_k(n-1))|$, n étant le nombre d'itérations, est devenu plus petit que 10^{-2} , ce qui correspond à une erreur sur les proportions inférieure à 0,01%.

En ce qui concerne les images réelles, l'algorithme a été stoppé quand $\|\nabla \mathcal{J}(\mathbf{R}, \boldsymbol{\eta})\|$ devenait plus petit que $\varepsilon = 3L \times 10^{-2}$.

4.3 Comparaison avec un algorithme utilisant une approche directe

Afin d'évaluer les performances de notre méthode de correction nous proposons de la comparer avec une méthode existante proposée dans [5]. Cette dernière est restreinte à des valeurs de paramètres d'acquisition particulières et est basée sur la résolution d'un système d'équation sous l'hypothèse d'un bruit nul. En utilisant θ_2 et θ_3 précédemment décrits pour acquérir des images sur un objet homogène avec $T_1 \approx 100$ ms, nous pouvons considérer que $E_1 \approx 0$ puisque $T_1 \ll TR$. De plus, avec $\alpha_3 = 2\alpha_2$ et $\beta_3 = \beta_2$, nous obtenons en l'absence de bruit :

$$\begin{cases} 1 = k_{\ell 1} + k_{\ell 2} \\ s_{1\ell} = R_\ell \sum_{i=1}^2 k_{\ell i} O_i f(\eta_\ell, \theta_1, T_{1i}) \\ s_{2\ell} = R_\ell O_h \sin \eta_\ell \alpha_2 (1 - \cos \eta_\ell \beta_2) \\ s_{3\ell} = R_\ell O_h \sin 2\eta_\ell \alpha_2 (1 - \cos \eta_\ell \beta_2) \end{cases}$$

où O_h est le signal de référence du produit homogène. T_{11} , T_{12} , O_1 , O_2 et O_h considérés comme connus *a priori*, $k_{\ell 1}$, $k_{\ell 2}$, η_ℓ et R_ℓ peuvent être facilement déduits de ce système d'équations :

$$\begin{cases} R_\ell = \frac{s_{2\ell}}{O_h \sin \eta_\ell \alpha_2 (1 - \cos \eta_\ell \beta_2)} \\ k_{\ell 1} = \frac{1}{R_\ell} \frac{s_{1\ell} - O_2 f(\eta_\ell, \theta_1, T_{12})}{O_1 f(\eta_\ell, \theta_1, T_{11}) - O_2 f(\eta_\ell, \theta_1, T_{12})} \\ k_{\ell 2} = 1 - k_{\ell 1} \\ \eta_\ell = \frac{1}{\alpha_2} \arccos \frac{s_{3\ell}}{2s_{2\ell}} \end{cases} \quad (6)$$

Cette méthode impose un choix de paramètres d'acquisition bien précis. Cependant elle a l'avantage d'être simple

et rapide. Nous nous y référerons par la suite en tant que méthode directe » par opposition à l'approche inverse utilisée dans la méthode présentée ici.

4.4 Construction des images simulées

Une image virtuelle de poisson a été construite à partir d'une image réelle en utilisant la méthode directe sur une image acquise avec un très grand rapport signal sur bruit. Les deux images (s_2, s_3) simulent des images acquises sur un objet homogène. \mathbf{R} et $\boldsymbol{\eta}$ ont également été choisis à partir d'images réelles. Du bruit Gaussien a été ajouté aux trois images. Le bruit dans les images IRM, qui sont en fait des images de module, suit une loi de Rice [26]. Cependant, pour un RSB supérieur à 5 dB, ce qui est le cas dans la plupart des applications, il peut être assimilé à un bruit blanc Gaussien. L'écart type du bruit ajouté aux images a été respectivement de 100 pour s_1 et 30 pour s_2 et s_3 . Un niveau de bruit plus faible a été ajouté aux deux dernières car elle correspondent à des images acquises une fois pour toutes et peuvent donc l'être avec un temps d'acquisition plus long. Ces valeurs de bruit sont à comparer avec les valeurs des signaux. Les valeurs moyennes du signal sont respectivement de 650, 2000 et 2200 pour s_1, s_2 et s_3 .

4.5 Acquisition des images réelles

s_1 a été acquise sur une truite, et (s_2, s_3) sur un cylindre rempli d'huile. L'IRM utilisé était un appareil bas champ à 0.2 T (Open, Siemens). Le poisson était réfrigéré à 5°C pendant la mesure pour éviter les fluctuations du signal dues à des variations de température. Afin de valider les performances de notre algorithme, cinq images s_1^1, \dots, s_1^5 de la même coupe (virtuelle) du poisson ont été acquises en effectuant une translation de 22.5 mm entre chaque acquisition, le long de l'axe z (*i.e.*, l'axe perpendiculaire aux plans de coupe). Dans un IRM dénué d'artéfacts, ces cinq images seraient les mêmes, puisqu'elles ne dépendraient pas de leur zone d'acquisition. Dans un IRM réel elles diffèrent et devraient être équivalentes après correction.

Deux niveaux de bruit différents ont été obtenus en faisant varier le nombre de moyennages du signal, ceci afin de tester les capacités de débruitage de notre algorithme. Un ensemble d'images a été acquis sans aucun moyennage, nous nous y référerons par la suite comme les images *fortement bruitées* et un second ensemble d'images a été acquis avec un moyennage sur 10 acquisitions qui seront référencées par la suite comme les images *peu bruitées*.

Le champ de vue était de 200 mm \times 200 mm et la taille de la matrice $N = 256 \times 256$. L'épaisseur de coupe était de 4 mm pour s_1 . Elle a été augmentée à 10 mm pour s_2 et s_3 , ceci afin d'augmenter le RSB.

Les quantités O_i ont été directement mesurées sur s_1 : une région remplie de tissu gras a été manuellement sélectionnée et son intensité moyenne mesurée. De la même façon, une région connue comme physiologiquement très peu grasse (moins de 1%) a été choisie pour mesurer le signal de référence du muscle.

5 Résultats

5.1 Résultats des simulations

Influence de la valeur des hyperparamètres. Nous avons effectué les simulations pour toutes les combinaisons des paramètres. Les meilleurs résultats, correspondant à la plus faible valeur pour ϵ_k , ont été obtenus pour

$$\gamma_R = 1e^5, \gamma_\eta = 1e^4, \gamma_k = 1e^1, \delta = 0.3. \quad (7)$$

La Figure 3 montre l'évolution de ϵ_k pour $\gamma_R = 1e^5$ et $\gamma_\eta = 1e^4$ en fonction de γ_k et δ . La Figure 4 montre l'évolution de l'erreur pour $\gamma_k = 1e^1$ et $\delta = 0.3$ en fonction de γ_R et γ_η . Il est à noter que l'échelle est logarithmique pour γ_R , γ_η et γ_k .

La Figure 3 montre que la norme $L_1 \epsilon_k$ est peu sensible aux variations de γ_R et γ_η . La sensibilité en fonction de γ_η est très faible : de la plus faible à la plus forte valeur de γ_η , ϵ_k varie seulement de 5 à 7%. ϵ_k est plus sensible à la valeur de γ_R , car des valeurs de γ_R trop élevées produisent des erreurs importantes. Ceci est lié au fait que la précision de l'estimation de \mathbf{R} a plus d'influence sur l'estimation de \mathbf{k} que l'erreur sur $\boldsymbol{\eta}$. Ceci se déduit facilement de l'expression de $k_{\ell 1}$ en fonction de R_ℓ et η_ℓ dans le système d'équation (6) : la sensibilité de $k_{\ell 1}$ en fonction de R_ℓ est plus élevée que celle en fonction de η_ℓ .

La Figure 4 montre que la valeur de γ_k a plus d'influence sur l'erreur, bien que la même erreur est obtenue alors que γ_k varie de 1 à 100. Le paramètre δ semble avoir une influence limitée sur le résultat.

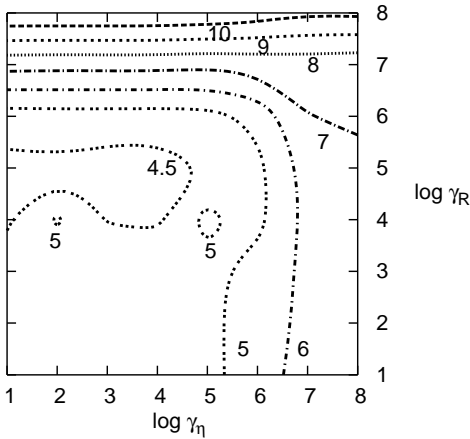


FIG. 3 – ϵ_k fonction de (γ_R, γ_η) pour $(\gamma_k, \delta) = (1e^1, 0.3)$.

En fait, la norme L_1 ne nous donne qu'une indication sur la performance de l'algorithme. En particulier, des résultats avec la même erreur peuvent correspondre à des images d'aspect différent. Ceci est illustré par la Figure 5. Les trois images ont été obtenues avec $\gamma_R = 1e^5$, $\gamma_\eta = 1e^4$ et $\gamma_k = 1e^1$. De gauche à droite la valeur de δ était respectivement 0.1, 0.3 et 0.6, l'erreur correspondante de 4.6, 4.4 et 4.6. Comme attendu, l'image obtenue avec la plus faible valeur de δ paraît moins bruitée et possède des régions plus homogènes, tandis que celle obtenue avec la plus grande




FIG. 4 – ϵ_k fonction de (γ_k, δ) pour $(\gamma_R, \gamma_\eta) = (1e^5, 1e^4)$.




FIG. 5 – \mathbf{k} estimé avec $\gamma_R = 1e^5$, $\gamma_\eta = 1e^4$ et $\gamma_k = 1e^1$. De gauche à droite : $\delta = 0.1, 0.3$ et 0.6 . L'erreur est 4.6, 4.4 et 4.6.

valeur de δ paraît plus bruitée. Cela montre les limites du critère utilisé pour choisir les meilleurs hyperparamètres et suggérerait de le définir en fonction des objectifs particulier de l'application visée. Cependant, nous considérons que ce critère nous donne une indication acceptable ici, d'autant que les images réelles que nous aurons à traiter ci-après auront le même type de structure que l'image utilisée pour les simulations. C'est pourquoi, dans la suite, les hyperparamètres ont été fixés aux valeurs données par (7).

Comparaison des résultats. La méthode complète donne une erreur de 4.4% avec un choix optimal des hyperparamètres.

Sans aucune régularisation, l'erreur augmente jusqu'à 7.4%. En d'autres termes la régularisation apporte un gain de 3%. Dans notre contexte applicatif, ce gain n'est pas négligeable car une variation de 1% est significative. En l'absence d'estimation du biais non-multiplicatif, l'erreur était de 6.6% ce qui prouve l'intérêt de le prendre en compte.

Enfin, la méthode directe donne une erreur de 7.4% qui est à comparer avec notre méthode sans aucune régularisation. Comme attendu, elle donne la même erreur, mais ne reste utilisable que pour des conditions d'acquisition particulières.




FIG. 6 – De gauche à droite : images originales acquises à 0 mm et 45 mm du centre du système IRM, et les images corrigées correspondantes.

5.2 Résultats obtenus sur les image réelles

Correction des images bruitées. Les deux images de gauche de la Figure 6 sont deux des cinq images acquises sur la même coupe virtuelle du poisson, à différentes positions dans l'IRM, dans le cas des images très bruitées. Les deux images corrigées correspondantes sont à droite. Les couleurs les plus claires correspondent au tissu gras et les plus sombres au muscle. Il est à noter que la plupart des voxels contiennent un mélange des deux tissus, ce qui empêche toute segmentation.

Les effets des inhomogénéités RF sont clairement visibles sur les images originales. En particulier l'image à 45 mm a des intensités plus faibles. Après correction les deux images retrouvent des intensités similaires. Les histogrammes d'intensité du signal sont représentés sur la Figure 7 pour les cinq images originales, et sur la Figure 8 pour les cinq images corrigées. Les histogrammes des cinq images originales diffèrent significativement les uns des autres à cause des inhomogénéités, tandis que les histogrammes des images corrigées sont similaires. De plus, les images corrigées ont des histogrammes moins étalés, car leur niveau de bruit est plus faible.

La Figure 9 montre les histogrammes d'intensité du signal pour les cinq images après correction partielle : seul R a été estimé et pris en compte dans la correction, tandis que η était supposé égal à 1. Cette configuration est équivalente à modéliser l'inhomogénéité par un biais purement multiplicatif. Le résultat confirme que cela ne suffit pas. Ceci est particulièrement vrai pour les zones qui contiennent plus de muscle que de gras car pour ce tissu le rapport TR/T_1 est plus faible et le biais-multiplicatif plus élevé.

Effets de la régularisation. Afin de quantifier les effets de la régularisation, nous avons calculé la norme L_1 de la différence entre d'une part les images fortement bruitées corrigées avec et sans régularisation, et d'autre part avec les images faiblement bruitées corrigées sans régularisation. Ces dernières font ainsi office de référence.

La Figure 10 montre la norme L_1 de la différence entre k_1 estimé à partir des images fortement bruitées (avec et sans régularisation) et k_1 estimé à partir des images faiblement bruitées (sans régularisation). En fonction de la position la régularisation apporte un gain de 2.3 à 2.7%. Cette apport




FIG. 7 – Histogrammes des intensités du signal pour les cinq images originales.

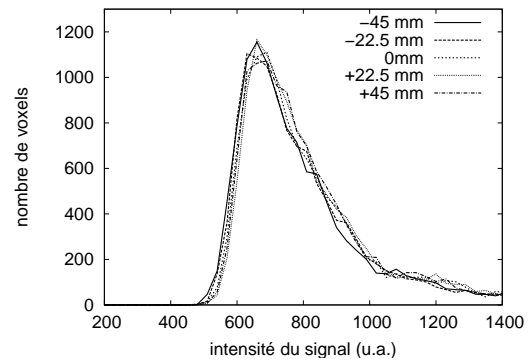


FIG. 8 – Histogrammes des intensités du signal pour les cinq images corrigée.




FIG. 9 – Histogrammes des intensités du signal pour les cinq images corrigée sans estimation de η .

est significatif et confirme celui observé dans l'étude par simulation qui était de 3%.

6 Conclusion

Nous avons proposé une méthode de correction des inhomogénéités spatiales de la RF en émission et en réception pour des images IRM. Elle est basée sur la modélisation du signal par la somme des contributions de différents tissus, ce qui permet de prendre en compte le fait que le biais engendré par les inhomogénéités de la RF en émission dépend du tissu en présence, plus particulièrement dans le cas des images pondérées T_1 . Nous n'utilisons pas l'hypo-

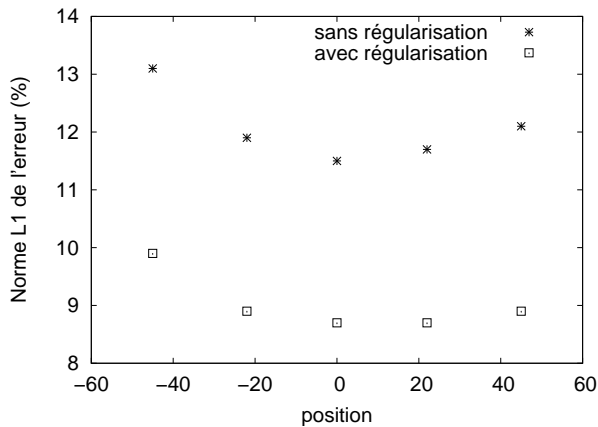


FIG. 10 – Norme L_1 de l'erreur, entre k_1 estimé à partir des images fortement bruitées (avec et sans régularisation) et k_1 estimé à partir des images faiblement bruitées (sans régularisation).

thèse d'existence de zones homogènes dans l'image, hypothèse trop restrictive dans le cadre d'applications non-médicales, comme le contexte des produits agroalimentaires par exemple. Notre approche est basée sur l'utilisation de plusieurs images acquises avec différents paramètres.

Un critère des moindres carrés pénalisé a été défini pour prendre en compte à la fois la fidélité du modèle aux données et le caractère régulier des cartes RF à estimer. Une régularisation non-quadratique a été également appliquée au contenu de l'image afin de réduire le bruit tout en conservant les discontinuités. La méthode a été testée sur un poisson, représentant un objet à deux tissus, en utilisant un ensemble de trois images, dont deux ont été acquises sur un fantôme d'huile.

Des résultats de simulation ont montré que notre méthode permettait de réduire la norme L_1 de l'erreur de 7.4 à 4.4% comparée à une méthode classique basée sur un calcul direct. Ces résultats montrent également l'apport de la régularisation et de l'estimation du biais non-multiplicatif. Enfin, nous avons également montré que le choix des hyperparamètres n'était pas crucial. Des images réelles acquises sur un poisson ont confirmé ces résultats.

Afin d'améliorer la méthode et élargir les applications potentielles plusieurs points restent à explorer. Le temps d'acquisition est un point clé en IRM et notre méthode nécessite au moins trois images (dans le cas d'un objet à deux tissus). Dans le cadre de l'IRM bas-champ, deux de ces images peuvent être acquises une fois pour toute sur un objet homogène. Cependant l'idéal serait d'acquérir toutes les images sur l'objet, notamment dans l'optique d'utiliser la méthode sur un IRM haut-champ où les inhomogénéités RF dépendent de l'objet imagé et où l'utilisation de fantôme serait moins adaptée. Dans le cas où toutes les images doivent être acquises sur l'objet d'intérêt, il paraît possible de limiter le temps d'acquisition en utilisant un nombre d'accumulations du signal plus faible et obte-

nir ainsi des images plus bruitées. Notre approche étant régularisée, nous pouvons espérer qu'un certain degré de dégradation des données n'entachera pas la précision des estimations.

Un autre point clé de la méthode est la connaissance *a priori* de plusieurs constantes. Nous étudions en particulier la possibilité d'estimer également les signaux de référence O^i .

Références

- [1] B. Belaroussi, J. Milles, S. Carme, Y. M. Zhu, and H. Benoit-Cattin. Intensity non-uniformity correction in MRI : Existing methods and their validation. *Med. Image. Anal.*, 10(2) :234–246, 2006.
- [2] J.C. Bezdek, R.J. Hathaway, R.E. Howard, C.A. Wilson, and M.P. Windham. Local convergence analysis of a grouped variable version of coordinate descent. *J. Optim. Theory Appl.*, 54(3) :471–477, 1987.
- [3] B. Blümich. *NMR imaging of materials*. Monographs on the physics and chemistry of materials. Oxford University Press, 2000.
- [4] B.H. Brinkmann, A. Manduca, and R.A. Robb. Optimized homomorphic unsharp masking for MR grayscale inhomogeneity correction. *IEEE Trans. Medical Imaging*, 17(2) :161–171, 1998.
- [5] G. Collewet, A. Davenel, C. Toussaint, and S. Akoka. Correction of intensity nonuniformity in spin-echo T1-weighted images. *Magn. Reson. Imaging*, 20(4) :365–373, 2002.
- [6] G. Collewet and J Idier. RF inhomogeneities correction in MRI T_1 -weighted spin-echo image handling the non-multiplicative character of the bias field. Rapp. tech., IRCCyN, 2007.
- [7] B.R. Condon, J. Patterson, D. Wyper, A. Jenkins, and D.M. Hadley. Image non-uniformity in magnetic resonance imaging : its magnitude and methods for its correction. *Brit. J. Radiol.*, 60(709) :83–87, 1987.
- [8] V. Daanen, E. Coste, G. Sergent, F. Godart, C. Vasseur, and J. Rousseau. Accurate localization of needle entry point in interventional MRI. *J. Magn. Reson. Imaging*, 12(4) :645–649, 2000.
- [9] A. Fan, W.M. Wells III, J.W. Fisher III, Çetin Müjdat, S. Haker, R. Mulkern, C. Tempany, and A.S. Willsky. A unified variational approach to denoising and bias correction in MR. In *Information Proc Med Imaging*, pages 148–159, 2003.
- [10] A. Grenier, T. Lucas, G. Collewet, and A. Le Bail. Assessment by MRI of local porosity in dough during proving. Theoretical considerations and experimental validation using a spin-echo sequence. *Magn. Reson. Imaging*, 21(9) :1071–1086, 2003.
- [11] R. Guillemaud and M. Brady. Estimating the bias field of MR images. *IEEE Trans. Medical Imaging*, 16(3) :238–251, 1997.

- [12] E.M. Haacke, R.W. Brown, M.R. Thompson, and R. Venkatesan. *Magnetic Resonance Imaging : Physical Principles and Sequence Design*. Wiley-Liss, 1999.
- [13] B. Hills. *Magnetic resonance imaging in food science*. Wiley-Interscience, 1998.
- [14] Zujun Hou. A review on MR image intensity inhomogeneity correction. *Int. J. Biomed. Imaging*, 2006 :1–11, 2006.
- [15] A. Koivula, J. Alakuijala, and O. Tervonen. Image feature based automatic correction of low-frequency spatial intensity variations in MR images. *Magn. Reson. Imaging*, 15(10) :1167–1175, 1997.
- [16] Christian Labat and Jérôme Idier. Convergence of conjugate gradient methods with a closed-form step-size formula. *J. Optim. Theory Appl.*, 135(2), 2007.
- [17] David G. Luenberger. *Optimization by Vector Space Methods*. John Wiley & Sons, Inc., New York, NY, USA, 1997.
- [18] F. A. Marden, A. M. Connolly, M. J. Siegel, and D. A. Rubin. Compositional analysis of muscle in boys with duchenne muscular dystrophy using MR imaging. *Skeletal Radiology*, 34(3) :140–148, 2005.
- [19] E.R. McVeigh, M.J. Bronskill, and R.M. Henkelman. Phase and sensitivity of receiver coils in magnetic resonance imaging. *Med. Phys.*, 13(6) :806–814, 1986.
- [20] T. Merl, M. Scholz, P. Gerhardt, M. Langer, J. Laubenberger, H. D. Weiss, H. B. Gehl, K. J. Wolf, and I. Ohnesorge. Results of a prospective multicenter study for evaluation of the diagnostic duality of an open whole-body low-field MRI unit. A comparison with high-field MRI measured by the applicable gold standard. *Eur. J. Radiol.*, 30(1) :43–53, 1999.
- [21] R. D. Nowak. Wavelet-based Rician noise removal for magnetic resonance imaging. *IEEE Trans. Medical Imaging*, 8(10) :1408–1419, 1999.
- [22] William H. Press, Brian P. Flannery, Saul A. Teukolsky, and William T. Vetterling. *Numerical Recipes : The Art of Scientific Computing*. Cambridge University Press, 1988.
- [23] S. Prima, N. Ayache, T. Barrick, and N. Roberts. Maximum likelihood estimation of the bias field in MR brain images : Investigating different modelings of the imaging process. In *MICCAI*, pages 818–819. Springer-Verlag Berlin Heidelberg, 2001.
- [24] D.H.F. Robb, S.C. Kestin, P.D. Warriss, and G.R. Nute. Muscle lipid content determines the eating quality of smoked and cooked atlantic salmon (*salmo solar*). *Aquaculture*, 205(3-4) :345–358, 2002.
- [25] R. B. Sequeiros, H. Reinikainen, A. M. B. Sequeiros, T. Vaara, R. Ojala, E. Paakko, and O. Tervonen. MR-guided breast biopsy and hook wire marking using a low-field (0.23 T) scanner with optical instrument tracking. *European Radiology*, 17(3) :813–819, 2007.
- [26] J. Sijbers, A.J. Den Dekker, J. Van Audekerke, M. Verhoye, and D. Van Dick. Estimation of the noise in magnitude MR images. *Magn. Reson. Imaging*, 16(1) :87–90, 1998.
- [27] J. G. Sled and G. B. Pike. Standing-wave and RF penetration artifacts caused by elliptic geometry : An electrodynamic analysis of MRI. *IEEE Trans. Medical Imaging*, 17(4) :653–662, 1998.
- [28] J. G. Sled and G. B. Pike. Correction for B_1 and B_0 variations in quantitative T_2 measurements using MRI. *Magn. Reson. Med.*, 43(4) :589–593, 2000.
- [29] J. G. Sled, A. P. Zijdenbos, and A. C. Evans. A non-parametric method for automatic correction of intensity nonuniformity in MRI data. *IEEE Trans. Medical Imaging*, 17(1) :87–97, 1998.
- [30] M. Tincher, C. R. Meyer, R. Gupta, and D. M. Williams. Polynomial modeling and reduction of RF body coil spatial inhomogeneity in MRI. *IEEE Trans. Medical Imaging*, 12(2) :361–365, 1993.
- [31] P. S. Tofts, G. J. Barker, A. Simmons, D. G. Macmanus, J. Thorpe, A. Gass, and D. H. Miller. Correction of nonuniformity in images of the spine and optic-nerve from fixed receive-only surface coils at 1.5-T. *J. Comput. Assist. Tomogr.*, 18(6) :997–1003, 1994.
- [32] Caroline Toussaint, Benoit Fauconneau, Françoise Medale, Guylaine Collewet, Serge Akoka, Pierrick Haffray, and Armel Davenel. Description of the heterogeneity of lipid distribution in the flesh of brown trout (*salmo trutta*) by MR imaging. *Aquaculture*, 243(1-4) :255–267, 2005.
- [33] K. Van Leemput, F. Maes, D. Vandermeulen, and P. Suetens. Automated model-based bias field correction of MR images of the brain. *IEEE Trans. Medical Imaging*, 18(10) :885–896, 1999.
- [34] U. Vovk, F. Pernus, and B. Likar. A review of methods for correction of intensity inhomogeneity in MRI. *IEEE Trans. Medical Imaging*, 26(3) :405–421, 2007.
- [35] J. Wang, M. Qiu, and R.T. Constable. In vivo method for correcting transmit/receive nonuniformities with phased array coils. *Magn. Reson. Med.*, 53(3) :666–674, 2005.
- [36] W.M. Wells, R Kikinis, W.E.L Grimson, and F Jolesz. Adaptive segmentation of MRI data. *IEEE Trans. Medical Imaging*, 15(4) :429–422, 1996.
- [37] Y. Zhang, M. Brady, and S. Smith. Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm. *IEEE Trans. Medical Imaging*, 20(1) :45–57, 2001.