



**HAL**  
open science

# Fonction de perte basée sur les contours pour la segmentation d'IRM de vessie par apprentissage profond

Marc-Adrien Hostin, Augustin C. Ogier, Marc-Emmanuel Bellemare

## ► To cite this version:

Marc-Adrien Hostin, Augustin C. Ogier, Marc-Emmanuel Bellemare. Fonction de perte basée sur les contours pour la segmentation d'IRM de vessie par apprentissage profond. 5ème congrès scientifique de la Société Française de Résonance Magnétique en Biologie et Médecine (SFRMBM), Sep 2021, Lyon, France. hal-03366156

**HAL Id: hal-03366156**

**<https://hal.science/hal-03366156>**

Submitted on 5 Oct 2021

**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.

## INTRODUCTION

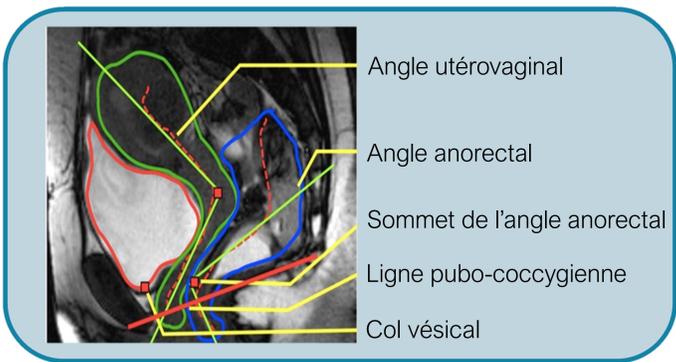


Fig. 1. Quantification de la déformation des organes pelviens

- Contexte**
- **Troubles pelviens**: concernent 50% des femmes de plus de 50 ans
  - **IRM 2D dynamique**: utilisée par les radiologues pour mesurer les positions de points caractéristiques par rapport à la ligne pubo-coccygène montrée en Fig. 1.
  - **Segmentation**: obligatoire pour la caractérisation de la déformation des organes [2]

### Segmentation par apprentissage profond

- **Fully Convolutional Networks (U-Net [1] et ses variantes)**
- **Fonction d'entropie croisée ou Dice**: insuffisant pour détecter les erreurs de contours montrées en Fig. 4 par les flèches jaunes

**Objectif**: Concevoir une fonction de perte dédiée à la détection de contour pour la segmentation d'organes pelviens sur des IRM 2D dynamiques

## MÉTHODOLOGIE

Notre méthode consiste à combiner la fonction de perte standard, le coefficient de Dice (eq. 1) avec une fonction basée sur la distance moyenne entre les surfaces (eq. 2) [3] employant une carte de distance aux contours (Fig. 3). Pour combiner les fonctions de pertes, nous avons proposé un coefficient adaptatif favorisant la compatibilité des gradients de chaque fonction (eq. 4), comparé aux coefficients usuels de la littérature (eq. 3)

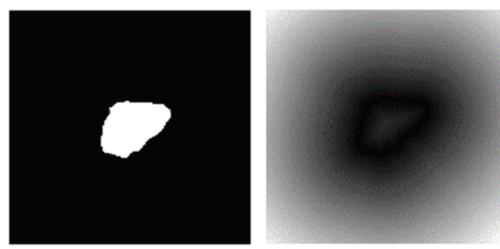
### Fonctions de perte

**Dice Similarity Coefficient**:

$$L_O(X, Y) = 1 - 2 \frac{\sum_{p \in \Omega} X(p)Y(p)}{\sum_{p \in \Omega} X(p)^2 + \sum_{p \in \Omega} Y(p)^2} \quad (1)$$

**Détection de contour**:

$$L_D(X, Y) = \frac{1}{|\Omega|} \sum_{p \in \Omega} (X(p) - Y(p))^2 d_Y(p) \quad (2)$$



Vérité terrain Carte de distance  
Fig. 3 Carte de distance  $d_Y$

$\Omega$  = grille de pixels,  $X$  = prédiction  
 $d_Y$  = carte de distance,  $Y$  = vérité terrain

### Combinaison des fonctions de pertes

**$\alpha$  empirique**:  $\alpha_0 = 0, \alpha_k = 0.01 * k, k = \text{nombre d'époch}$

$$L_{OD}(X, Y) = (1 - \alpha)L_O(X, Y) + \alpha L_D(X, Y) \quad (3)$$

**$\alpha$  adaptatif**:  $\alpha = \frac{\mu_o}{\mu_d}, \mu_o = \text{moyenne du gradient de } L_O \text{ sur 20 epochs}$   
 $\mu_D = \text{moyenne du gradient de } L_D \text{ sur 20 epochs}$

$$L_P(X, Y) = L_O(X, Y) + \alpha L_D(X, Y) \quad (4)$$

## RÉSULTATS

### Évaluation

- 3 réseaux U-Net à 4 couches entraînés avec: Dice  $L_O$ , une combinaison de fonctions avec  $\alpha$  empirique  $L_{OD}$ , notre méthode  $L_P$
- Distributions de DSC, HD et ASD en Fig. 4
- Améliorations de la détection de contour en Fig. 5

### Acquisition

- 16 patients / 10 témoins
- $T_2w$  à 1,5 Tesla
- $256 \times 256$  pixels =  $300 \times 300$  mm
- 12 images/séquence
- 312 images total

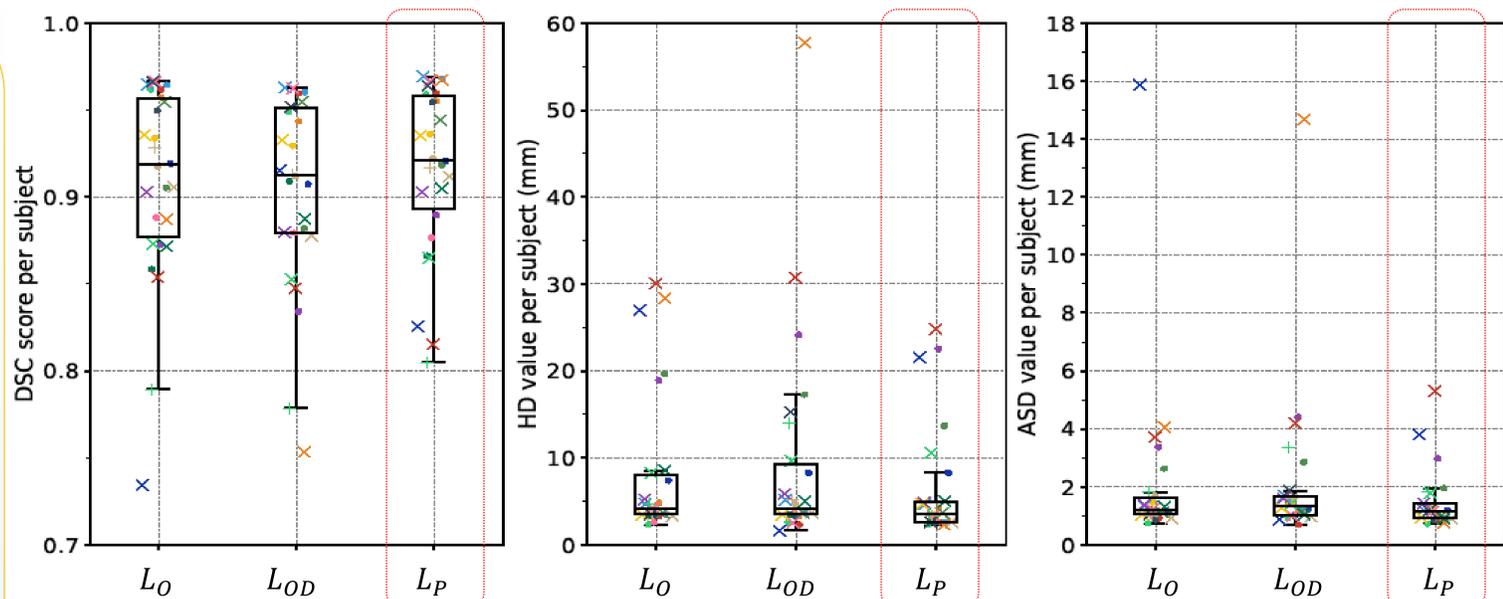


Fig. 4. Distribution des scores moyens par sujet (notre méthode encadrée en rouge)

DSC = Dice Similarity Coefficient, HD = Hausdorff Distance, ASD = Average Surface Distance

## DISCUSSION

- La compatibilité de fonctions de pertes pour l'apprentissage reste à explorer
- De nouvelles fonctions de perte doivent être développées
- L'évaluation sur d'autres bases de données/réseaux sont à réaliser

## CONCLUSION

- **Avantages de notre méthode**: La variabilité des résultats de HD et ASD a été réduite, montrant une meilleure précision des contours
- **La combinaison des fonctions de pertes** a été réalisée grâce au coefficient adaptatif proposé utilisant les gradients de chaque fonction

## RÉFÉRENCES

- [1] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," in International Conference on Medical image computing and computer-assisted intervention. Springer, 2015, pp. 234–241.
- [2] M. Rahim, M.-E. Bellemare, R. Bulot et al., "A diffeomorphic mapping based characterization of temporal sequences: application to the pelvic organ dynamics assessment," Journal of mathematical imaging and vision, vol. 47, no. 1-2, pp. 151–164, 2013.
- [3] D. Karimi and S. E. Salcudean, "Reducing the hausdorff distance in medical image segmentation with convolutional neural networks," IEEE Transactions on medical imaging, vol. 39, no. 2, pp. 499–513, 2019.

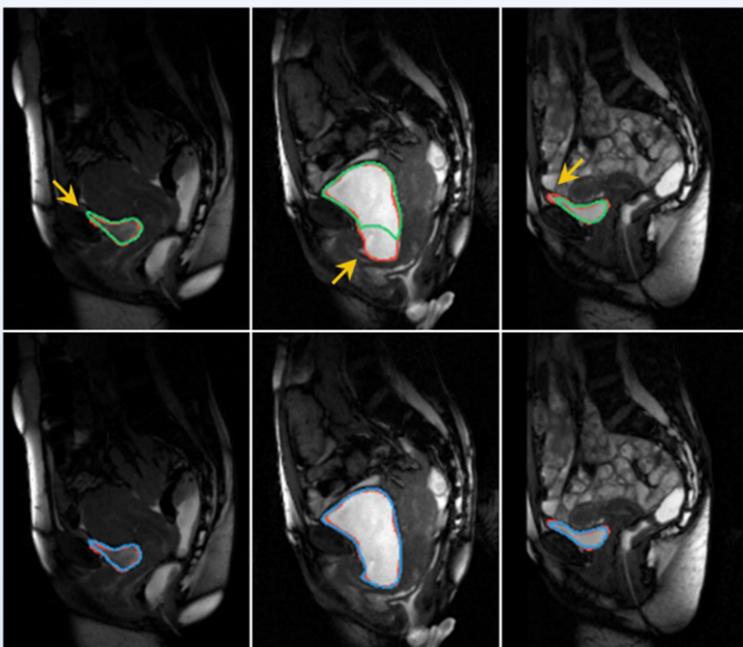


Fig. 5. Exemples de 3 segmentations de vessie: vérité terrain (rouge), prédiction d'un réseau entraîné avec  $L_O$  (vert) et notre méthode (bleu)