

Algorithmes flous : Application à la quantification du tissu adipeux en IRM abdominale.

Vincent ROULLIER^{1,3}, Christine CAVARO-MÉNARD¹, Guillaume CALMON³, Christophe AUBÉ²

¹LISA UPRES EA-4014

62, Avenue Notre Dame du Lac, 49000 Angers, France

²CHU Angers, Service de Radiologie

4, Rue Larrey, 49933 Angers Cedex 9, France

³GE Healthcare

283, Rue de la Minière, 78530 Buc, France

vincent.roullier@etud.univ-angers.fr, christine.menard@univ-angers.fr,
guillaume.calmon@med.ge.com, christophe.aube@chu-angers.fr

Résumé – Le syndrome métabolique, associé à l’obésité est une pathologie en forte progression dans nos sociétés occidentales. Un marqueur jouant un rôle prépondérant dans le diagnostic de cette pathologie est le tour de taille, dépendant de la graisse viscérale et sous-cutanée. Nous proposons dans cet article une méthode automatique et fiable de segmentation des graisses viscérale et sous-cutanée utilisant successivement un algorithme de classification floue suivi d’un algorithme de connectivité nous permettant de nous affranchir des problèmes d’inhomogénéités du tissu adipeux et du champs magnétique.

Abstract – Metabolic syndrome, associated to abdominal obesity is a fast growing disease in our western countries. Waist circumference, related to visceral and subcutaneous adipose tissue, plays a key role in the diagnostic of this disease. The purpose of this article is to develop an automatic and reliable method to segment visceral and subcutaneous fat, by using, first a fuzzy classification algorithm followed of a connectednes algorithm that avoid inhomogeneities problem of adipose tissue and magnetic field.

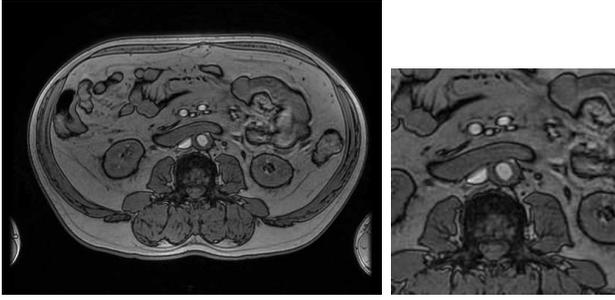
1 Introduction

Près d’un quart des adultes de plus de 40 ans est en surpoids ou obèse aux Etats-Unis. Ce constat est semblable en France avec une statistique alarmante : 1 enfant sur 2 de moins de 12 ans est en surpoids. Le syndrome métabolique est la pathologie conséquente à ce problème de surpoids, récurrent dans nos sociétés sédentaires. Cette pathologie augmente le risque chez le patient de développer des maladies cardio-vasculaires (infarctus), des pathologies rénales et du diabète. L’augmentation du tour de taille est l’un des cinq critères du syndrome métabolique. Mais cette augmentation peut être causé par deux types de tissus adipeux (graisse viscérale et graisse sous-cutanée) dont les rôles sont différents dans le syndrome métabolique, d’où l’importance de les distinguer.

Dans cet article, nous proposons une méthode automatique et fiable pour segmenter les graisses viscérale et sous-cutanée, afin de détecter les patients ayant un risque de développer le syndrome métabolique et de suivre l’évolution de la répartition du tissu adipeux abdominal à la suite d’un traitement. En routine clinique, ces mesures requièrent une segmentation manuelle longue et fastidieuse par les radiologistes. Positano *et al.* [1] ont proposé une méthode utilisant un algorithme de classification floue et les contours actifs pour segmenter les tissus adipeux viscéral et sous-cutané. Les résultats sont bons pour la graisse sous-cutanée mais prennent en compte certains organes in-

ternes (reins, intestins et vaisseaux qui ne contiennent pas de graisse) dans la segmentation de la graisse viscérale. En fait, les méthodes utilisant les contours actifs ne sont pas adaptées à la segmentation de la graisse viscérale car celle-ci est caractérisée par une forme complexe et variable. La méthode décrite dans [2] utilise une séquence d’acquisition spécifique qui supprime le pic de l’eau. La segmentation est alors obtenue par un simple seuillage manuel. Cette méthode est rapide mais requiert l’intervention d’un radiologue pour trouver le seuil et pour séparer la graisse viscérale de la graisse sous-cutanée. De plus, cette méthode prend en compte des pixels qui ne correspondent pas de la graisse à cause des inhomogénéités d’intensité. Actuellement, la segmentation s’effectue manuellement par un radiologue. Ce travail est long et fastidieux et est tenir à jour en routine clinique.

Dans cet article, nous présentons une méthode automatique et fiable de segmentation des tissus adipeux viscéral et sous-cutané sur des images IRM. Cette méthode prend en compte les inhomogénéités des intensités du signal IRM dues à la séquence d’acquisition et aux inhomogénéités du champ magnétique et du signal reçu par l’antenne. La méthode que nous avons développé utilise dans un premier temps un algorithme de classification floue, et dans une second temps, un algorithme de connectivité floue.



(a) Image sur laquelle le signal de l'eau et de la graisse sont en opposition (b) Zoom de l'image

FIG. 1 – a) Une coupe abdominale d'un patient acquise par IRM. b) Un agrandissement d'une région de l'image (a)

2 Matériels

2.1 Patients

Nous avons inclus dans cette étude 37 patients (28 hommes et 9 femmes) avec un âge moyen de 59.7 ans (de 42 à 73 ans). Les patients sont en surpoids avec un poids moyen de 94.13 Kg (de 66 à 126 Kg) avec une IMC¹ moyen de 33.4 Kg/m² (de 24.3 à 41.3 Kg/m²). Tous les patients inclus dans cette étude ont un syndrome métabolique diagnostiqué en accord avec la définition médicale de cette pathologie. Les patients n'avaient aucune contre indication au passage d'un examen IRM (claustrophobie, stimulateur cardiaque, ...).

2.2 Acquisition

L'examen IRM s'effectue pour l'ensemble des patients en utilisant une séquence d'acquisition standard. Les images sont acquises sur un IRM 1.5T avec une antenne multicanaux flexible (Signa Excite et antenne flexible 8 canaux en réseau phasé - GE Healthcare - Milwaukee - USA). L'image IRM est une image axiale pondérée T1 en opposition de phase centrée sur la troisième vertèbre lombaire. L'image en opposition de phase, i.e. le signal de l'eau et de la graisse sont opposés, permet de mettre en évidence les contours des organes, zone où les proportions de graisse et d'eau sont les mêmes (Figure 1). L'acquisition s'effectue en apnée afin d'éviter les artefacts de respiration.

3 Méthode de segmentation

La méthode de segmentation que nous avons développée se déroule en deux étapes. Les pixels ayant une intensité proche de celle de la graisse sont tout d'abord extraits de l'image. Pour cela, nous utilisons un algorithme de classification fondée sur la logique floue. Ensuite, un algorithme de connectivité floue ajoute à la classe graisse les pixels non classés proche en distance et en intensité. Ce second algorithme nous permet également de discriminer

¹Indice de Masse Corporelle (IMC) est un rapport entre la taille et le poids associé à la graisse du corps et aux risques de santé. L'IMC se calcule ainsi : (Poids en Kg)/(Taille en mètre)². Lorsque l'IMC est supérieur à 25, la personne est en surpoids.

la graisse sous-cutanée de la graisse viscérale. nous allons, grâce à l'algorithme de connectivité floue,

3.1 Classification floue généralisée

Les méthodes de segmentation utilisant la classification floue permettent de regrouper les pixels en fonction de la distribution de leurs intensités. Les méthodes de classification s'expriment sous la forme d'une fonction objective que l'on doit minimiser. Cette fonction objective attribue à chaque arrangement de pixels une énergie, fonction de la distance entre la donnée (i.e. l'intensité) et le représentant de chaque classe (i.e. le centroïde). La résolution de cette fonction objective fut d'abord développée par Dunn [3] et ensuite améliorée par Bezdek en 1981 [4] avec l'introduction d'un facteur de floue m apportant une incertitude dans la partition floue.

Nous utilisons pour notre application une fonction objective généralisée, extension de la fonction objective de Bezdek, proposée par M. Ménard [5]. Cette fonction objective inclue l'information de Tsallis qui permet de prendre en compte des pixels plus éloignés des centroïdes et également d'espacer davantage les centroïdes les uns des autres par rapport à la classification floue proposé par Bezdek.

Si $Y = \{y_1, y_2, \dots, y_n\}$ est l'ensemble des données que l'on souhaite partitionner, $U = (u_{ik})$, la matrice $c \times n$ des u_{ik} (mesure d'appartenance de la donnée y_k à la classe i), $V = \{v_1, v_2, \dots, v_c\}$, les représentants des c classes et m le degré de floue, la fonction objective proposée par M. Ménard, dans le cas de l'approche probabiliste (FGcM : Fuzzy Generalized c-Means) s'écrit ainsi (équation 1).

$$J(U, V; Y) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d^2(y_k, v_i) + \frac{1}{\lambda(m-1)} \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m - \frac{1}{\lambda} \sum_{k=1}^n \gamma_k \left(\sum_{i=1}^c u_{ik} - 1 \right) \quad (1)$$

avec comme premier terme, le terme des moindres carrés (que l'on retrouve dans la fonction objective de Bezdek présentée dans [4]), puis le terme dépendant de l'entropie de Tsallis paramétré par λ , et le dernier terme, la contrainte probabiliste.

La fonction objective, dans le cas de l'approche possibiliste (PGcM : Possibilistic Generalized c-Means), s'écrit de la manière suivante (équation 2) :

$$J(U, V; Y) = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d^2(y_k, v_i) + \frac{1}{\lambda(m-1)} \sum_{i=1}^c \sum_{k=1}^n [u_{ik}^m - u_{ik}] - \frac{1}{\lambda} \sum_{i=1}^c \sum_{k=1}^n u_{ik} \quad (2)$$

Le processus de minimisation de ces fonctions objectives est un processus itératif permettant de déterminer U et V de telle sorte que $J(U, V; Y)$ soit minimale. La fonction

utilisée pour mettre à jour U à chaque itération est, dans le cas probabiliste (équation 3) :

$$u_{ik} = \frac{1}{Z_m} [1 + \lambda(m-1)d^2(y_k, v_i)]^{-\frac{1}{m-1}} \quad (3)$$

avec $Z_m = \sum_{j=1}^c [1 + \lambda(m-1)d^2(y_k, v_j)]^{-\frac{1}{m-1}}$ et dans le cas possibiliste (équation 4) :

$$u_{ik} = \frac{1}{[1 + \lambda(m-1)d^2(y_k, v_i)]^{\frac{1}{m-1}}}. \quad (4)$$

Et l'équation de mise à jour des prototypes est de la forme (dans les deux approches) (équation 5) :

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m y_k}{\sum_{k=1}^n u_{ik}^m}. \quad (5)$$

Pour notre application, nous utilisons successivement l'approche probabiliste suivie de l'approche possibiliste. Tout d'abord, nous utilisons l'algorithme probabiliste initialisé aléatoirement, nous permettant de nous approcher de la valeur *VRAI* des centroïdes. Ensuite, nous utilisons l'approche possibiliste initialiser par les résultats précédents, pour s'approcher plus précisément de la valeur *VRAI* des centroïdes. Pour notre application, nous recherchons trois classes, la classe *fond*, la classe *graisse* et la classe que l'on appelle *reste* (i.e. organes, vaisseaux, muscles, ...). La figure 2 présente un résultat de classification sur une coupe IRM.

Après le processus de classification, un algorithme de connectivité floue est utilisé sur l'image classée permettant d'ajuster les erreurs de la classification dues aux inhomogénéités d'intensités et également afin de séparer la graisse viscérale de la graisse sous-cutanée.

3.2 Connectivité floue

La connectivité floue, introduite par Udupa [6] a été utilisée avec succès dans de nombreuses applications. Cette méthode utilise le fait que les images IRM sont en soi inhomogènes (l'inhomogénéité du champ magnétique et à l'acquisition). Le principe de l'algorithme de connectivité floue est de regrouper des pixels ayant un certain niveau de *similarité* (connectivité floue). Pour cela, Udupa définit l'*affinité* entre deux pixels d'une image par le degré d'*adjacence* et de *similarité* de leurs intensités. Une relation floue de connectivité s'exprime dans une image en assignant à chaque paire de pixels une mesure de *coût* désignant le degré de similarité. Le coût du chemin permettant de connecter deux pixels est définie comme étant l'affinité la plus faible sur le chemin. Le degré de connectivité floue entre deux pixels est le coût optimal sur l'ensemble des chemins connectant ces deux pixels. Udupa définit une *scène floue* comme une carte représentant de degré de connectivité floue entre chaque pixel de l'image. Afin d'obtenir une image binaire, on définit un seuil sur la mesure de connectivité floue.

Mathématiquement, cela se traduit ainsi, la mesure d'affinité est de la forme suivante (équation 6) :

$$\begin{aligned} k &= \{(c, d), \mu_k(c, d) | (c, d) \in C\} \\ \mu_k &: C \times C \rightarrow [0, 1], \\ \mu_k(c, c) &= 1, \quad \forall c \in C \\ \mu_k(c, d) &= \mu_k(d, c), \quad \forall (c, d) \in C. \end{aligned} \quad (6)$$

où c et d sont deux pixels de l'image. La forme générale de μ_k est la suivante $\mu_k(c, d) = h(\mu_\alpha(c, d), \mu_\psi(c, d), \mu_\phi(c, d), c, d)$ pour tout $(c, d) \in C$ où :

- $\mu_\alpha(c, d)$ représente le degré d'*adjacence* de c et d ,
- $\mu_\psi(c, d)$ représente le degré de *similarité* d'intensité entre c et d ,
- $\mu_\phi(c, d)$ représente le degré de *similarité* d'intensité entre c et d pour l'image gradient.

Pour notre application, nous avons défini μ_k de la manière suivante (équation 7) :

$$\begin{cases} \mu_k(c, d) &= \mu_\alpha(c, d)[w_1.h_1(f(c), f(d)) + \\ &w_2.h_2(f(c), f(d))], \\ \mu_k(c, c) &= 1, \end{cases} \quad (7)$$

comme une combinaison linéaire de $h_1(f(c), f(d))$ et $h_2(f(c), f(d))$ ($f(c)$ et $f(d)$ sont les intensités des pixels c et d), avec $w_1 + w_2 = 1$, $\mu_\alpha(c, d)$ la mesure d'adjacence, $h_1(f(c), f(d))$ fonction de l'intensité, $h_2(f(c), f(d))$ fonction du gradient.

La fonction d'adjacence est une relation booléenne définie ainsi : $\mu_\alpha(c, d) = 1$ si $\sqrt{\sum_i (c_i - d_i)^2} \leq 1$ et 0 sinon.

Les fonctions h_1 and h_2 sont des fonctions Gaussiennes de $\frac{1}{2}(f(c) + f(d))$ et $|f(c) - f(d)|$, respectivement, définie ainsi (équation 8) :

$$\begin{aligned} h_1(f(c), f(d)) &= \exp\left\{-\frac{1}{2}\left[\frac{\frac{1}{2}(f(c)+f(d))-m_1}{s_1}\right]^2\right\} \\ h_2(f(c), f(d)) &= \exp\left\{-\frac{1}{2}\left[\frac{|f(c)-f(d)|-m_2}{s_2}\right]^2\right\} \end{aligned} \quad (8)$$

avec m_1 (respectivement m_2) l'intensité moyenne et s_1 (respectivement s_2) l'écart type de la région (respectivement du gradient de la région).

Nous avons utiliser comme paramètre w_1 et w_2 égaux à 0.5. Pour obtenir une image binaire, nous utilisons un seuil de 0.5 sur la mesure de connectivité floue.

3.3 Algorithme générale

L'algorithme général implanté pour notre application est le suivant. Tout d'abord, nous effectuons une classification de l'image en trois classes. Ensuite, l'image ainsi classée est traitée par l'algorithme de connectivité floue via une sélection de la région que l'on souhaite segmenter. L'algorithme de connectivité nous fournit une image binaire après seuillage de la mesure (Figure 2-c,d).

4 Resultats

Nous avons comparé sur 34 images les surfaces de graisse viscérale d'une part et sous-cutanée d'autre part calculées par notre algorithme à celles définies après segmentation manuelle des IRM par un expert radiologue. La zone de graisse sous-cutanée présente peu de structures internes comparée à celle du tissu adipeux viscéral où nous trouvons différents organes et vaisseaux. De ce fait, la corrélation entre les surfaces obtenues par l'expert et par l'algorithme pour le graisse sous-cutanée est bonne ($r^2 = 0,94$). La corrélation entre les résultats de l'expert et du logiciel est, pour le tissu adipeux viscéral, de par les inhomogénéités du signal de la graisse, moins bonne ($r^2 = 0,84$).

Les résultats obtenus par l'expert sont, sur certains patients, assez différents des résultats obtenus par l'algo-

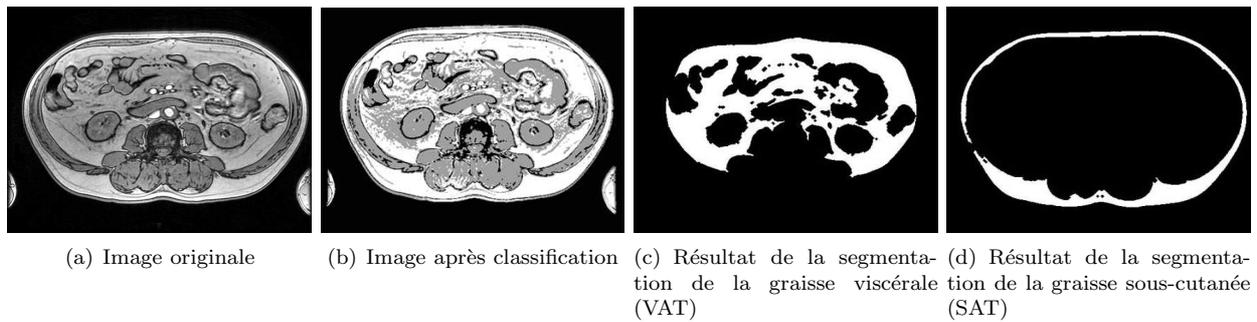


FIG. 2 – Une coupe IRM (a) après l’algorithme de classification (b) (en noir, le fond, en blanc, la graisse et en gris clair, le reste). (c) Le résultat de l’algorithme de connectivité pour la segmentation de la graisse viscérale. (d) Le résultat de l’algorithme de connectivité pour la segmentation de la graisse sous-cutanée.

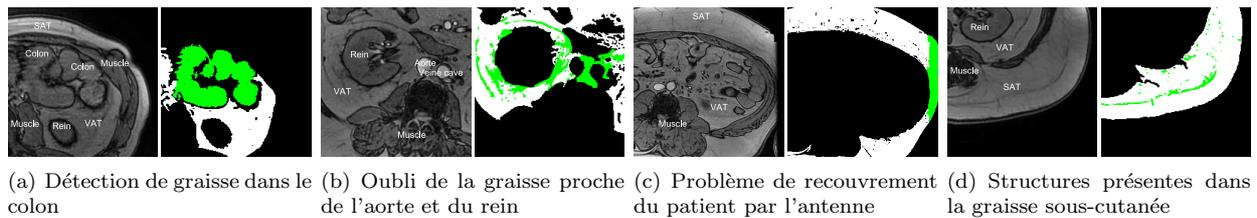


FIG. 3 – Résultats obtenus par l’algorithme : a) présentant une erreur de détection dans le colon (en vert, ce que l’algorithme a détecté en trop). b) présentant un manque de détection de graisse (en vert, les régions que l’algorithme aurait dû détecter). c) présentant un problème de recouvrement du patient par l’antenne (en vert, ce que l’expert ajoute comme étant de la graisse sous-cutanée et que l’algorithme ne comptabilise pas). d) présentant des structures dans la graisse sous-cutanée (en vert, ce qui est pris en compte par l’expert et non par l’algorithme).

gorithme. Pour la graisse viscérale, les problèmes de détection peuvent être de deux natures. Premièrement, le logiciel détecte trop de graisse, en particulier, dans le colon. Cela s’explique par la présence de matière organique ayant un signal IRM proche de celui de la graisse (figure 3-a). Deuxièmement, le logiciel ne détecte pas la région comme de la graisse. Cela s’explique par la présence de vaisseaux ou de structures ayant un signal IRM proche de celui des régions voisines (figure 3-b). Pour la graisse sous-cutanée, nous remarquons des différences moins importantes. Le premier cas de figure est un problème de recouvrement du patient par l’antenne, ce qui se traduit par une image ne comportant pas tout l’abdomen du patient (figure 3-c). Le second cas, qui est moins important car présent sur une grande partie des images, est la présence de vaisseaux dans la graisse sous-cutanée qui n’est pas prise en compte par le logiciel mais comptabilisée par l’expert (figure 3-d).

5 Conclusion et Perspectives

Dans cet article, nous proposons une méthode automatique, fiable et non-subjective de segmentation de la graisse viscérale et sous-cutanée qui est un marqueur prépondérant du syndrome métabolique. Les résultats sont bons, dans la plupart des cas, mais peuvent présenter des imperfections dues à différents facteurs. Une interface graphique a été développée afin que les experts puissent modifier les erreurs de détection de l’algorithme.

Les inhomogénéités d’intensité sont des problèmes récurrents en IRM. Afin de limiter ces problèmes, l’utilisation

d’une séquence d’acquisition de calibration afin de corriger ces problèmes est envisagée.

Références

- [1] V. Positano, A. Gastaldelli, A.M. Sironi, M.F. Santarelli, M. Lombardi, and L. Landini, “An accurate and robust method for unsupervised assessment of abdominal fat by mri,” *Journal of Magnetic Resonance Imaging*, vol. 20, pp. 684–689, 2004.
- [2] J.-A. Koch R. Willers M. Cohnen C. Kapitza L. Heinemann L. W. Poll, H.-J. Wittsack and U. Mödder, “A rapid and reliable semiautomated method for measurement of total abdominal fat volumes using magnetic resonance imaging,” *Magnetic Resonance Imaging*, vol. 21, no. 6, pp. 631–636, 2003.
- [3] J.C. Dunn, “A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters,” *Journal of Cybernetics*, vol. 3, pp. 32–57, 1973.
- [4] J.C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [5] M. Ménard and M. Eboueya, “Extreme physical information and objective functions in fuzzy clustering,” *Fuzzy Sets and Systems*, 2001.
- [6] J. K. Udupa and S. Samarasekera, “Fuzzy connectedness and object definition : Theory, algorithms, and applications in image segmentation,” *Graphical Models and Image Processing*, vol. 58, no. 3, pp. pp. 246–261, May 1996.