



HAL
open science

Automatisation de la pose de landmarks sur des meshes 3D en morphométrie grâce à une approche de Deep Learning

Guillaumot Charlène, Sklab Youcef, Dubied Morgane, Laffont Rémi, Nicolas Navarro

► To cite this version:

Guillaumot Charlène, Sklab Youcef, Dubied Morgane, Laffont Rémi, Nicolas Navarro. Automatisation de la pose de landmarks sur des meshes 3D en morphométrie grâce à une approche de Deep Learning. Journée Deep Learning pour la Science, Fidle CNRS, IDRIS, May 2024, PARIS, France. hal-04590093

HAL Id: hal-04590093

<https://hal.science/hal-04590093>

Submitted on 28 May 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.

Journée

Deep learning

Pour

La Science

VENDREDI


24 MAI 2024

AUDITORIUM MARIE CURIE

SIÈGE DU CNRS

3 RUE MICHEL ANGE

75016 PARIS



Automatisation de la pose de landmarks sur des meshes 3D en morphométrie grâce à une approche de Deep Learning

GUILLAUMOT Charlène¹, SKLAB Youcef², DUBIED Morgane¹, LAFFONT Rémi¹, NAVARRO Nicolas^{1,3}

1. Biogéosciences, UMR 6282 CNRS, Université de Bourgogne, 6 Boulevard Gabriel, 21000 Dijon, France

2. IRD, Sorbonne Université, UMMISCO, F-93143, Bondy, France

3. EPHE, PSL University, 75014 Paris, France



BIOG OSCIENCES





 cole Pratique
des Hautes  tudes



Institut de Recherche
pour le D veloppement
FRANCE

Analyse de meshes 3D en morphométrie




Application logiciel (ALPACA) , Slicer

-> prédictions de points


-> méthode par déformation du nuage de points

-> MAIS prédictions imparfaites


**Implique la pose de
landmarks (manuellement)**



Analyse de meshes 3D en morphométrie



Implique la pose de landmarks (manuellement)




Application logiciel (ALPACA) , Slicer


-> prédictions de points

-> méthode par déformation du nuage de points


-> MAIS prédictions imparfaites

Objectifs : faire mieux avec une approche deep learning !

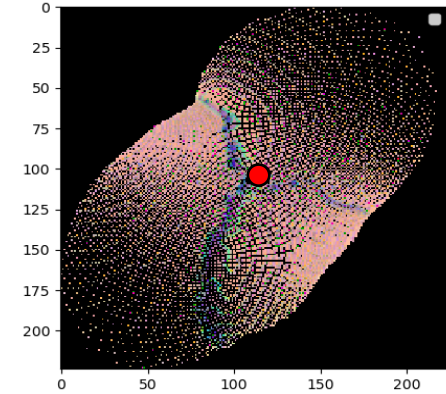




1. Extraction de la zone d'intérêt à analyser (3 rayons différents, 1 translation)
=> 4 petites images 3D par zone







2. Coloration RGB (occlusion ambiante, obscurance volumétrique, courbure)



3. Paramétrisation dans un espace 2D et transformation en images raster RGB de taille 224x224
4. Repositionnement des landmarks « vrais » connus pour l'entraînement du modèle


5. Entraînement des modèles pour 6 landmarks, avec entre 6800 et 9100 images disponibles par landmark pour l'entraînement



DECOUPAGE DU JEU D'IMAGES

70% training

20% validation ; 10% test

**METRIQUES D'EVALUATION**

Loss : mean squared error (MSE)

Eval : Root MSE

TRAITEMENT DES IMAGES

Normalisation des images

Augmentation : rotation 30°

CALLBACKS & HYPERPARAMETRES

Early stopping, monitoré sur loss, patience de 15


Checkpoint pour enregistrer le .h5

Batch size de 128

Epochs: 500

Optimizer: Adam; learning rate : défaut 10⁻⁴

DropOut, batchNormalization et régularisation L1/L2



ex. Landmark F15

Xception


ResNet101

ViT

Pré-entraînement « ImageNet »






Prédiction des coordonnées du landmark, comparaison (distance) à la prédiction faite par ALPACA



RESULTATS XCEPTION


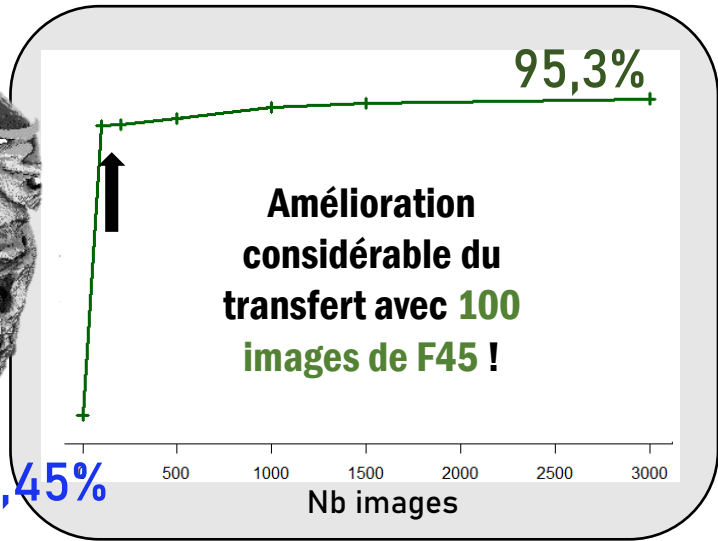



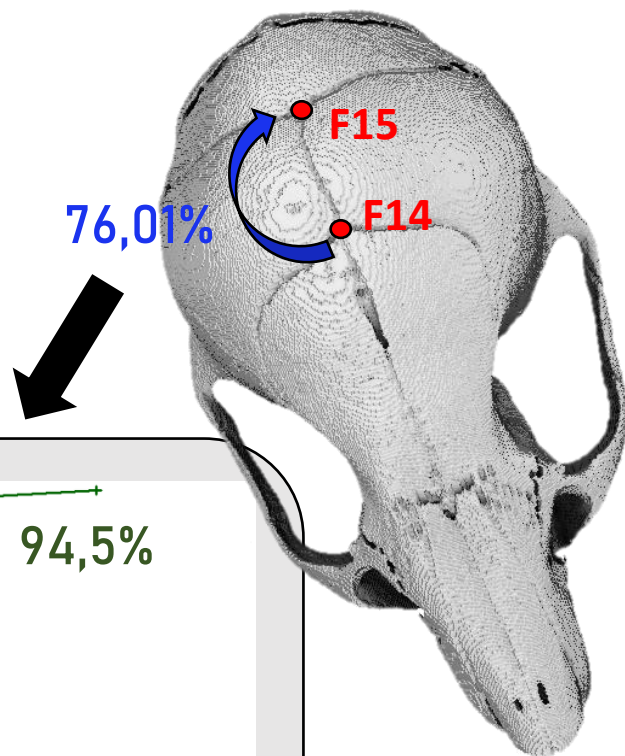
Landmark	Nombre d'images	Meilleur que ALPACA?*
F15	7426	94.74%
F14	9063	98.56%
F35	6826	75.81%
F34	7947	94.08%
F49	8539	88.04%
F45	9800	93.16%

* Comparaison du nb de fois où la distance au manuel est inférieure à celle de la prédiction de ALPACA







Transfer learning : utilisation .h5 pour prédire directement sur un autre landmark

Fine-tuning : .h5 + entraînement complémentaire avec des images du landmark



- Etablir des zones d'application des .h5
- Tenter de faire un modèle avec tous les landmarks mélangés
- Généraliser la méthode à d'autres modèles 3D




Merci pour votre attention et RDV sur le poster !

Utiliser le deep learning pour automatiser la pose de landmarks dans les analyses de morphométrie d'images 3D

GUILLAUMOT Charlene¹, SKLAB Youcef², DUBIED Morgane¹, LAFFONT Rémi¹, NAVARRO Nicolas^{1,3}

¹ Biogéosciences, UMR 6282 CNRS, Université de Bourgogne, 6 Boulevard Gabriel, 21000 Dijon, France
² IJOS, Sorbonne Université, UMR 8150, F-03143, Reims, France
³ EPHE, PSL University, 75014 Paris, France



CONTEXTE

Analyse d'images 3D en morphométrie




Implique la pose de landmarks (manuellement)

Il existe une application logicielle (ALPACA, Slicer) qui permet de faire des prédictions de position de landmarks, par la déformation d'une image source transformée en nuage de points vers une image cible avec des prédictions, → les prédictions sont imparfaites

Notre objectif

Utiliser un réseau de neurones type CNN pour faire apprendre au modèle les zones de failles/jointures/craux qui caractérisent l'emplacement des landmarks et automatiser leur positionnement.




Focus sur des petites zones d'intérêt définies préalablement par le logiciel de prédiction ALPACA. On utilise le CNN pour améliorer la position de la prédiction ALPACA.

METHODE : PRODUCTION DES IMAGES D'APPRENTISSAGE




1. Extraction de la zone d'intérêt à analyser (3 rayons différents, 1 transition) → 4 petites images 3D par zone

2. Coloration RGB (occlusion ambiante, opacité volumétrique, courbure)




3. Paramétrisation dans un espace 2D et transformation en images raster RGB de taille 224x224
 4. Repositionnement des landmarks « vrais » connus pour l'entraînement du modèle



Entraînement des modèles pour 6 landmarks, entre 4800 et 9100 images disponibles par landmarks pour l'entraînement

METHODE : DETAIL DES RESEAUX DE NEURONES

DECOMPOSITION DES IMAGES



Données input: image raster 224x224 et position (x,y) du landmark connu

Output: prédiction de la position (x,y) du landmark

ARCHITECTURES TESTÉES

Xception
ResNet101
VIT

FONDS

Pré-entraînement = ImageNet

MÉTODES D'OPTIMISATION

Loss : mean square error (MSE)
Evik : Root MSE

TUNING DES PARAMÈTRES

Normalisation des images
Augmentation : rotation 30°

CALLBACKS & HYPERPARAMÈTRES

Early stopping, monitoré sur loss, patience de 15

Checkpoint pour enregistrer le .h5



Batch size de 128

Epoques: 500


Optimizer: Adam; learning rate : défaut 10⁻⁴

DropOut, batchNormalization et régularisation L1/L2

ARCHITECTURE XCEPTION



Couche personnalisée



Input: images raster 224x224 et position (x,y) du landmark connu

```
from tensorflow.keras.applications import Xception
base_model = Xception(input_shape=(224, 224, 3), include_top=False, weights='imagenet')
base_model.trainable = True # sortie du modèle chargé - block CNN taille 2568
```

```
model = keras.Sequential([
    base_model,
    layers.MaxPooling2D((4,4)),
    Flatten(),
    layers.Dense(512, activation='relu', kernel_regularizer=L1(0.01+0.5, (2+0.5)),
    Dropout(0.5),
    layers.BatchNormalization(),
    layers.Dense(2, kernel_regularizer=L1(0.01+0.5, (2+0.5))])
```

RESULTATS

Landmark	Nombre d'images	Milleur que ALPACA*
F15	7426	94.74%
F16	9262	99.54%
F18	4826	76.81%
F24	7947	94.08%
F49	8539	88.04%
F45	9100	92.16%



Tableau 1. Résultats des entraînements des modèles pour 6 landmarks

* Comparaison du 20 de la distance au maximum entre l'alignement à la main et la prédiction ALPACA.



TRANSFÈRES : ZERO-SHOT LEARNING puis FINE-TUNING

Zero-shot learning du modèle de F16 sur F15 De F15 sur F24 De F49 sur F45



Fine-tuning : réentraînement des modèles en utilisant des images du landmark, entre 100 et 1000 images nécessaires pour atteindre des scores intéressants