

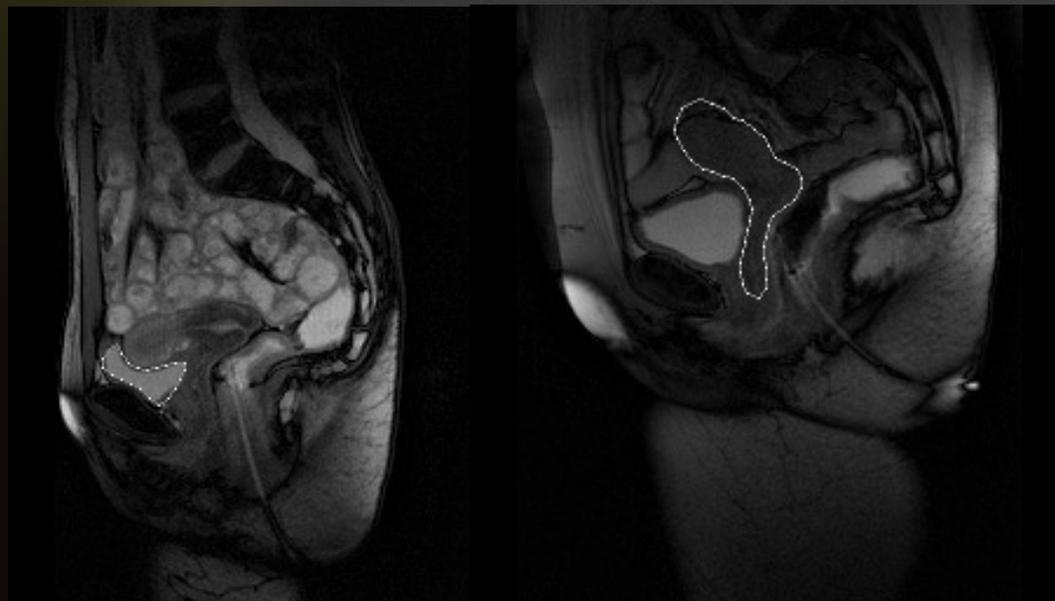
# Le Deep Learning pour la segmentation d'IRM

MARC-EMMANUEL BELLEMARE

LIS UMR 7020 - CNRS AMU

Colloque IA & Santé

Institut Laennec Novembre 2021



# Plan

- L'apprentissage profond et les Images dans l'équipe I&M du LIS
  - IA et Computer Vision
  - IA & Santé
- La segmentation d'IRM
  - Projet pelvis
  - Projet muscle
- Conclusion

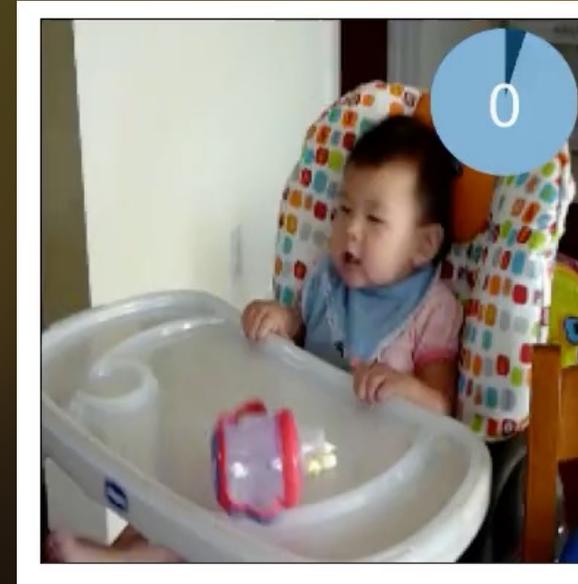
# IA & traitement d'images au LIS



- L'Équipe **Images & Modèles** du Laboratoire Informatique et Systèmes
  - 11 Enseignant-Chercheurs, 9 étudiants en thèse
  - Sur 2 sites : St Jérôme & Luminy
  - Thématiques:
    - Vision artificielle, Photogrammétrie, Imagerie médicale

# IA & Computer Vision

- Le deep-learning pour l'étude du comportement humain par vidéo
  - Le projet **ANR ACTIVIS** (Séverine Dubuisson) a pour objectif d'étudier le comportement autistique avec des séquences vidéo.
    - Détecter les stéréotypies (gestes répétitifs) dans les séquences vidéo.
      - Étude des trajectoires pour des points spécifiques (main, dos, jambes, cou)
    - Trouver un **mode de représentation** de ces données temporelles
    - **Créer une Base de Données** annotée par des médecins de séquences synthétiques
  - Étude du comportement du consommateur, en situation dans des magasins, en fonction de stimuli (publicités, odeurs, ...).
    - Suivi multi-personne multi-caméra avec des champs qui se recouvrent
      - problème de suivi, de détection, de ré-identification...
    - Ajout d'informations « sociales » dans les modèles d'apprentissage



# IA & Santé par l'image

- Projet ANR Diamelex** (Djamal Merad, Collaboration APHM/CRCM - Jean-Jacques Grob et Jilliana Monnier *et al.*, laboratoire CEDRIC - Nicolas Thome, Société Anapix - Bernard Fertil)
- Les cancers cutanés sont les plus fréquents parmi tous les cancers dans la population caucasienne. Et le mélanome est le cancer cutané le plus agressif.

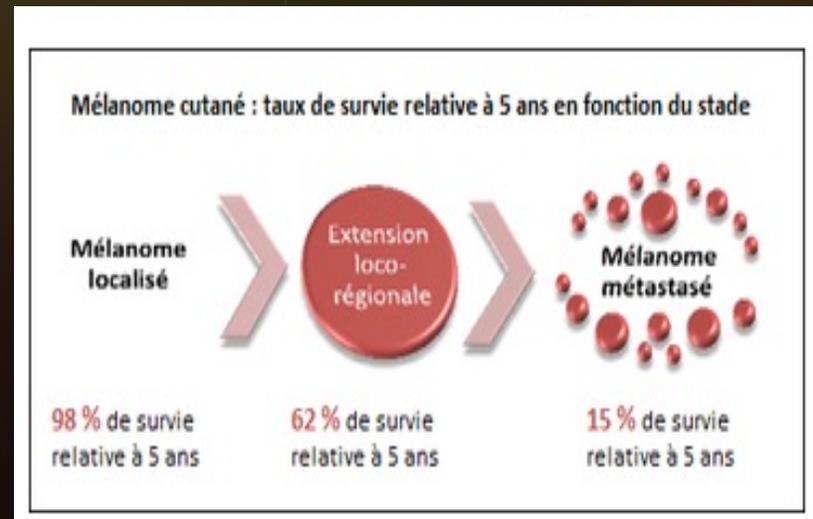


Mélanome ~ 10%

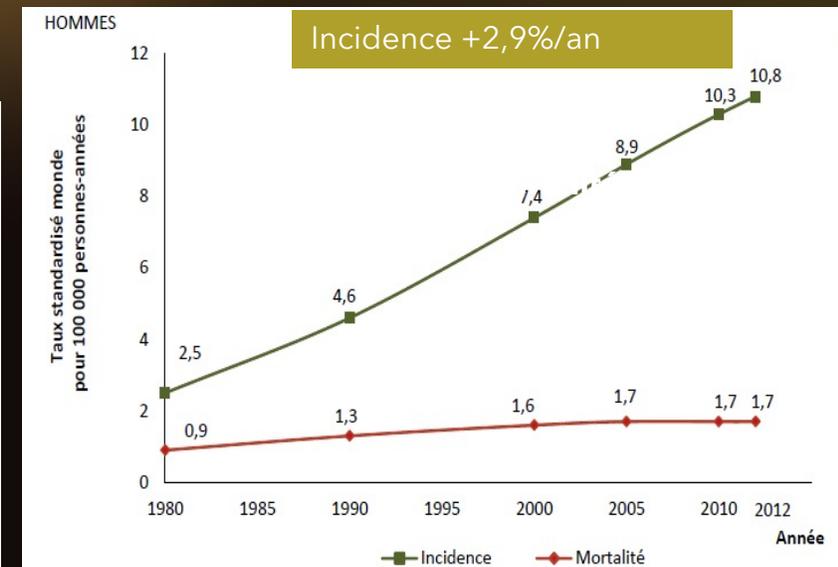
Carcinome épidermoïde ~20%



Carcinome baso-cellulaire ~70%



Incidence du mélanome et de la mortalité en France entre 1980-2012



Source : Partenariat Francim/HCL/Santé publique France/INCa [Binder-Foucard F, 2013]. Traitement : INCa

# IA & Santé par l'image

- Cabine scanner cutané 3D corps entier, système VECTRA 3D (Canfield)

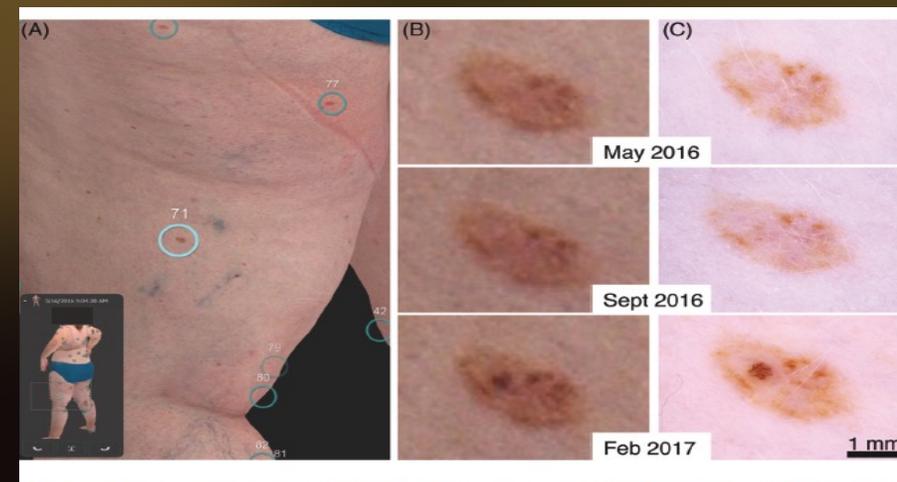
Acquisition de tous les nævus d'un individu pouvant s'effectuer avec une résolution suffisante



Système VECTRA 3D



Représentation 3D Canfield

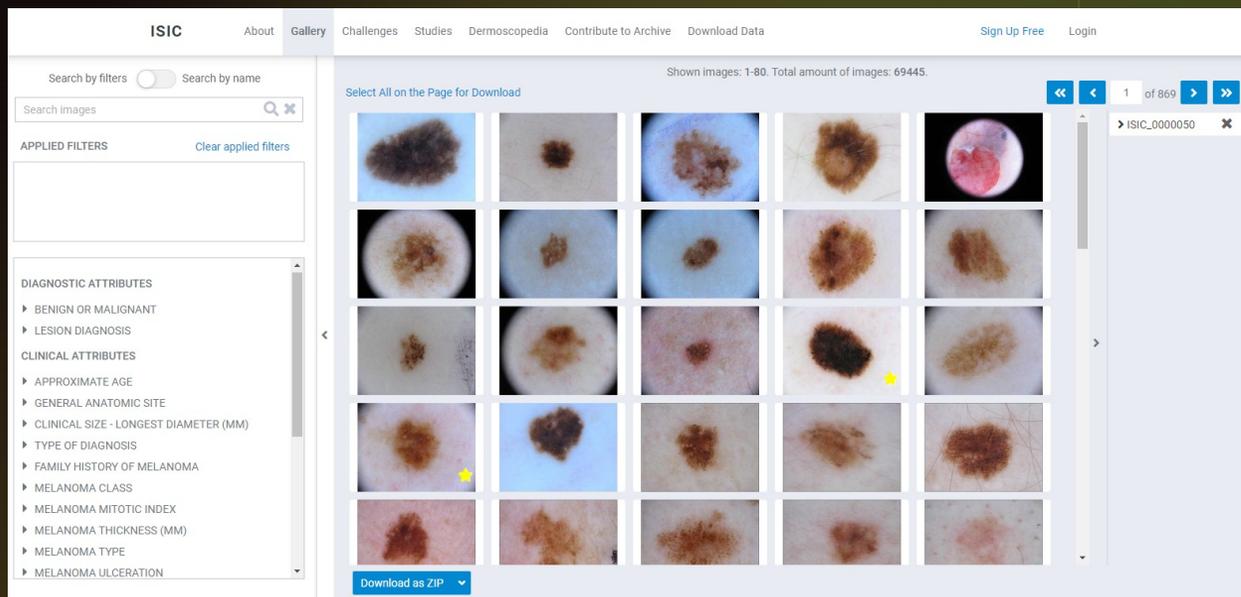


Détection d'un mélanome à partir de la photographie 3D corps entier

# IA & Santé par l'image

BDD existante pour les données des photographies et données cliniques

Nævogramme



<https://www.isic-archive.com/#!/topWithHeader/onlyHeaderTop/gallery?filter=%5B%5D>

Spécifique du patient

# IA & Santé par l'image

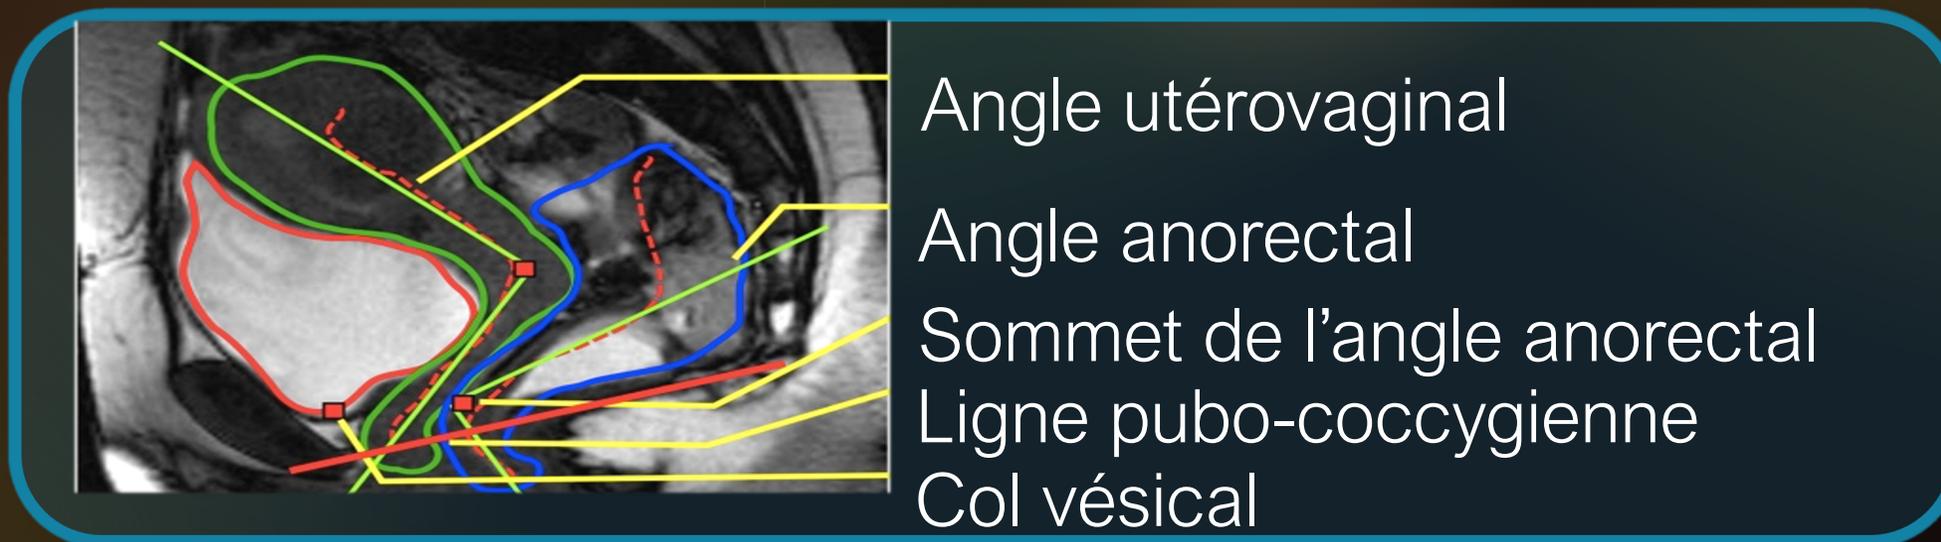
- **Projet Diamelex - self detect** (Cf. Poster)
  - Élaborer un système d'aide à la détection automatique de lésions suspectes de mélanomes cutanés
  - Étapes
    - **Collecter** les photographies 3D corps entier obtenues
    - **et annoter** les diagnostics des lésions cutanées selon l' « analyse lésion par lésion » et l'« analyse comparative intra-individuelle »
    - Développer des algorithmes d'IA fondés sur l'« analyse lésion par lésion» et l'« analyse comparative intra-individuelle »

# La segmentation d'IRM

- **Projet Dynamique pelvienne** (Collaboration APHM - Nicolas Pirró *et al.*)

Pour la caractérisation du comportement des organes pelviens, nous nous intéressons à la déformation des organes au cours du temps

- Suivi d'indices caractéristiques => les contours sont importants

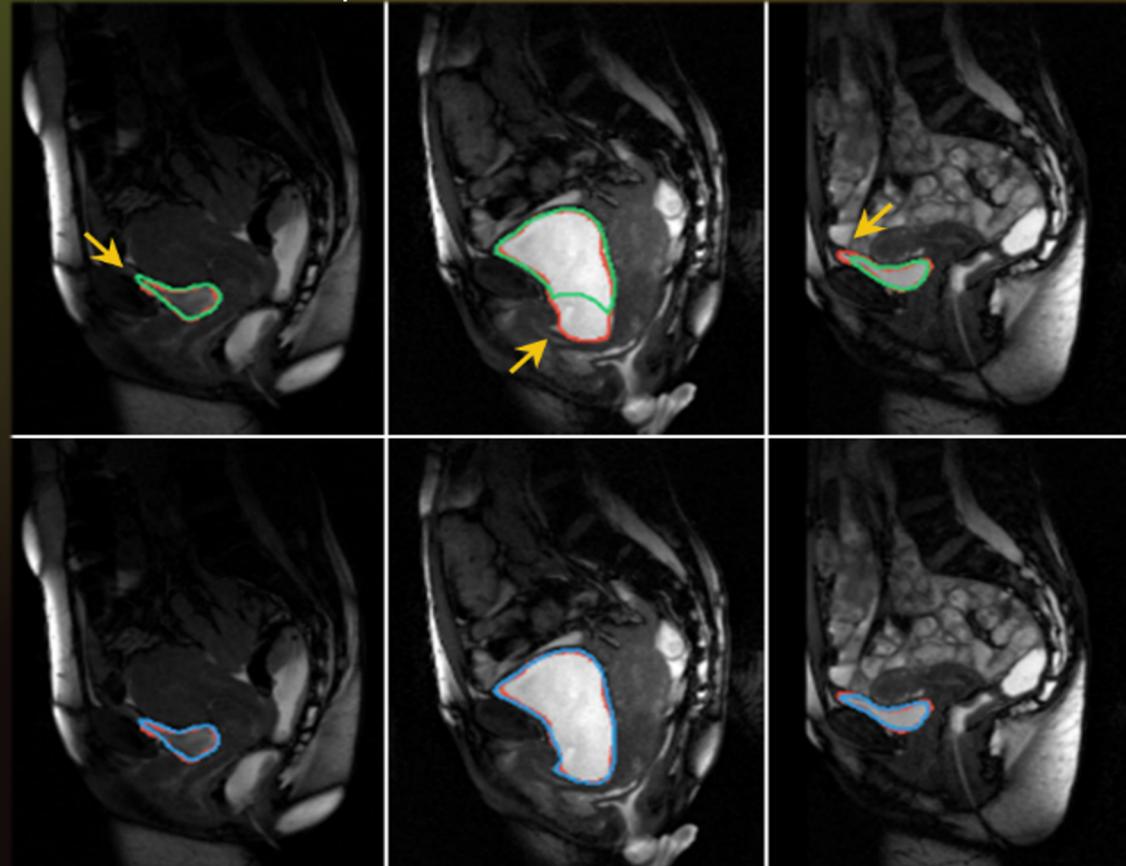


# La segmentation d'IRM

## • Projet Dynamique pelvienne

- U-Net<sup>1</sup>
- Le résultat de segmentation est estimé essentiellement par Coefficient de Dice
  - Lié au % de recouvrement de la région segmentée avec le masque fourni par l'expert.
- Introduction d'une fonction de perte tenant compte de la distance au contour.
  - => gain

--- Contour expert      — inférence U-Net



Dice loss  
 $L_0$

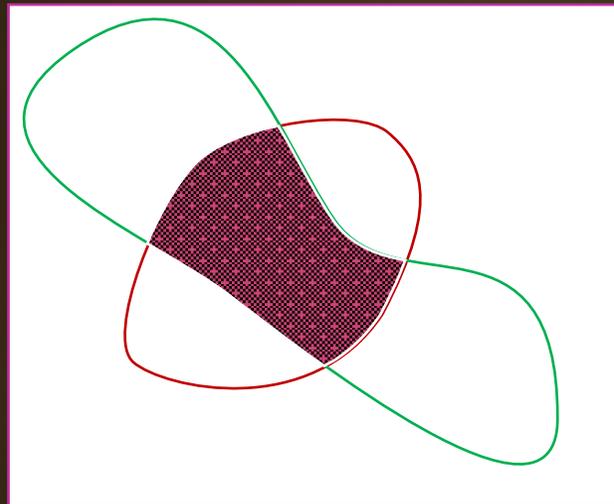
Notre méthode  
 $L_p$

Fig. Exemples de 3 segmentations de vessie

# La segmentation d'IRM

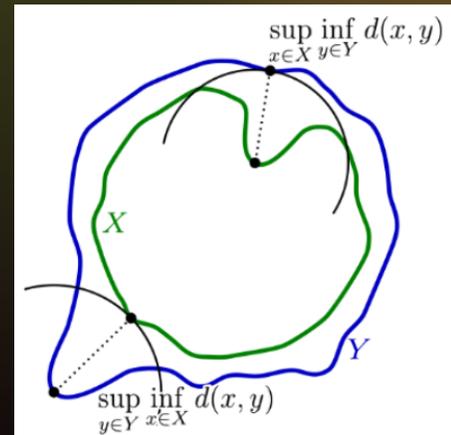
- Indicateurs

Score de Dice (DSC)



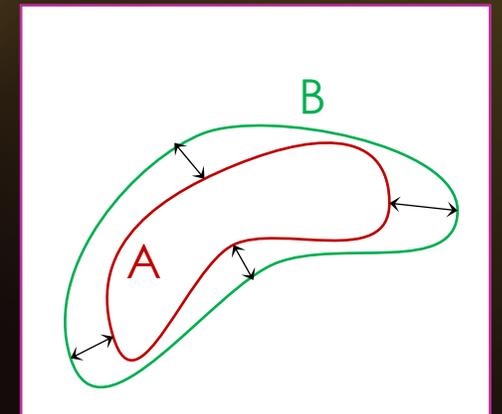
$$DSC = \frac{(A \cap B) * 2}{|A| + |B|}$$

Distance de Hausdorff (HD)



$$HD = \max\{h(A, B), h(B, A)\}$$

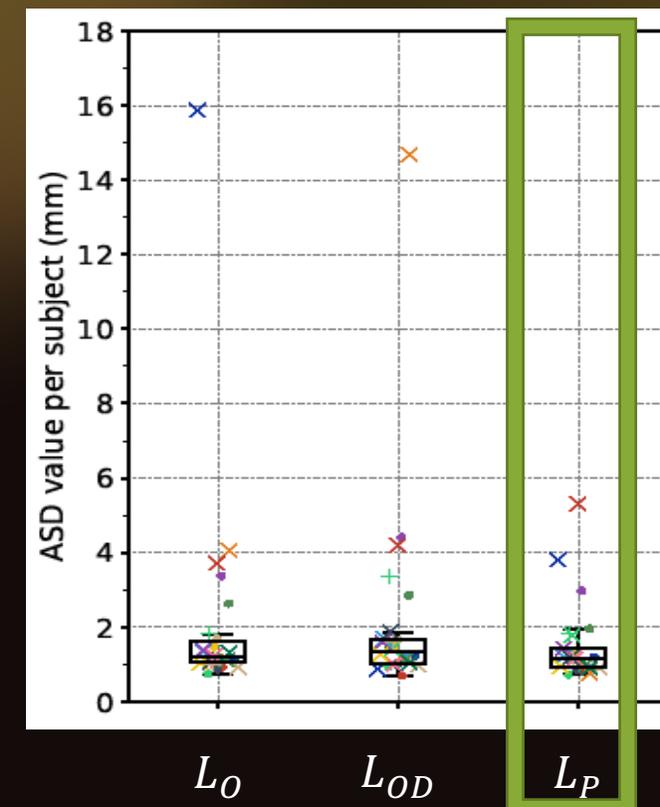
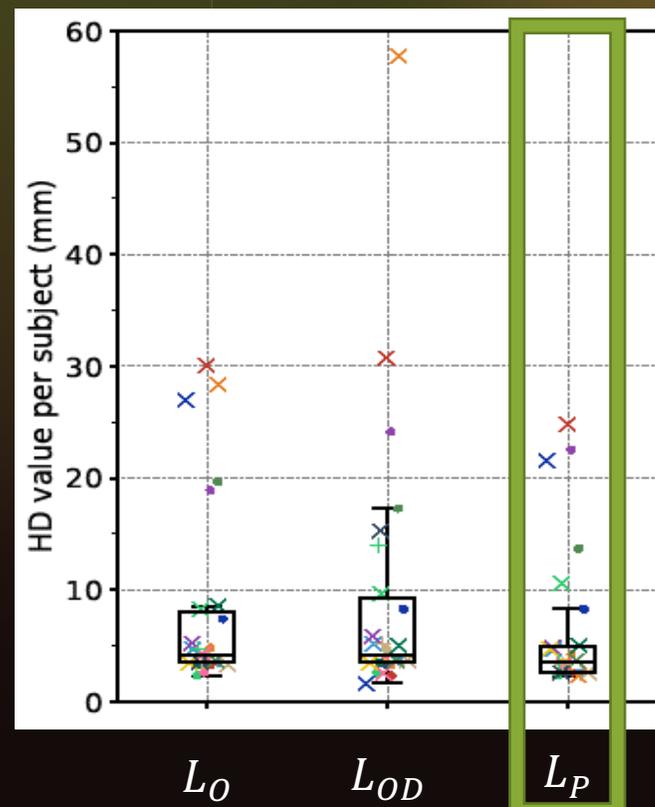
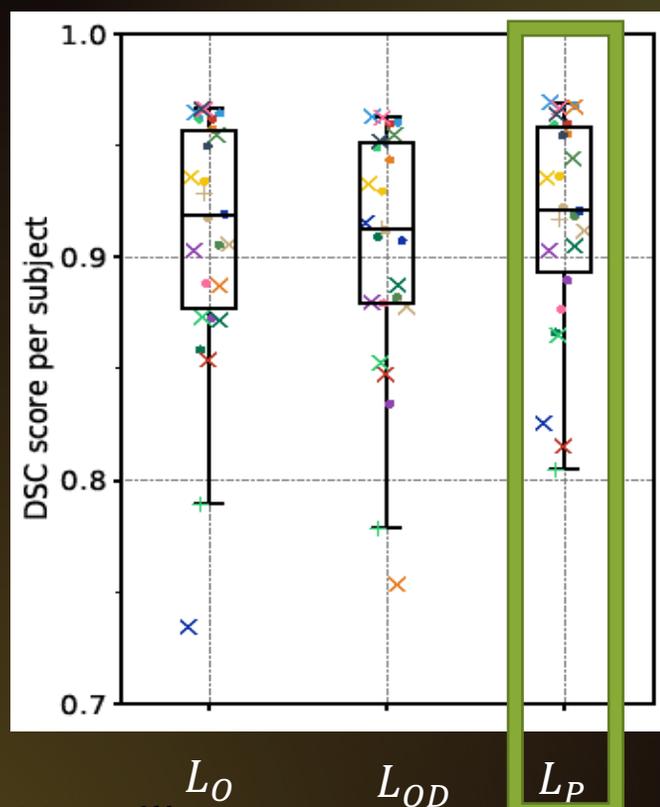
Distance moyenne (ASD)



$$ASD = \frac{1}{|A| + |B|} \sum_X d(x, Y) + \sum_Y d(y, X)$$

# La segmentation d'IRM

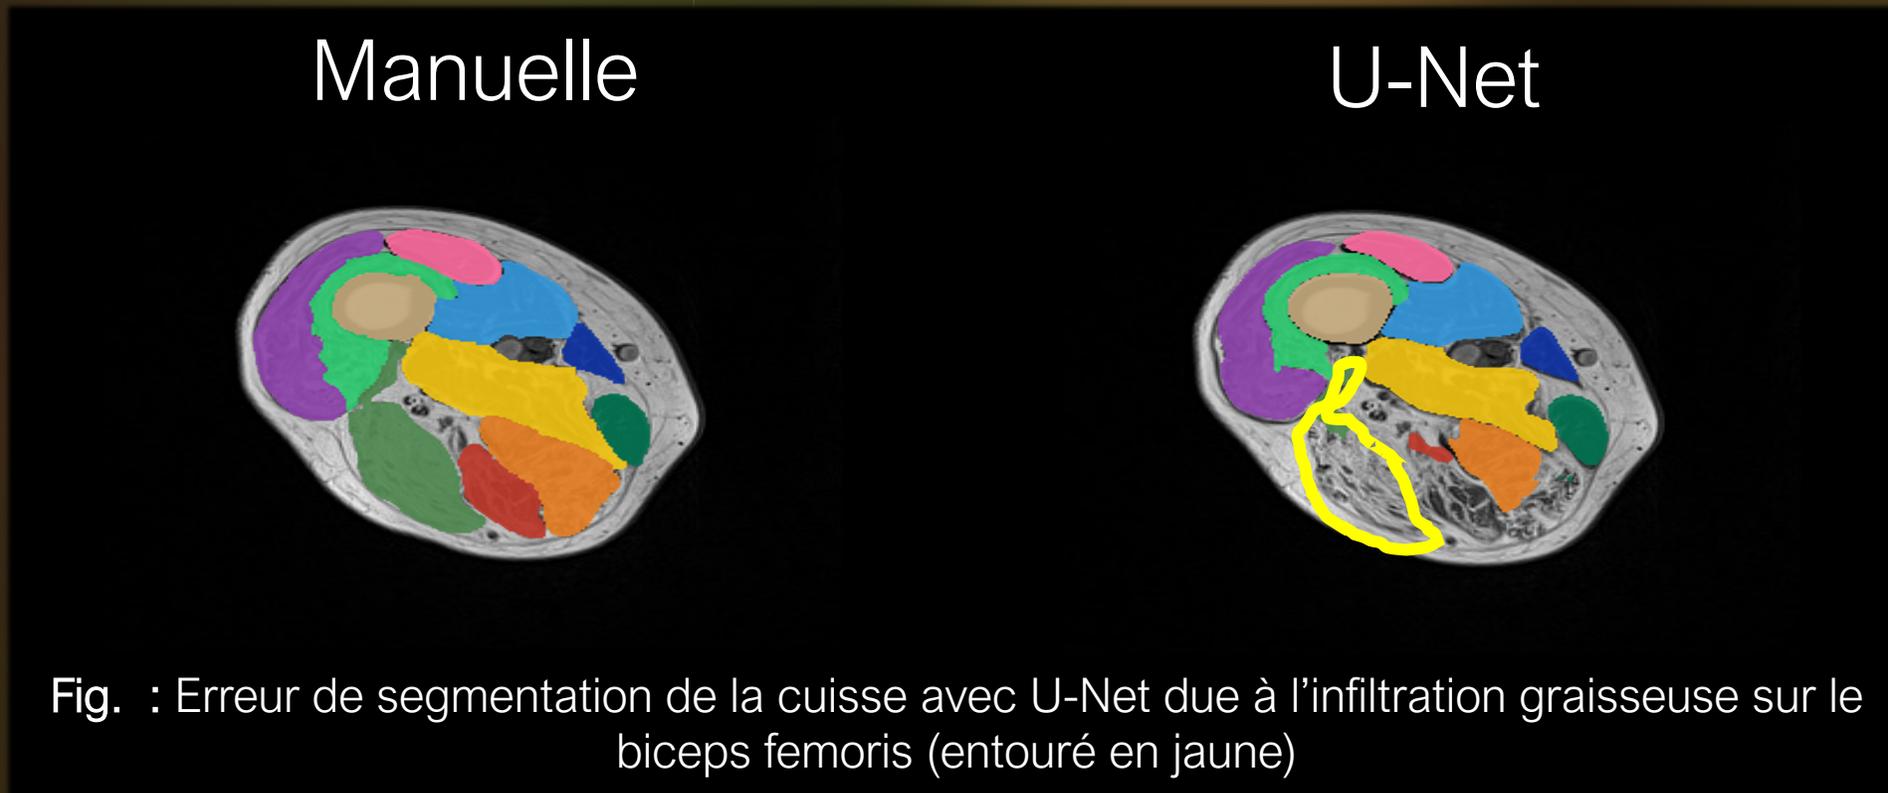
- **Projet Dynamique pelvienne** - Résultats de segmentation  
 Test de 3 fonctions de perte
  - $L_0$  : DSC classique,  $L_{OD}$  : combinaison naïve,  $L_p$  : combinaison adaptative (Cf. poster)



• Le gain est faible pour le DSC mais significatif sur les HD et ASD

# La segmentation d'IRM

- **Projet Muscle** (Collaboration CRMBM - David Bendahan *et al.*)
  - Dans le cadre de l'étude des pathologies neuro-musculaires nous cherchons à segmenter les loges des muscles individuels.
  - Problème difficile dans le cas des pathologies avec infiltrat graisseux des muscles.



# La segmentation d'IRM

## • Projet Muscle

- Nous testons des architectures différentes (dont U-Net3D non montré sur la figure)

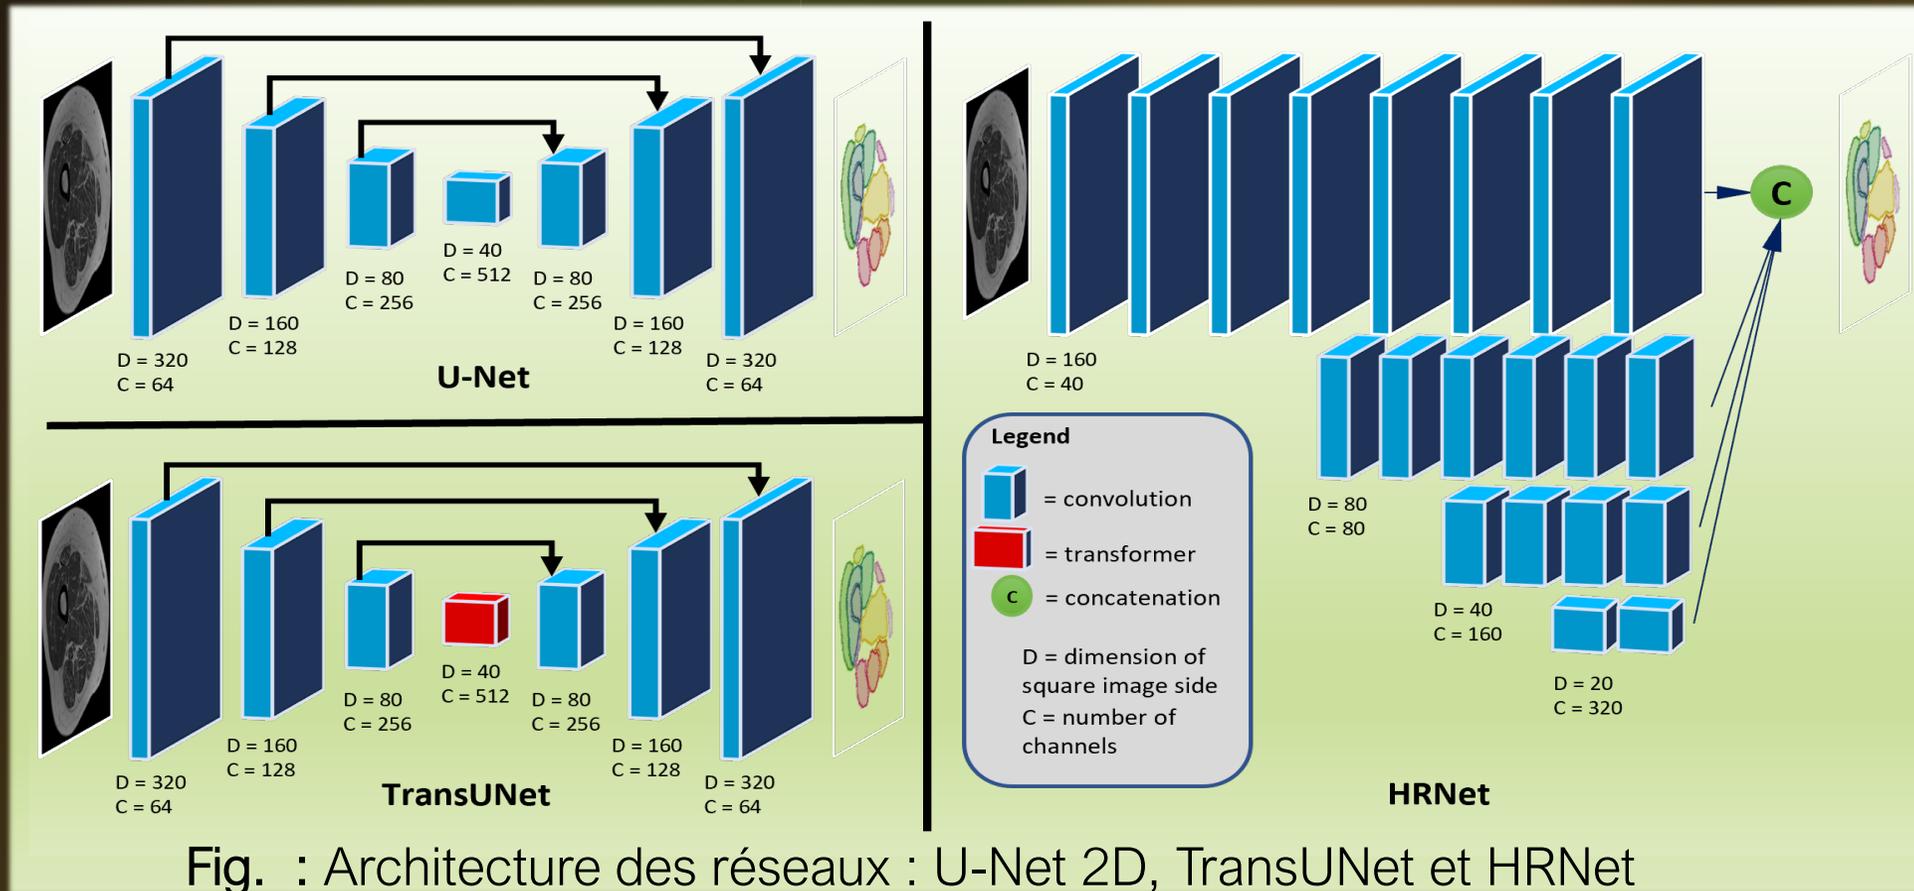


Fig. : Architecture des réseaux : U-Net 2D, TransUNet et HRNet

# La segmentation d'IRM

- **Projet Muscle**
  - Résultats de segmentation des différents réseaux (Cf. Poster)

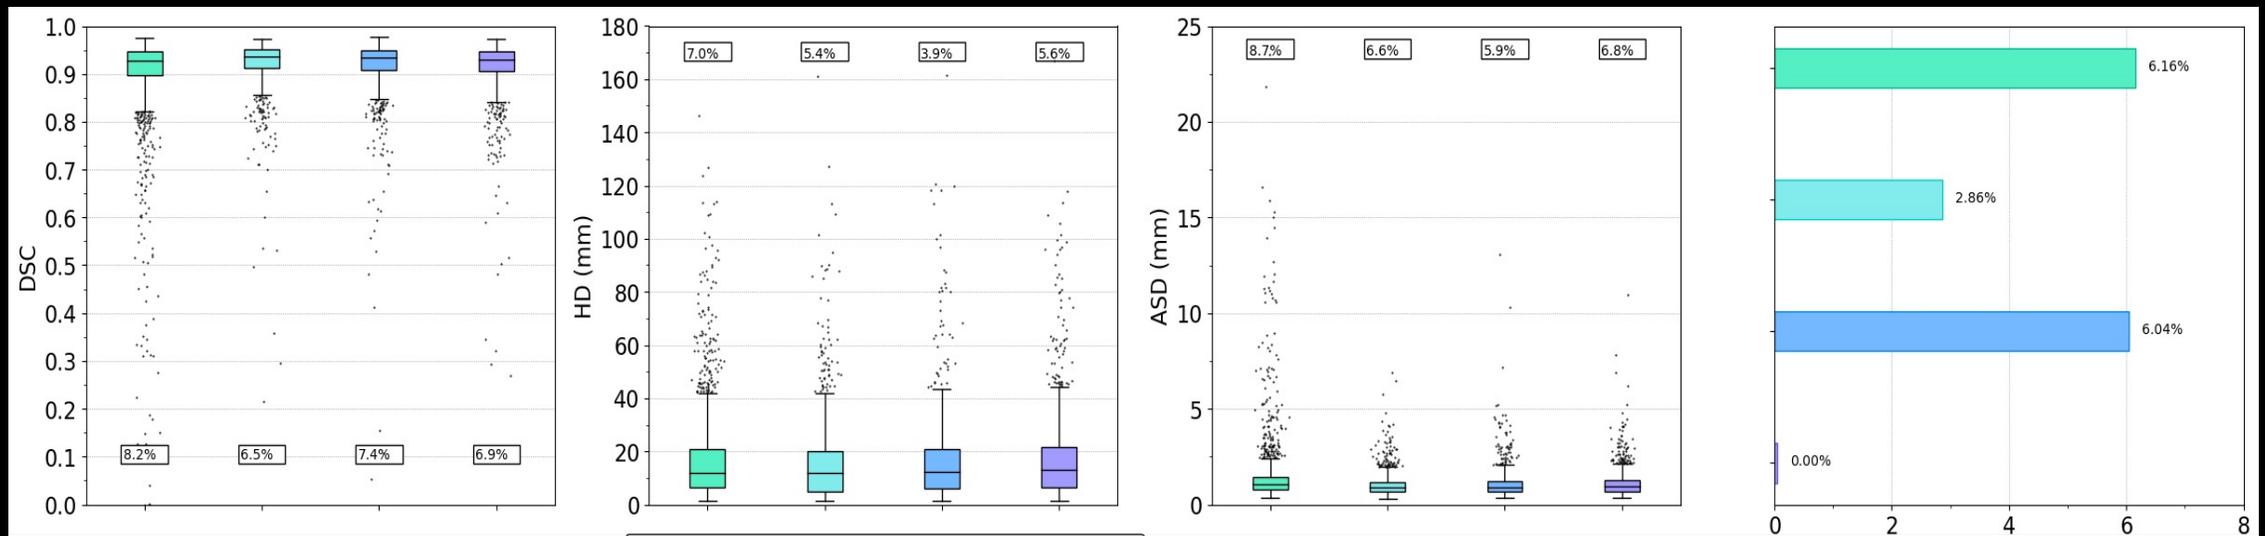


Fig. : Evaluation géométrique de U-Net 2D, U-Net 3D, TransUNet et HRNet avec les scores DSC, HD et ASD où chaque point représente le score d'un muscle individuel. Le graphique de droite indique le pourcentage de muscles non segmentés (0% pour HRNet).

# Deep-Learning et segmentation

- Comment identifier le « meilleur » réseau ?
  - Une étude de la performance de différents réseaux (U-Net et HR-Net) en prenant le U-Net de base comme référence (100%) montre :
    - Sur une base de données disponible MyosegmenTUM<sup>2</sup> (Université de Munich)
      - ✓ Avec une variation du nombre de paramètres de 103% à 1100%;
      - ✓ qui produit un apprentissage dont le temps varie de 40% à 118%;
      - ✓ le résultat moyen d'apprentissage DSC a varié de 93,6% à 95,1%;
      - ✓ Pour un résultat moyen de segmentation de 87% à 89% en DSC.
  - L'effort ne se traduit pas nécessairement en termes de résultats

<sup>2</sup><http://bigd.big.ac.cn/databasecommons/database/id/6674>

# Conclusion

- La segmentation par apprentissage profond est une approche qui fonctionne bien et qui reste facile !
  - Quelques dizaines lignes de code et des GPU accessibles à distance
    - Cloud, Datacenter AMU & Mésocentre
- Nous sommes passés
  - de la construction explicite de modèles des données par **l'étude de leurs caractéristiques**
  - à la sélection automatique et implicite (supervisée en général) des caractéristiques à partir des données.

# Conclusion

- Pour l'apprentissage supervisé il est nécessaire d'avoir suffisamment d'annotations mais aussi des annotations de **bonne qualité** (influence de l'expert, accord intra expert ?)
- Malheureusement :
  - Les données pathologiques sont rares en général, et très variables (sujet et centre d'imagerie)
  - Le travail d'annotation est fastidieux pour les experts

*Tout le monde peut segmenter à condition de disposer de suffisamment de données représentatives et de qualité*

# Perspectives

- On peut améliorer les résultats mais le coût pour gagner quelques pourcents (qui peuvent très bien être inclus dans la confusion intra-expert) est-il raisonnable ?
- Des améliorations possibles
  - Introduire des modèles
    - pour améliorer le processus d'apprentissage (fonctionnement du réseau)
    - ou pour augmenter la quantité des données (en créant)
  - Développer l'apprentissage non supervisé
  - Tester de nouvelles architectures voire paradigmes
    - SpikeNN ?
      - À événements discrets
      - Intégration spatio-temporelle de trains d'impulsions
    - Des API ? spykeTorch. <https://cnrl.ut.ac.ir/SpykeTorch/doc/SpykeTorch.html>
    - BindsNet <https://binds.cs.umass.edu/bindsnet.html> (Université du Massachusetts)

*Merci de votre attention*