



HAL
open science

Segmentation d'IRM multimodales par réseaux de neurones : Stratégies de transfert d'apprentissage pour des ensembles de données de taille limitée

Liliane Daniela Talba Malla Tchamedeu, Benjamin Lambert, Thomas Coudert, Elizabeth Moyal Cohen-Jonathan, Soléakhéna Ken, Géraldine Le Duc, Michel Dojat, Fabien Boux, Benjamin Lemasson

► To cite this version:

Liliane Daniela Talba Malla Tchamedeu, Benjamin Lambert, Thomas Coudert, Elizabeth Moyal Cohen-Jonathan, Soléakhéna Ken, et al.. Segmentation d'IRM multimodales par réseaux de neurones : Stratégies de transfert d'apprentissage pour des ensembles de données de taille limitée. IABM 2024 - Colloque français d'intelligence artificielle en imagerie biomédicale, Mar 2024, Grenoble, France. pp.1-1, 2024. hal-04541089

HAL Id: hal-04541089

<https://hal.science/hal-04541089v1>

Submitted on 10 Apr 2024

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.

Public Domain

Segmentation d'IRM multimodales par réseaux de neurones : Stratégies de transfert d'apprentissage pour des ensembles de données de taille limitée

Liliane Daniela Talba Malla Tchamedeu¹, Benjamin Lambert^{2,3}, Thomas Coudert², Elizabeth Moyal Cohen-Jonathan^{5,6}, Soleakhena Ken^{5,6}, Géraldine Le Duc¹, Michel Dojat^{2,4}, Fabien Boux¹, Benjamin Lemasson²



¹NH TherAguiX, 19 Chemin des Prés, 38240 Meylan, France

²Univ. Grenoble Alpes, Inserm, U1216, Grenoble Institut Neurosciences, 38000, France

³Pixyl, Research and Development Laboratory, 38000 Grenoble, France

⁴Univ. Grenoble Alpes, Inria, CNRS, LJK, Grenoble, France

⁵Oncopole Claudius Regaud - Institut Universitaire du Cancer de Toulouse, 31059 Toulouse, France

⁶CRCT INSERM UMR1037 RADOPT Team 11, Toulouse, France



Introduction : Qu'est-ce que le transfert d'apprentissage ?

Contexte :

➤ **L'apprentissage profond (Deep Learning)** est la méthode la plus utilisée pour automatiser la segmentation d'images médicales. Cependant, cette tâche est complexe et est souvent limitée par la nécessité d'un grand nombre de données annotées et la phase longue d'entraînement requises par les modèles d'apprentissage profond.[1]

➤ **Le transfert d'apprentissage (Transfert Learning, TL)** se présente comme une solution prometteuse pour contourner ces limitations en capitalisant sur les connaissances préalablement acquises par des modèles pré-entraînés sur de larges collections de données préexistantes.[2]

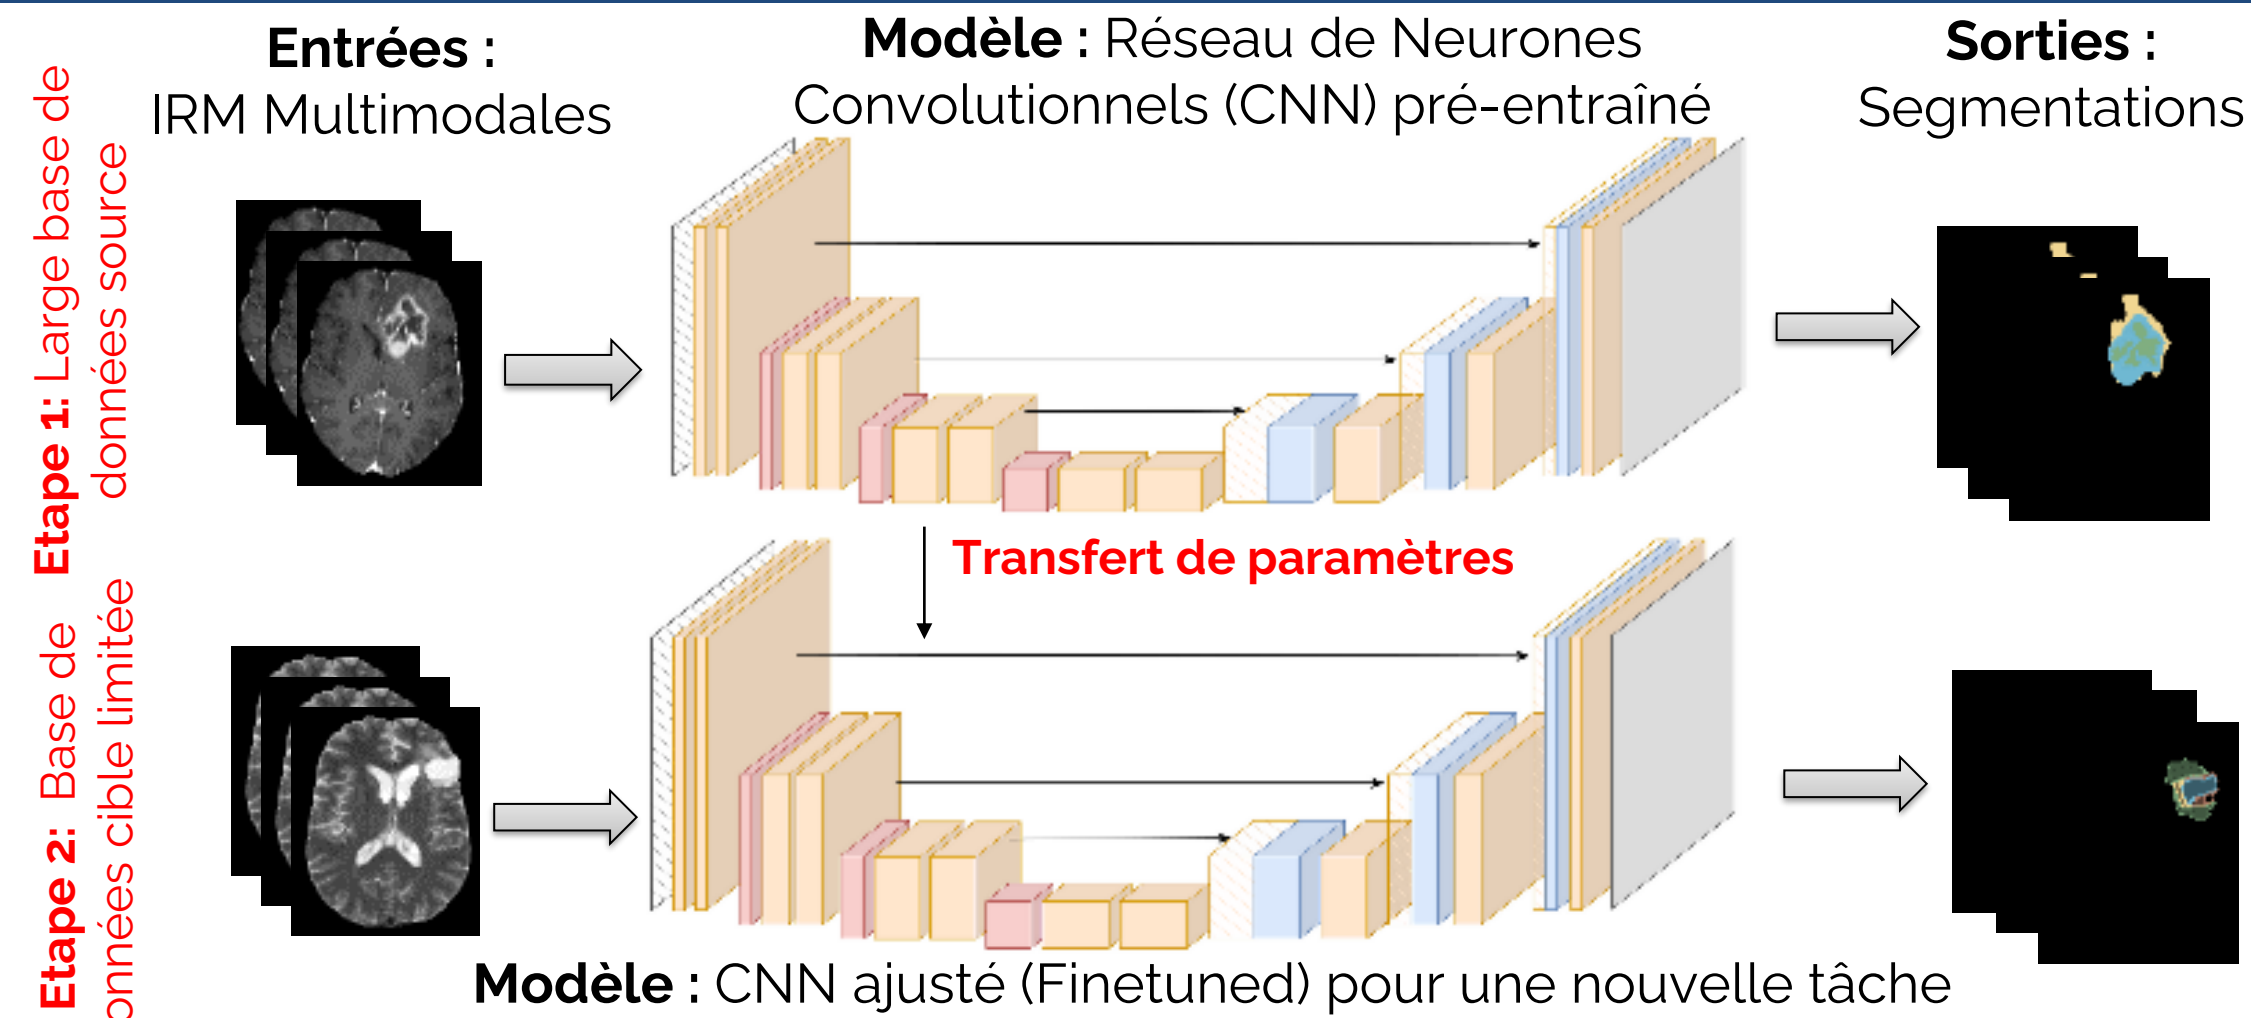


Figure 1: Différentes étapes du Transfert d'apprentissage

Objectifs :

- Evaluer l'efficacité du transfert d'apprentissage pour la segmentation des bases de données de taille limitée.
- Evaluer l'impact de différentes stratégies de transfert d'apprentissage sur les performances des modèles.
- Evaluer l'impact de la taille des bases de données cibles sur les bénéfices du transfert d'apprentissage.
- Examiner la généralisation du modèle source sur différentes bases de données cibles plus ou moins similaires (différentes pathologies).
- Examiner l'impact de l'architecture du modèle sur l'efficacité du transfert d'apprentissage.

Matériels et Méthodes

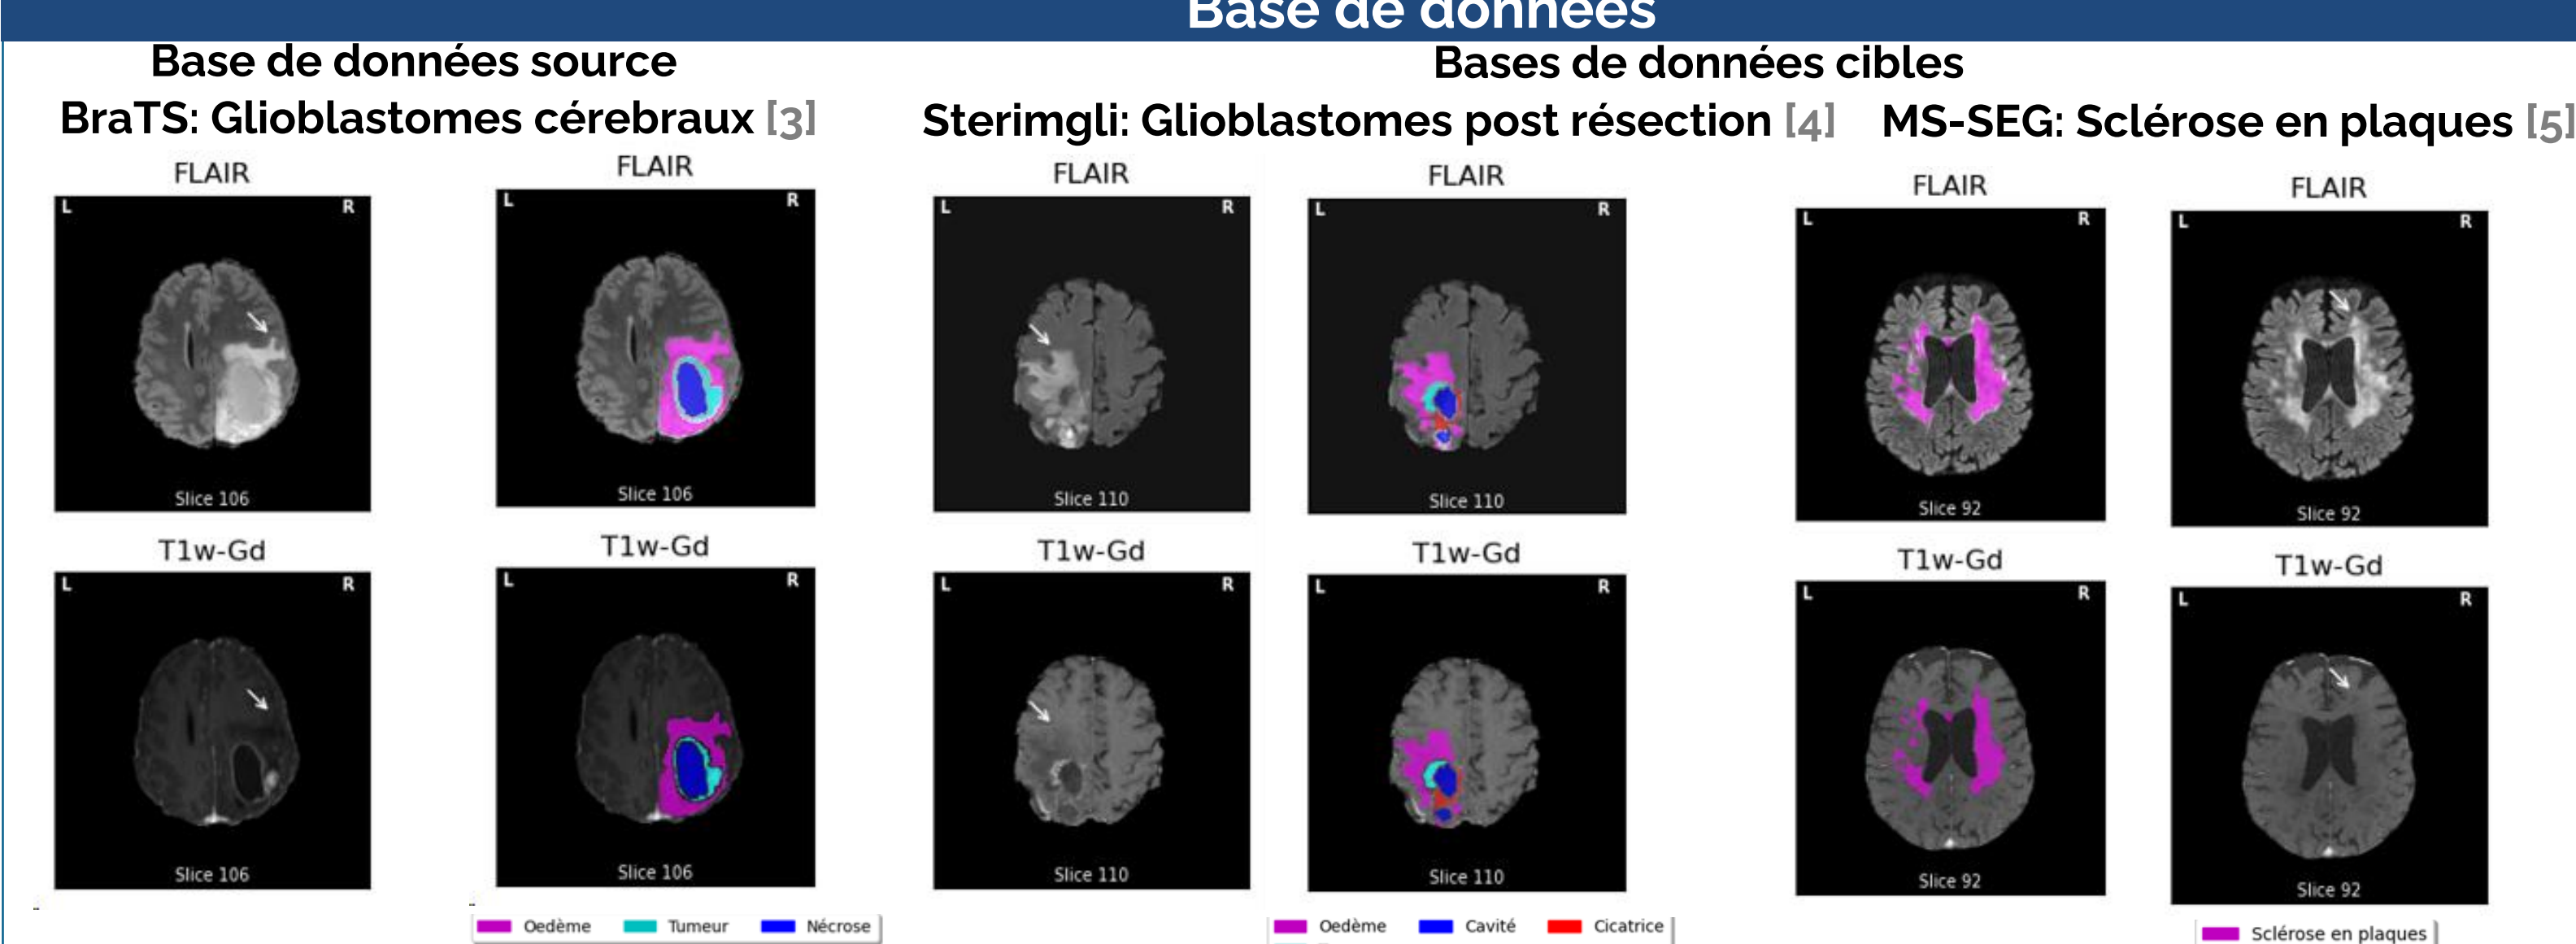


Figure 2: Glioblastomes de la base de données BraTS. Figure 3: Glioblastomes de la base de données Steringli. Figure 4: Sclérose en plaques de la base de données MS-SEG.

- 1251 patients
- Séquences : Flair, T1w, T1w-Gd, T2w
- Labels : Tumeur, Nécrose, Oedème
- 28 patients
- Séquences : Flair, T1w, T1w-Gd, T2w
- Labels : Tumeur, Cavitité, Oedème, Cicatrice
- 53 patients
- Séquences : Flair, T1w, T1w-Gd, T2w
- Labels : Sclérose en plaques

Le même prétraitement a été appliqué aux données sources et cibles en utilisant un outil open source: la BraTS toolkit [6]:

- Rééchantillonnage des images en voxels isotropes : 1mm³.
- Co-registation de tous les cerveaux dans l'espace du template BraTS avec l'algorithme ANTs [9].
- Extraction des cerveaux avec l'algorithme HD-BET.

U-Net [7]

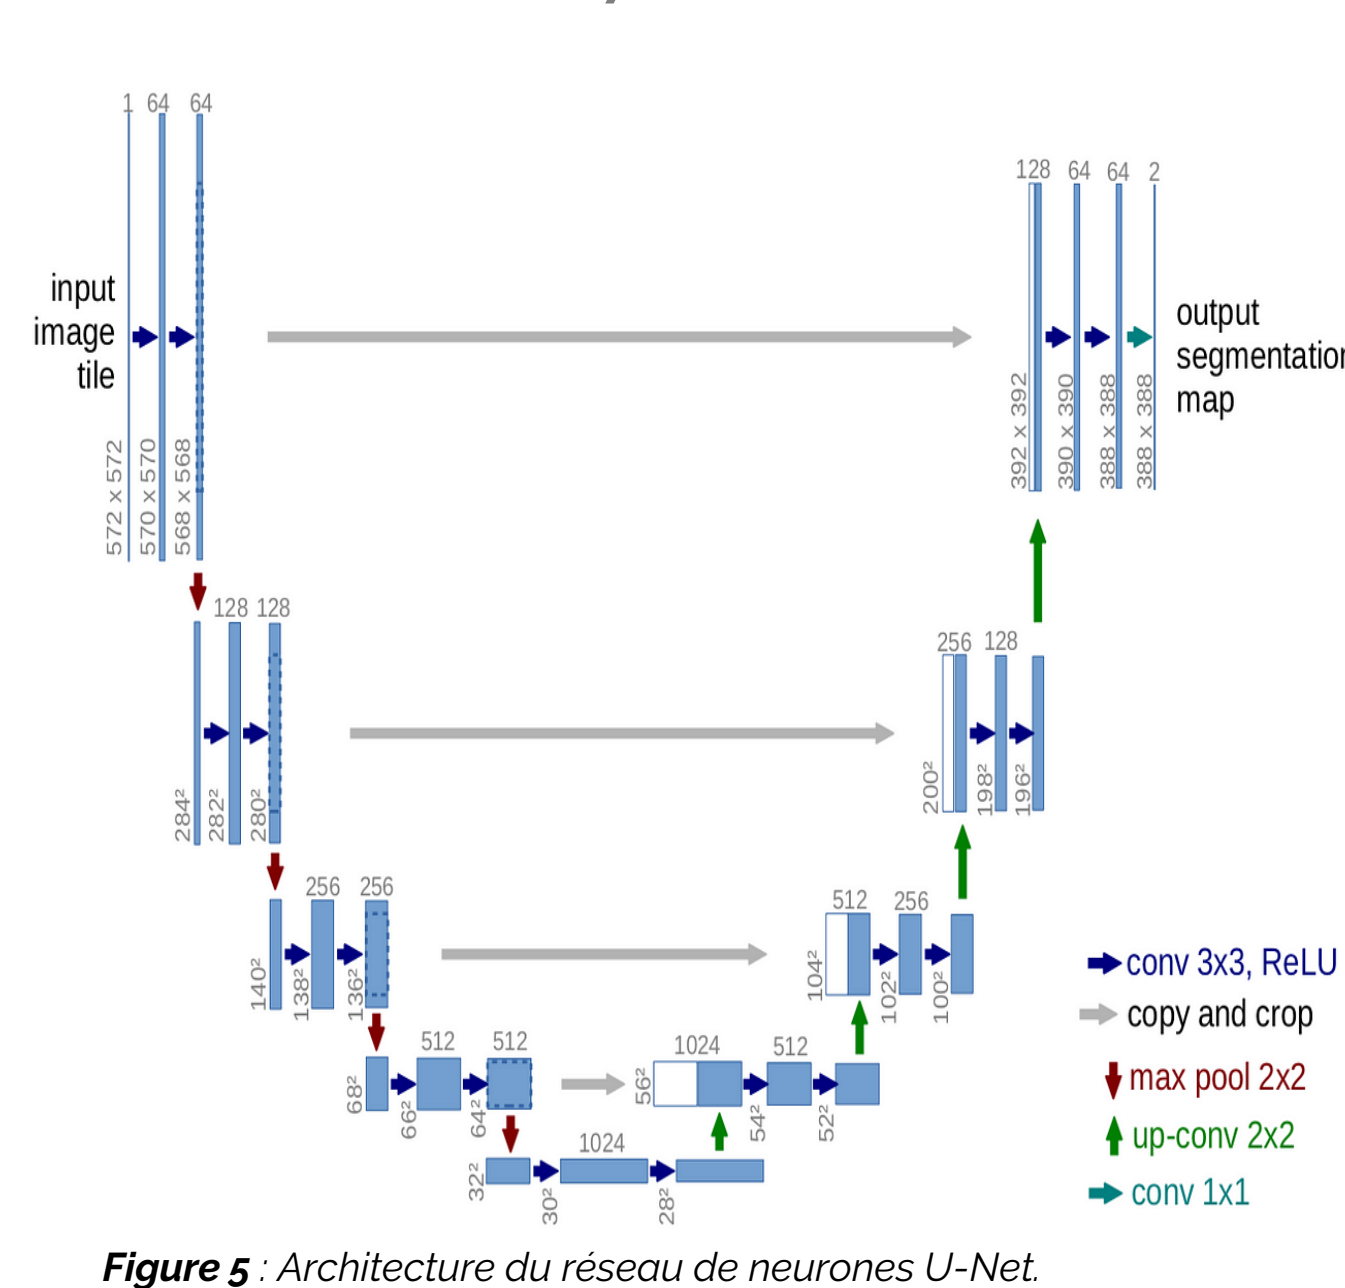


Figure 5: Architecture du réseau de neurones U-Net.

- Réseau de Neurones Convolutionnels (CNN).
- Publié en 2016
- 125000 paramètres
- Architecture fixe, symétrique Encodeur, Décodeur.

Modèles

Dynamic U-Net [8]

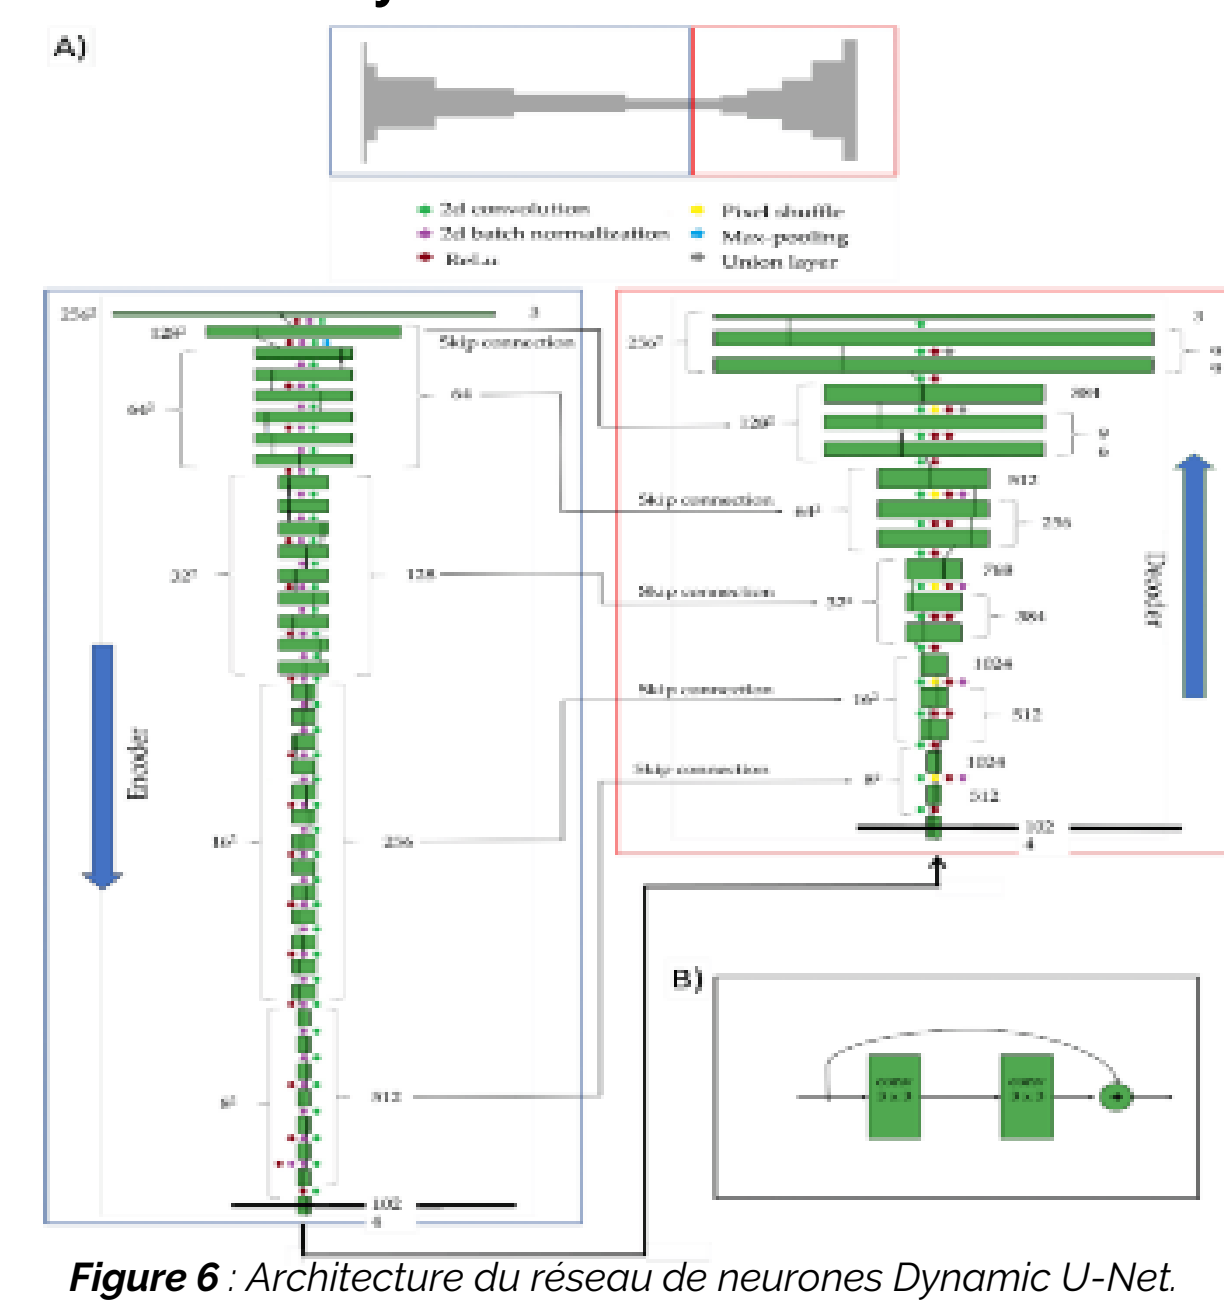


Figure 6: Architecture du réseau de neurones Dynamic U-Net.

- Réseau de Neurones Convolutionnels (CNN).
- Publié en 2021
- 33 millions paramètres
- Architecture flexible en fonction de la tâche de segmentation, asymétrique, Encodeur, Décodeur.

Plan expérimental

Division des jeux de données :

- ✓ Base de données source :
- ❖ **BraTS :**
 - Apprentissage : 80% (1001 patients)
 - Validation : 4% (50 patients)
 - Test : 16% (200 patients)
- ✓ Bases de données cibles :
- ❖ **Steringli :**
 - Apprentissage : 60% (30 patients)
 - Validation : 18% (10 patients)
 - Test : 22% (13 patients)
- ❖ **MS-SEG :**
 - Apprentissage : 56% (30 patients)
 - Validation : 19% (10 patients)
 - Test : 25% (13 patients)

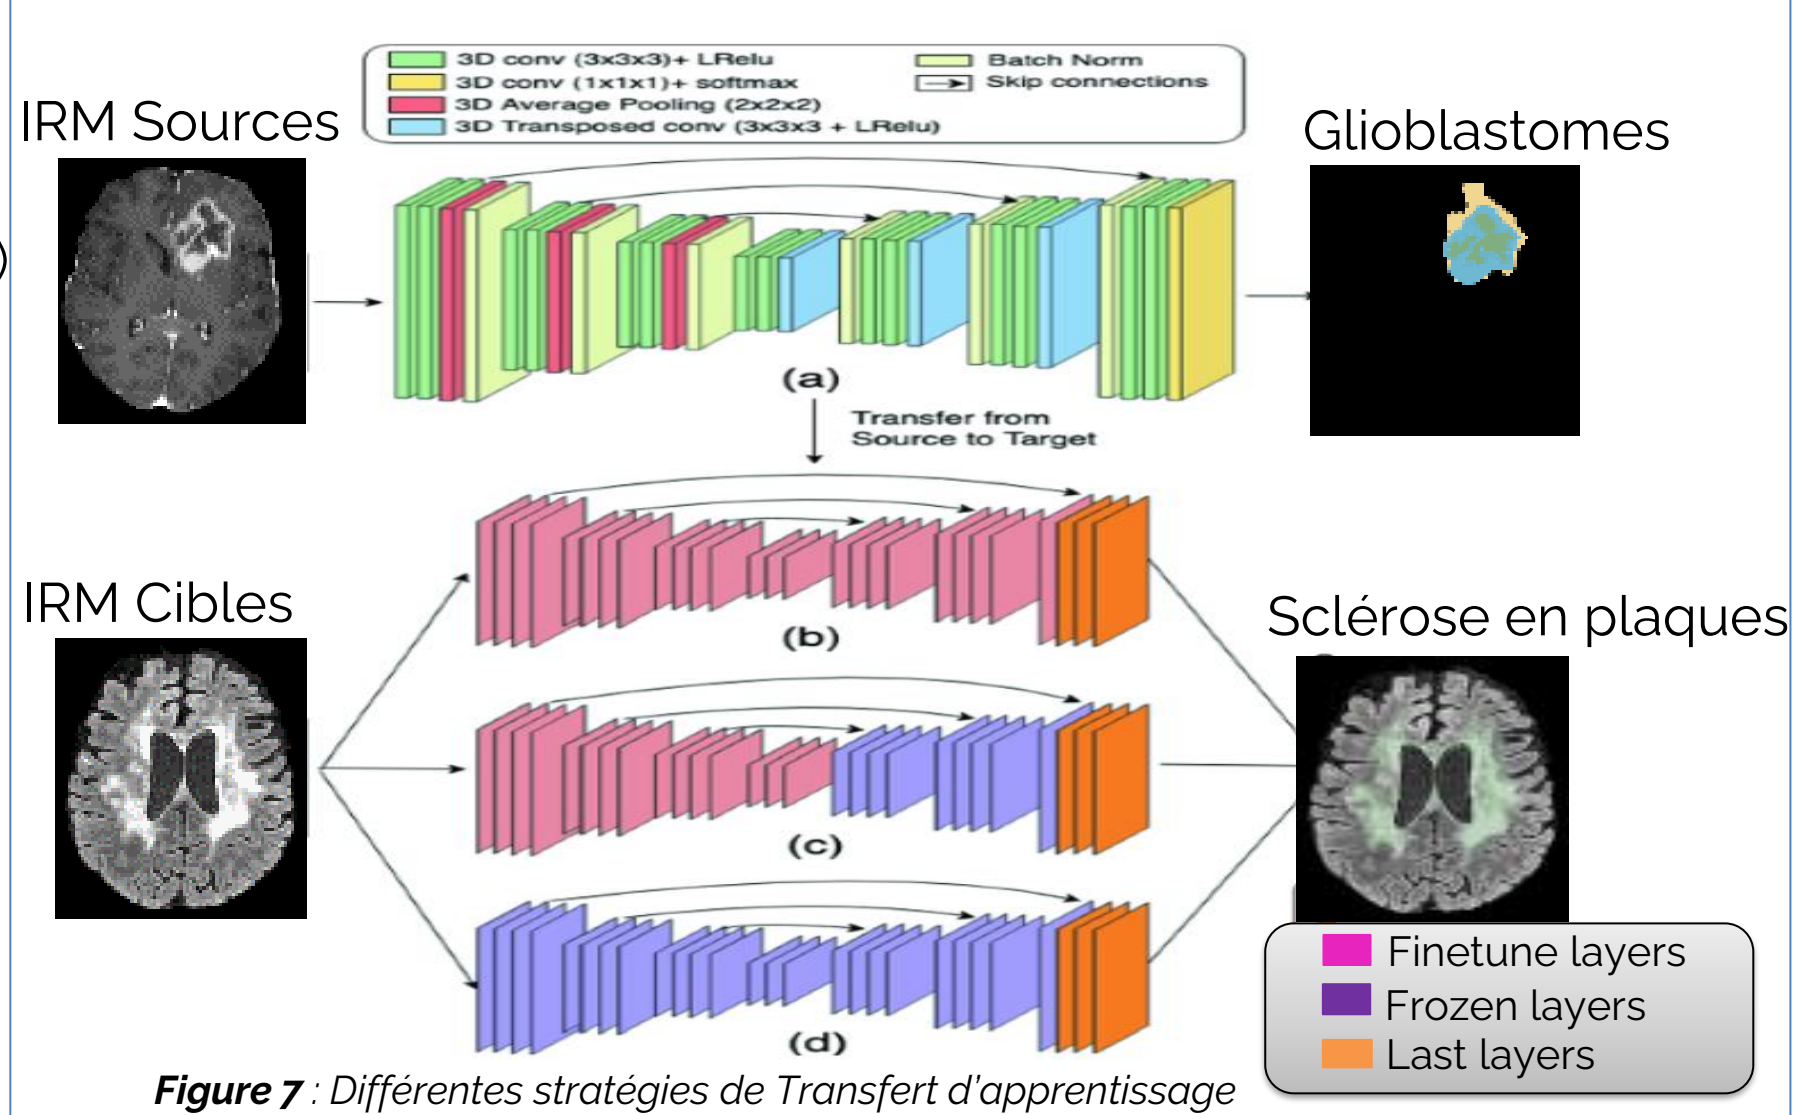


Figure 7: Différentes stratégies de Transfert d'apprentissage

Expériences:

- **Scratch** : le modèle cible est entraîné sans transfert d'apprentissage (à partir de zéro).
- **Half learning rate** (fig 7.a) : transfert d'apprentissage avec mise à jour de tous les paramètres du modèle cible.
- **Freeze encoder** : Pas de mise à jour des paramètres de l'encodeur du modèle cible lors de l'entraînement.
- **Freeze decoder** (fig 7.c) : Pas de mise à jour des paramètres du décodeur du modèle cible lors de l'entraînement.
- **Freeze both** (fig 7.d) : Pas de mise à jour des paramètres de l'encodeur et du décodeur du modèle cible lors de l'entraînement.

Expériences U-Net/Dynamic U-Net	Paramètres totaux	Paramètres entraînaibles	Paramètres non entraînaibles
Fine tune all layers	125,229/33,092,517	125,229/33,092,517	0/0
Freeze encoder	100% / 100%	56% / 49%	44% / 50%
Freeze decoder	100% / 100%	68% / 79%	33% / 21%
Freeze both	100% / 100%	23% / 28%	77% / 72%

Tableau : Nombre de paramètres non entraînaibles après chaque expérience de transfert d'apprentissage

- Les entraînements ont été répétés pour un nombre croissant de patients issus des données d'apprentissage afin de déterminer un nombre de patients jusqu'au quel le transfert d'apprentissage aurait un intérêt en termes de précision avec les modèles U-Net et Dynamic U-Net.
- Modèles évalués avec la métrique Dice sur les données de test.

Résultats

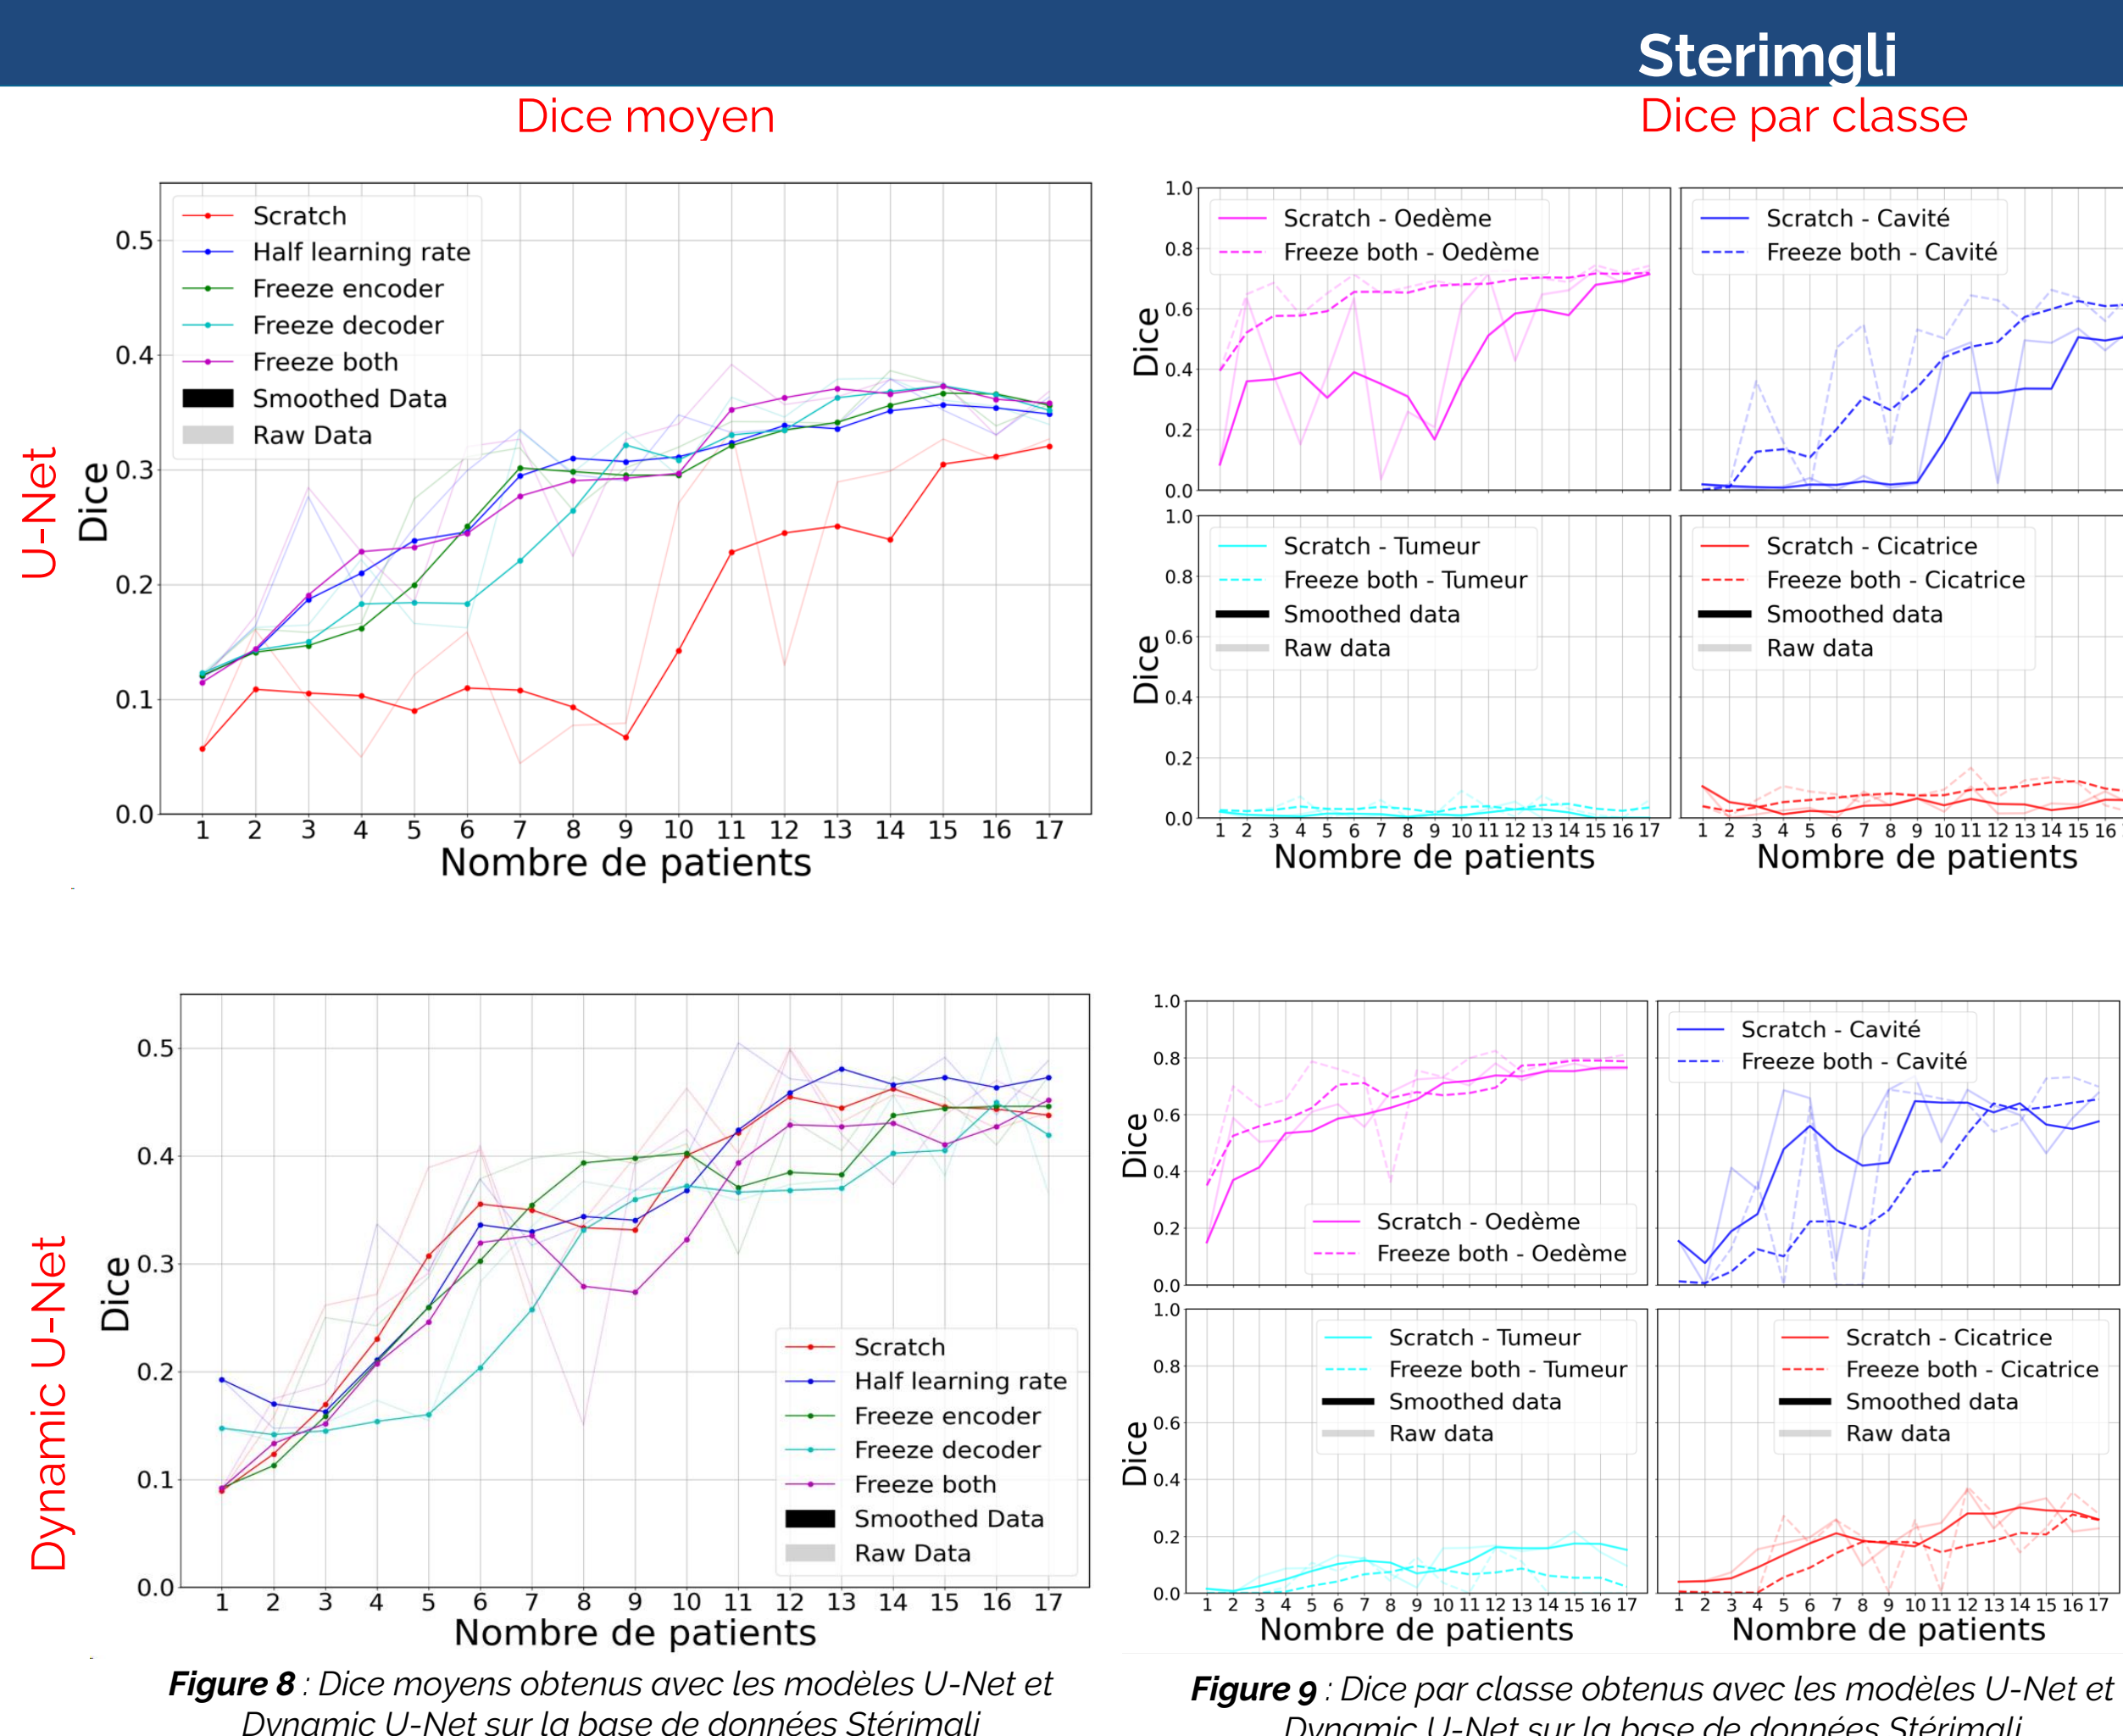


Figure 8: Dice moyens obtenus avec les modèles U-Net et Dynamic U-Net sur la base de données Steringli

Figure 9: Dice par classe obtenus avec les modèles U-Net et Dynamic U-Net sur la base de données Steringli

❖ **BraTS** : le Dice moyen est 0.79 pour le U-Net et 0.84 pour le Dynamic U-Net.

Steringli

- ✓ **U-Net** : intérêt du transfert d'apprentissage quel que soit le nombre de patient, maximal pour 9 patients.
- Aucune différence significative observée entre les expériences de transfert d'apprentissage.
- Gain de Dice moyen des expériences de transfert d'apprentissage par rapport à l'apprentissage « de zéro » (Scratch) est entre +275 et 321%.
- Dice par classe : l'œdème et la cavité ont les Dice les plus élevés. L'œdème est une classe qui est assez représentée dans les bases de données sources et cibles. La cavité très représentée dans la base cible ressemble physiquement à la nécrose qui est très représentée dans la base source. La tumeur et la cicatrice ont les Dice les plus faibles du fait d'un manque de représentativité de ces classes dans la base cible.
- ✓ **Dynamic U-Net** : Toutes les expériences atteignent des Dice supérieurs aux Dice atteints par le modèle U-Net. Le U-Net atteignant un Dice moyen de 0.35 comparé à un Dice moyen de 0.45 pour le Dynamic U-Net.
- Pas de bénéfice significatif du transfert d'apprentissage par rapport à l'apprentissage de zéro (Scratch).

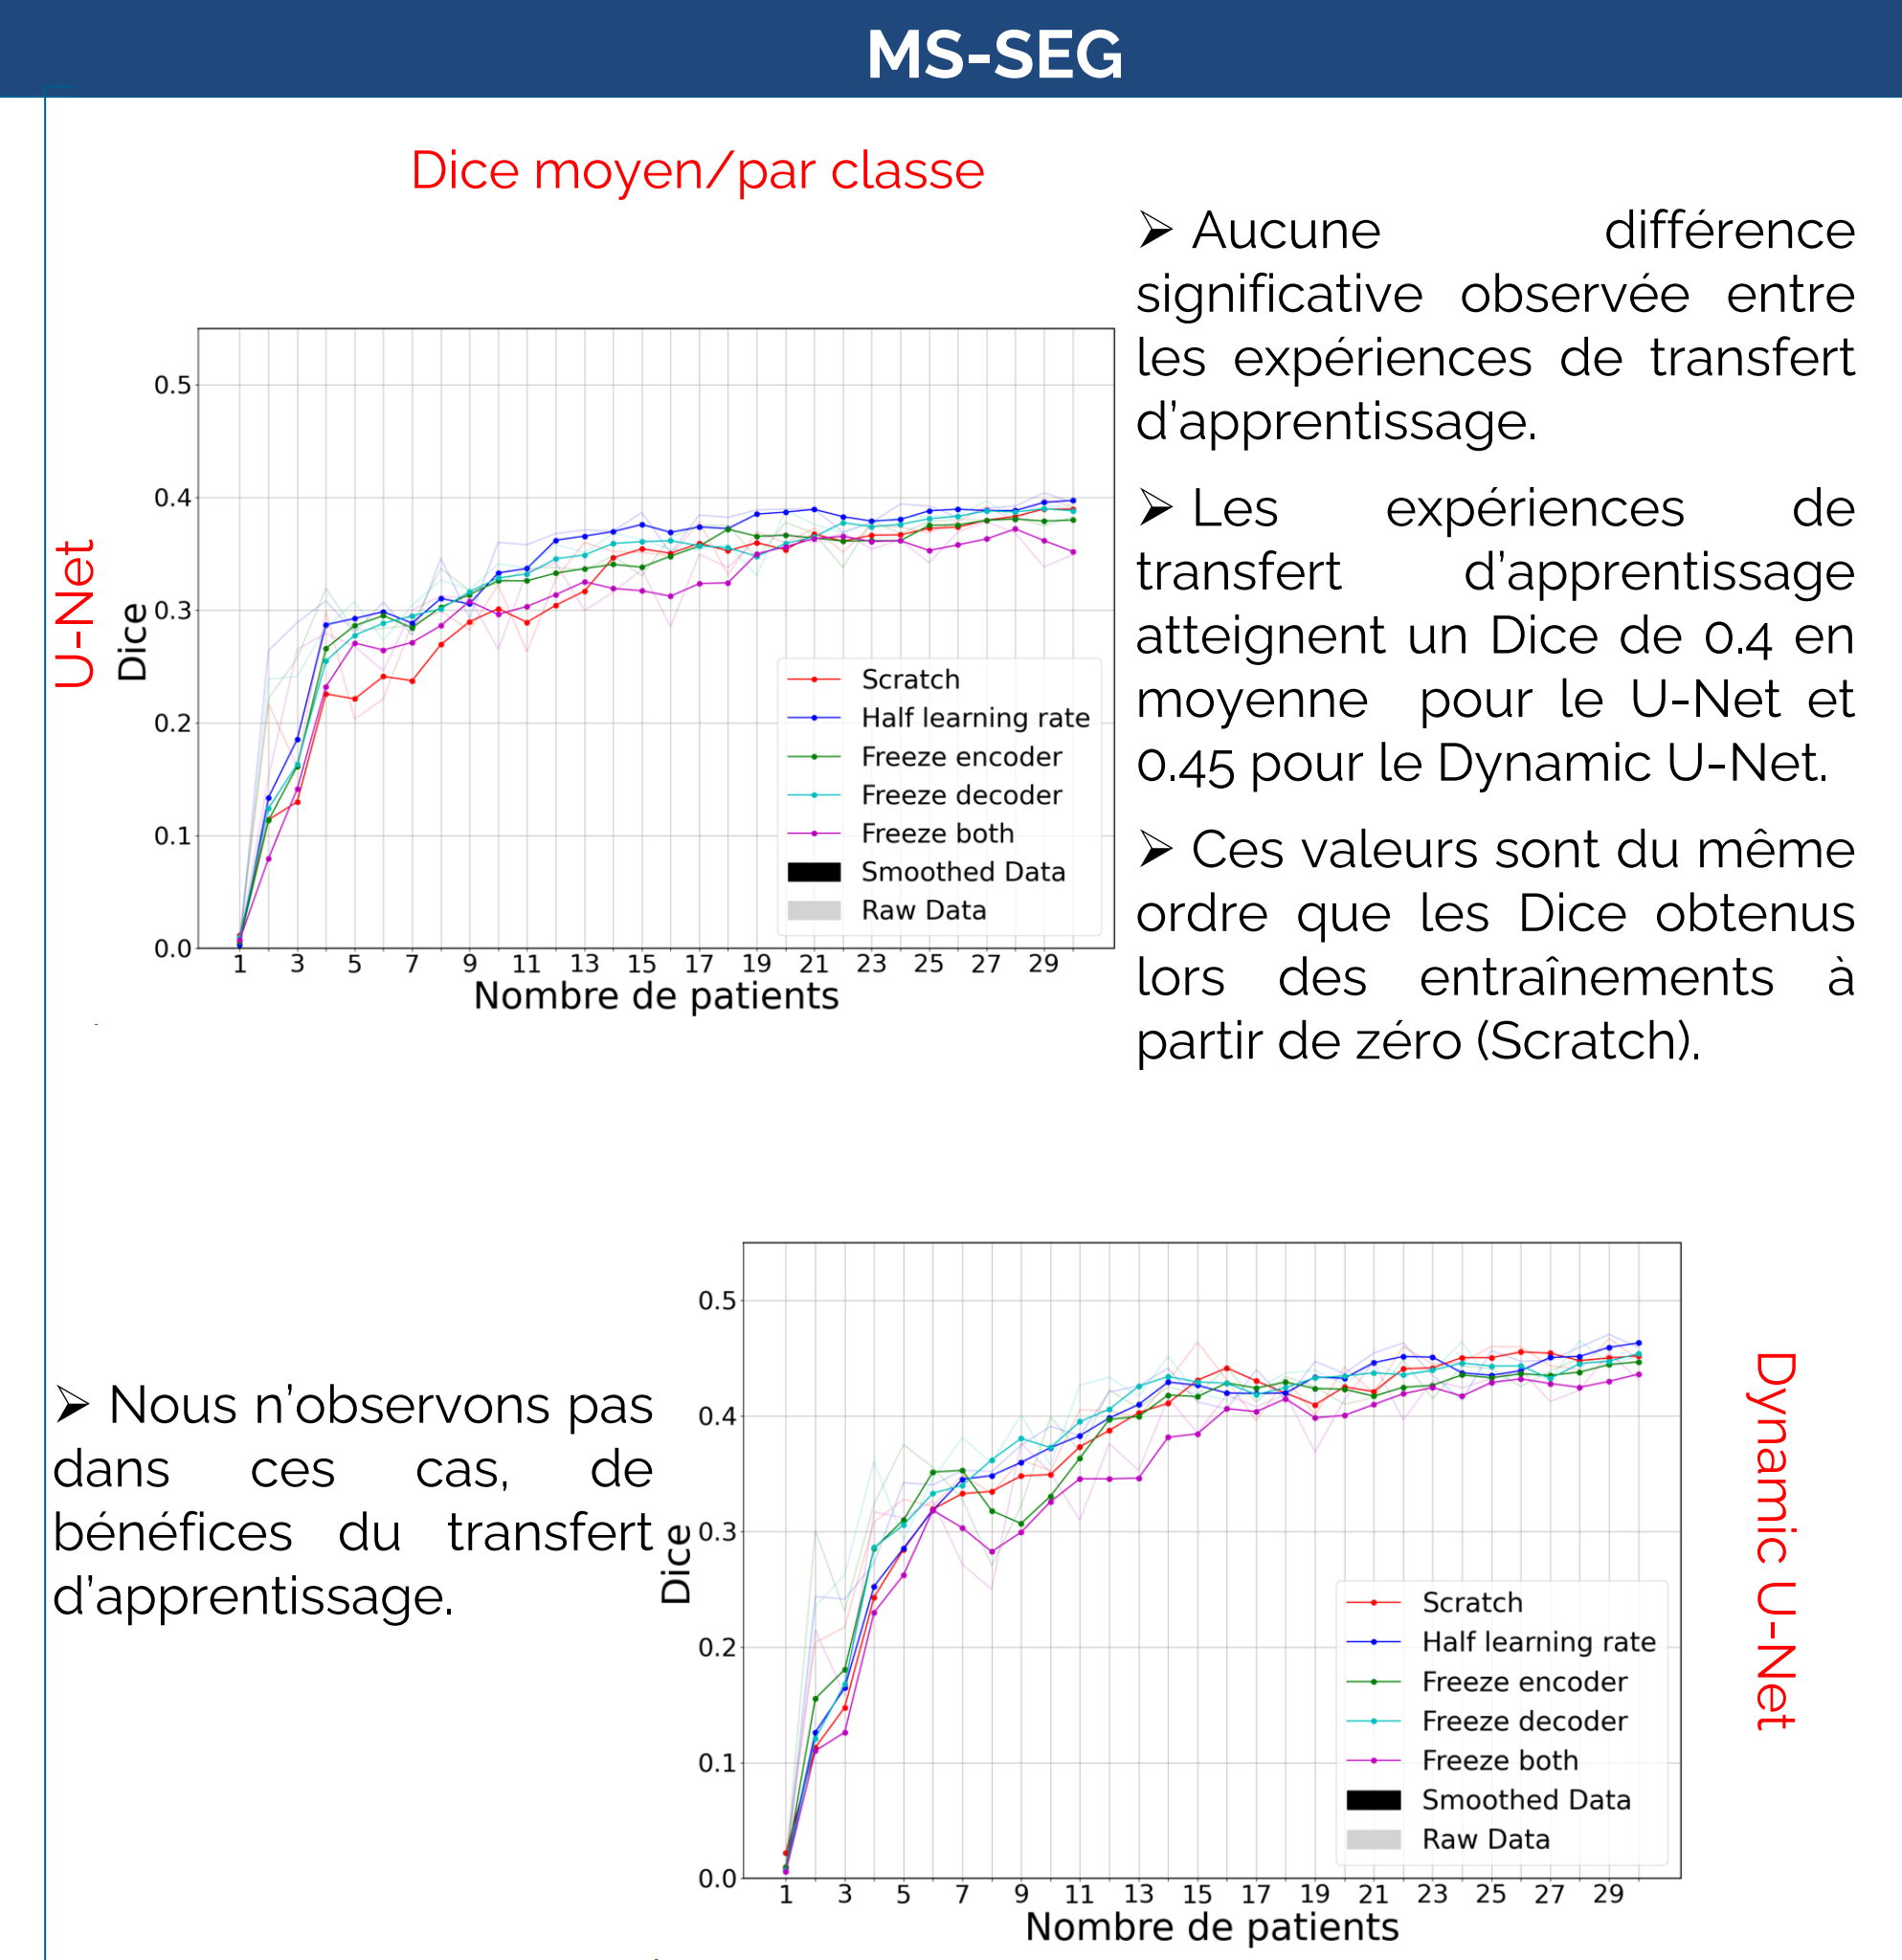


Figure 10: Dice obtenus avec les modèles U-Net et Dynamic U-Net sur la base de données MS-SEG

Discussion, Conclusion & Perspectives

- Bénéfices du transfert d'apprentissage observés pour le modèle U-Net comparativement au modèle Dynamic U-Net. Ceci pourrait s'expliquer par le fait que le U-Net soit un modèle plus ancien et moins performant que le Dynamic U-Net.
- Bénéfices du transfert d'apprentissage observés pour la base de données Steringli comparativement à la base de données MS-SEG. Ceci pourrait s'expliquer par le fait que le transfert d'apprentissage a de meilleures performances sur des bases de données cibles semblables aux bases de données sources.

- Le gain du transfert d'apprentissage bien que relativement modeste en termes de précision s'observe davantage pour des données cibles semblables aux données sources et pour les modèles conventionnels tels que le modèle U-Net, les modèles récents comme le Dynamic U-Net étant assez performants avec ou sans le transfert d'apprentissage.
- Perspective: Evaluer le transfert d'apprentissage en fonction des métriques de similarité des bases de données sources et cibles.
- Ce projet constitue une avancée dans la compréhension du transfert learning, une méthode de deep learning qui pourrait permettre d'obtenir des segmentations précises à partir d'un nombre restreint d'images et de labélisations et ainsi potentiellement alléger la charge de travail des radiologues pour une tâche souvent très chronophage et fastidieuse.

Publications

1. Liljens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal.* 2017; Dec;42:60-88

2. Weiss K, Khoshgoftar TM, Wang D. A survey of transfer learning. *J Big Data.* 2016 May 28;3(1)

3. Paul A, Yushkevich P, Joseph P, Heath C, Hazlett R, Gimpel Smith, Sean Ho, James C. Gee, and Guido Gerig. User-guided 3D active contour segmentation of anatomical structures: Significantly improved efficiency and reliability. *Neuroimage.* 2005 Jul 1; 31(3):1116-28.

4. Menze BH, Jakab A, Bauer S, Kalpathy-Cramer J, Farahani K, Kirby J, et al. The Multimodal Brain Tumor Image Segmentation Benchmark (BraTS). *IEEE Trans Med Imaging.* 2015 Oct;34(10):1993-2024

5. Commowick O, Kain M, Casey R, Ameli R, Ferré JC, Kerbrat A, Toudias T, Cervenansky F, Camarasa-Pop S, Glatard T, Vukusic S, Edan G, Barillot C, Dojat M, Cotton F. Multiple sclerosis lesions segmentation from multiple experts: The MICCAI 2016 challenge dataset. *Neuroimage.* 2021 Dec 1;244:118580. doi: 10.1016/j.neuroimage.2021.118580. Epub 2021

6. Kofler F, Berger C, Waldmannstetter D, Lipkova J, Ezhov I, Tetteh G, Kirschke J, Zimmer C, Wiestler B, Menze BH. BraTS Toolkit.

7. Ronneberger O, Fischer P, Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *ArXiv:1505.04597 Cs [Internet].* 2015 May 18 [cited 2022 Apr 22].

8. N. A. Mashudi, N. Ahmad and N. M. Noor, "Dynamic U-Net Using Residual Network for Iris Segmentation"

9. Avants, Brian B., et al. "Ants: Open-source tools for normalization and neuroanatomy." *Neuroinformatics* 10 (2009): 1-11.