

Morpho-Net

E. Carlinet, J. Chazalon, J. Fabrizio, T. Géraud, É. Puybureau,
G. Tochon,

`firstname.lastname@lrde.epita.fr`

EPITA Research & Development Laboratory (LRDE)



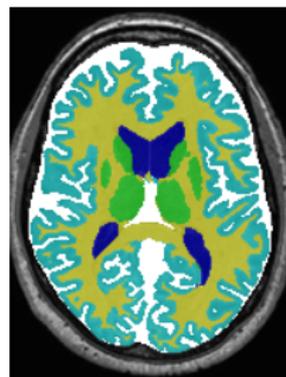
2018/12/12 — Paris

Les travaux réalisés par l'équipe

Histoire du Deep Learning au labo...

Première application : segmentation de structures cérébrales

Y. Xu et al. *From neonatal to adult brain MR image segmentation in a few seconds using 3D-like fully convolutional network and transfer learning*. In Proc. of IEEE Intl. Conf. on Image Processing (ICIP), pp. 4417–4421, Beijing, China, Sep 2017.



Ou comment faire des réseaux de neurones même quand on n'a que 2 images...

VGG, un réseau de classification d'images naturelles...

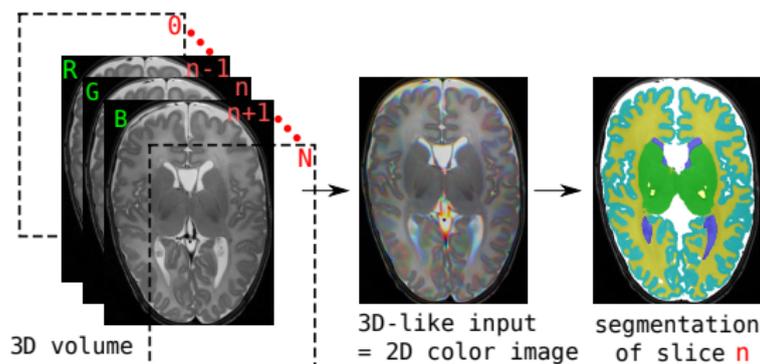
| ConvNet Configuration | | | | | |
|-----------------------------|------------------------|-------------------------------|--|--|---|
| A | A-LRN | B | C | D | E |
| 11 weight layers | 11 weight layers | 13 weight layers | 16 weight layers | 16 weight layers | 19 weight layers |
| input (224 × 224 RGB image) | | | | | |
| conv3-64 | conv3-64 LRN | conv3-64 conv3-64 | conv3-64 | conv3-64 conv3-64 | conv3-64 |
| maxpool | | | | | |
| conv3-128 | conv3-128 | conv3-128 conv3-128 | conv3-128 | conv3-128 | conv3-128 |
| maxpool | | | | | |
| conv3-256 conv3-256 | conv3-256 conv3-256 | conv3-256 conv3-256 | conv3-256 conv1-256 | conv3-256 conv3-256 | conv3-256 conv3-256 conv3-256 |
| maxpool | | | | | |
| conv3-512 conv3-512 | conv3-512 conv3-512 | conv3-512 conv3-512 | conv3-512 conv3-512 conv1-512 | conv3-512 conv3-512 conv3-512 | conv3-512 conv3-512 conv3-512 conv3-512 |
| maxpool | | | | | |
| conv3-512 conv3-512 | conv3-512 conv3-512 | conv3-512 conv3-512 | conv3-512 conv3-512 conv1-512 | conv3-512 conv3-512 conv3-512 | conv3-512 conv3-512 conv3-512 conv3-512 |
| maxpool | | | | | |
| FC-4096 | | | | | |
| FC-4096 | | | | | |
| FC-1000 | | | | | |
| soft-max | | | | | |

- ▶ Développé pour classifier des images naturelles par Simonyan et Zisserman
- ▶ Prend en entrée des images 2D RGB
- ▶ Entraîné sur la base ImageNet
- ▶ Inférence rapide
- ▶ Disponible et facilement modifiable pour faire de la segmentation

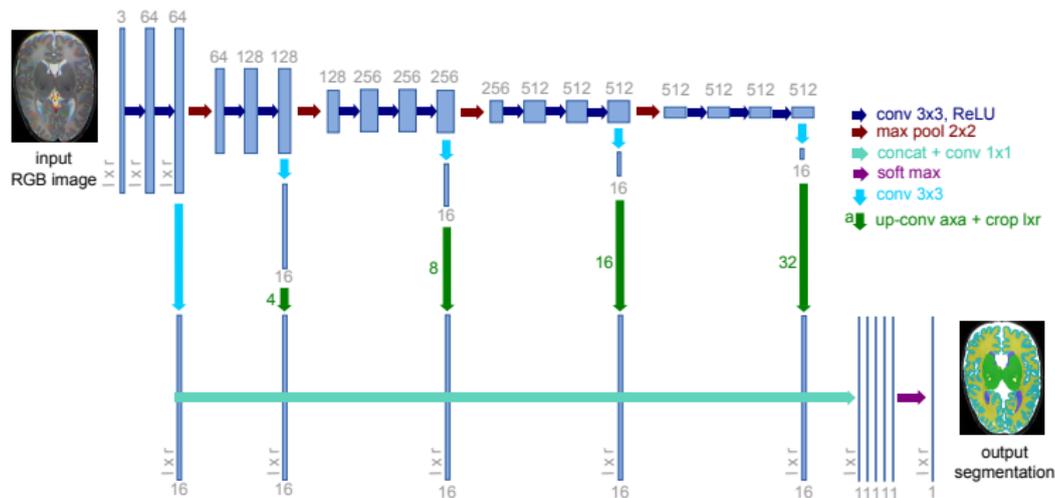
Comment l'adapter pour de la **segmentation d'images médicales 3D** ?

La définition du pseudo-3D, ou comment concilier images 2D et information 3D

- Pour chaque slice n du volume 3D, on définit son image “pseudo-3D” comme étant la combinaison de la slice n et de ses voisines ($n-1$ et $n+1$)



Et quand on combine tout ça...

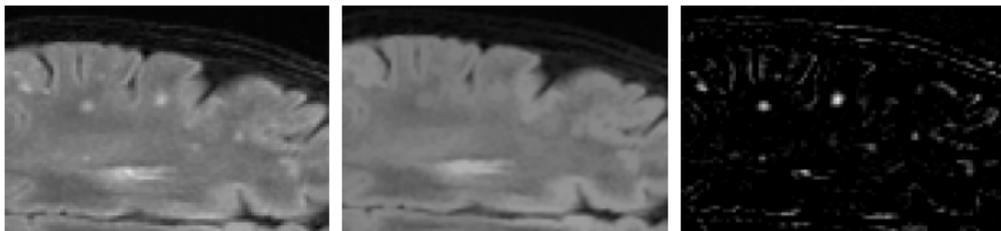


- ... on obtient un réseau qui segmente les images 3D cérébrales en quelques secondes !

Et la morphologie mathématiques dans tout ça ?

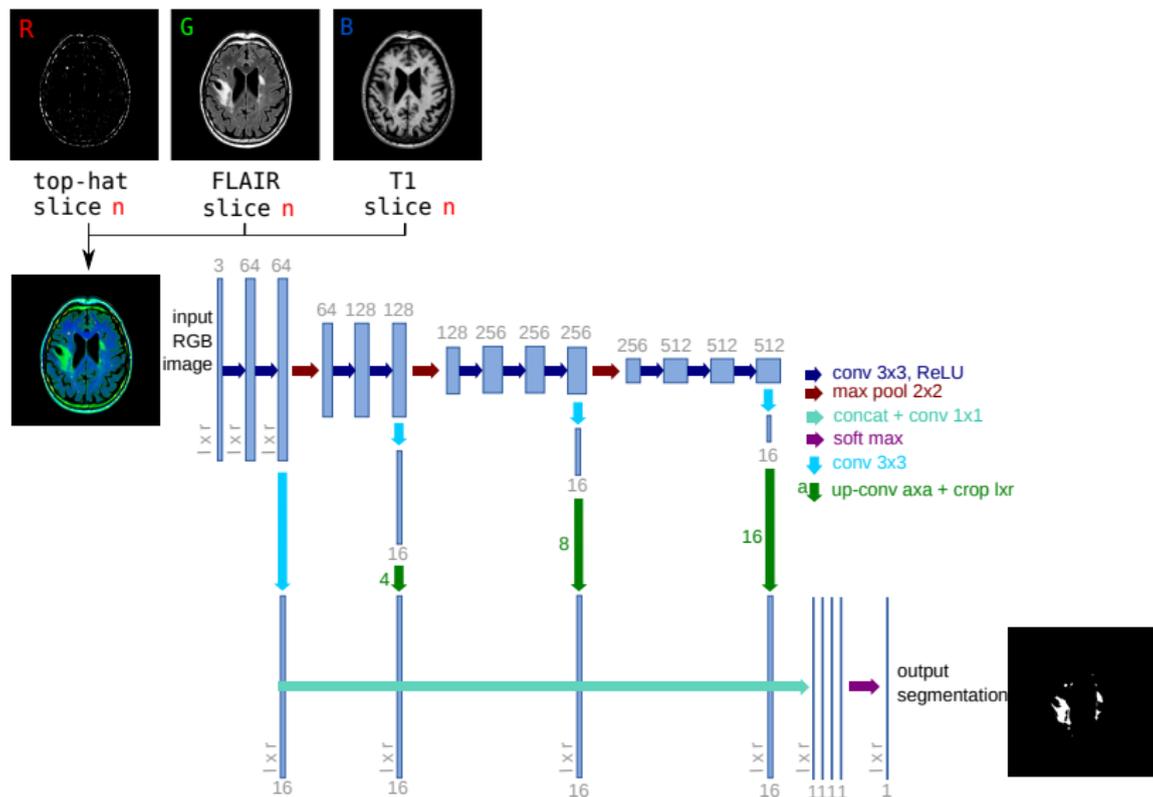
En 2017, le challenge MICCAI WMH propose de segmenter les hyperintensités de la matière blanche. Problème ? Ce sont des structures qui peuvent être très petites. . .

C'est là qu'intervient la morphologie mathématique :



- ▶ Le résidu du top-hat permet d'extraire les petites hyperintensités. . .
- ▶ Comment en tirer parti ?

Et la morphologie mathématiques dans tout ça ?



Et la morphologie mathématiques dans tout ça ?

Résultats :

| Images d'entrée | Dice | AVD | Recall | F1 |
|-----------------|------|--------------|-------------|-------------|
| pseudo-3D | 0.72 | 23.90 | 0.38 | 0.46 |
| 2D sans top-hat | 0.72 | 28.24 | 0.39 | 0.48 |
| 2D avec top-hat | 0.75 | 22.63 | 0.61 | 0.63 |

Conclusion :

- ▶ Le pseudo-3D n'est pas la méthode la plus efficace ici.
- ▶ Le pré-processing morphologique est un atout certain pour la détection et segmentation des WMH.

Et la morphologie mathématiques dans tout ça ?

En 2018, le challenge MICCAI MrBrains propose de segmenter les structures du cerveau ainsi que les hyperintensités de la matière blanche. 2 méthodes ont été soumises :

- ▶ un réseau entraîné sur toutes les modalités,
- ▶ et une fusion de ce dernier réseau avec celui développé pour le challenge WMH.

Et la morphologie mathématiques dans tout ça ?

| Méthode | Dice | Volume Similarity | H95 |
|-------------------------------|--------------|-------------------|--------------|
| Réseau 3 modalités seul | 0.531 | 0.651 | 15.13 |
| + ajout réseau spécifique WMH | 0.595 | 0.719 | 11.16 |

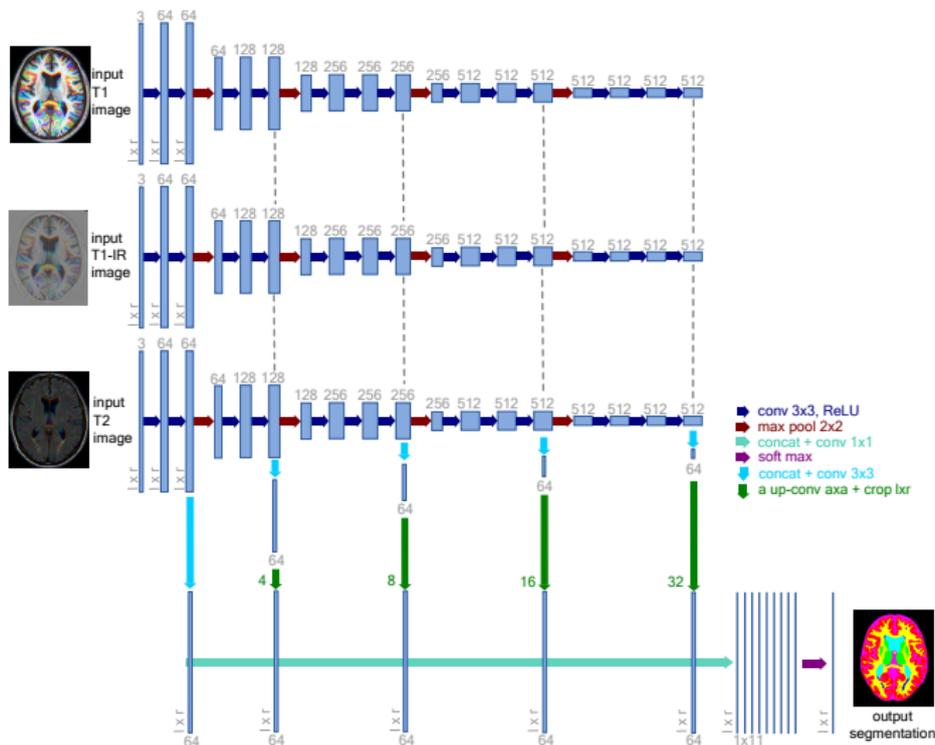
Bilan : oui, la fusion des deux segmentations augmente les performances du réseau. La preuve ? Nous sommes passés de 11ème à 6ème au classement général sur 23 participants !

Conclusion de ces expériences

- ▶ VGG peut décrire de manière générique une image, ce qui permet de passer de classification à segmentation, même sur des jeux de données complètement différents
- ▶ L'idée qui émerge est que si les CNN sont extrêmement performants, ils peuvent laisser passer de l'information qu'on peut "garder" grâce à du pré-traitement à base de morphologie mathématiques
- ▶ La morphologie mathématique améliore les résultats de détection et de segmentation, en particulier pour les **petites structures** : on peut aider les réseaux à "mieux" apprendre.

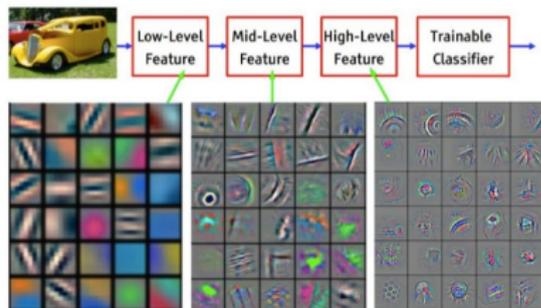
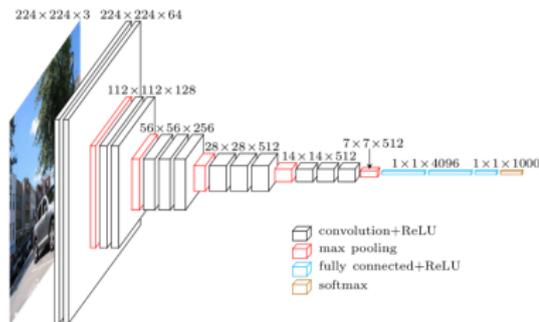
Perspectives

Directement sur les images d'entrée, par exemple :



Est-ce que rajouter le résidu du top-hat aux images d'entrée pourrait aider la détection des WMH ?

Intégration des opérateurs morphologiques dans le CNN

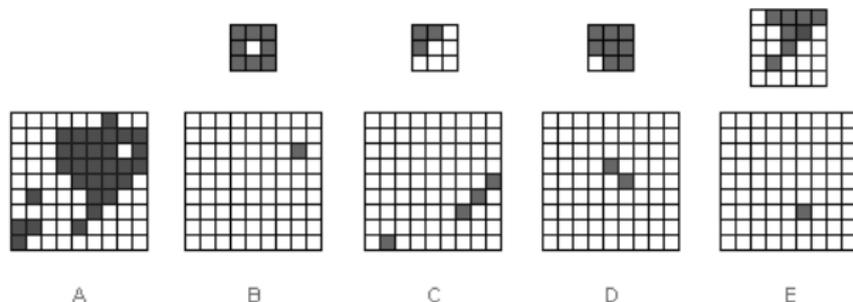


Feature visualization of convolutional net trained on ImageNet from [Zeiler & Fergus 2013]

- ▶ Premières couches très (trop?) génériques (low-level feature)
- ▶ Premières couches = filtrage local
- ▶ **Avantages:** invariance par translation
- ▶ **Inconvénients:** pas de prise en compte de la géométrie

Intégration des opérateurs morphologiques dans le CNN

- ▶ On peut fixer les poids des premières couches (transfer learning)
- ▶ On peut guider le réseau (introduire l'a-priori)



Premières couches à base d'extracteurs de caractéristiques morphologiques

- ▶ Erosion / dilatation / ouverture / fermeture à base de SE
- ▶ Gradients morphologiques (pour des filtres de 1er ordre)
- ▶ Hit-or-miss
- ▶ LBP
- ▶ ...

Intégration des opérateurs morphologiques dans le CNN

- ▶ Certains filtres des 1eres couches sont des régularisateurs



Premières couches fixes à base de morphologie connexe

- ▶ Ouvertures et fermetures connexes
- ▶ Filtres de grains

Objectifs:

- ▶ Les contours (détails) sont préservés
(important pour la classification des structures fines)
- ▶ Introduire de la régularisation non-locale qui suit la géométrie

Intégration des opérateurs morphologiques dans le CNN

- ▶ Le pooling ne suit pas la géométrie
- ▶ Le *deep learning* supporte déjà les graphes

Objectifs:

- ▶ Mettre en place un pooling cohérent sur les images simplifiées (E.g. un pooling sur les RAGs)

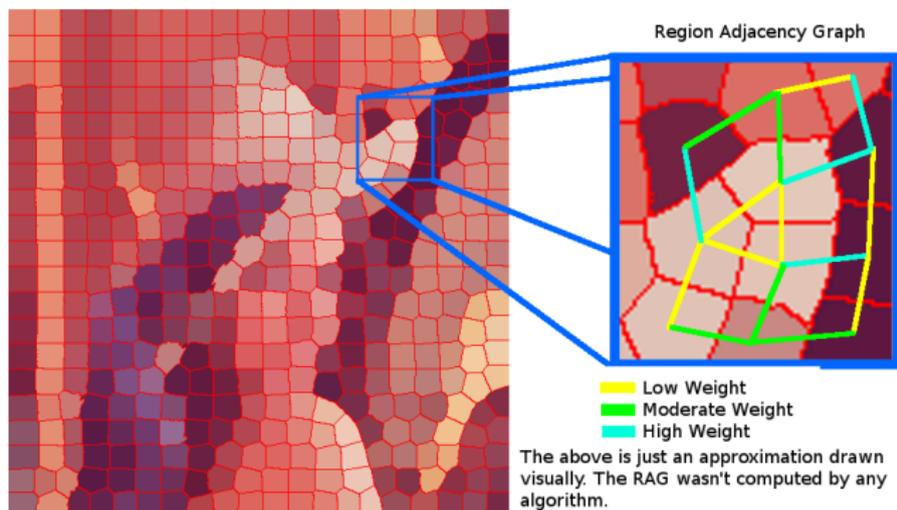


Image from ¹

¹(<https://vcansimplify.wordpress.com/2014/05/16/graph-based-image-segmentation/>)

Voici venu le moment de la discussion !



Merci de votre attention !