

Déformation 3D automatique du fémur à partir d'un nombre arbitraire de radiographies EOS calibrées

par

Francis TOUPIN

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE DES TECHNOLOGIES DE LA SANTÉ
M. Sc. A.

MONTRÉAL, LE 17 DÉCEMBRE 2023

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Francis Toupin, 2023



Cette licence Creative Commons signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette oeuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'oeuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE:

M. Carlos Vazquez, directeur de mémoire
Département de génie logiciel et des TI, École de Technologies Supérieure

M. Jacques de Guise, codirecteur
Département de génie des systèmes, École de Technologies Supérieure

M. Marco Pedersoli, président du jury
Département de génie de systèmes, École de Technologies Supérieure

M. Adrien Gruson, membre du jury
Département de génie logiciel et des TI

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 11 DÉCEMBRE 2023

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

J'aimerais remercier Jacques de m'avoir accueilli au LIO aussi rapidement et avec autant d'aisance ; je n'aurais pas pu demander mieux. Merci à Thierry et Carlos de m'avoir guidé au fil des dernières années, j'ai beaucoup appris de vous. Un grand merci à Lulu, qui m'a beaucoup aidée avec Matlab et qui a toujours été rapide dans ses réponses et patiente lorsque je ne comprenais pas. Merci à EOS Imaging pour le financement et pour la possibilité d'avoir pu travailler sur un projet aussi intéressant.

Je veux aussi dire merci à toutes les personnes incroyables que j'ai rencontrées au LIO, certains sont devenus des amis et d'autres des collègues de travail. J'aurais aimé passer plus de temps avec vous, ce temps à la maîtrise n'aurait pas été pareil si nous avions pu être ensemble tout le long du processus. Merci aussi à mon équipe d'EOS Imaging, vous m'avez beaucoup aidé et supporté autant dans la rédaction de mon mémoire que dans mon nouvel emploi.

Merci à ma femme Catherine (j'imagine que d'ici à ce que ce mémoire soit disponible, ce sera fait !) pour l'aide qu'elle m'a apportée dans mes longues soirées de travail sans jamais me faire sentir que je travaillais trop. Évidemment, ma maîtrise aurait été très solitaire pendant la COVID sans toi, mais je n'aurais pas voulu être avec personne d'autres. Finalement, je pense que mes plus gros remerciements vont à mes parents. Vous m'avez toujours supporté à continuer d'étudier, même lorsque je n'étais pas certain d'où je m'en allais. Ce diplôme de maîtrise n'est pas que le mien !

Déformation 3D automatique du fémur à partir d'un nombre arbitraire de radiographies EOS calibrées

Francis TOUPIN

RÉSUMÉ

La reconstruction 3D du fémur est utile aux chirurgiens orthopédiques afin de planifier leur chirurgie ainsi que le type d'implants à utiliser. En partenariat avec la compagnie EOS Imaging, nous utiliserons leurs radiographies biplanes calibrées afin de proposer une méthode de déformation 3D précise du fémur permettant d'utiliser un nombre arbitraire de radiographies EOS calibrées. Ce projet de recherche s'inscrit dans l'optique de remplacer la méthode de reconstruction 3D semi-automatique actuellement utilisée dans la plateforme commerciale de EOS Imaging, SterEOS. Notre revue de la littérature a permis de constater que les algorithmes de reconstruction 3D actuellement utilisés en reconstruction d'os à partir de radiographies s'appuient majoritairement sur des algorithmes de recalage 3D/2D non rigide. Ces méthodes, bien que robustes et précises, possèdent plusieurs limitations et sont complexes à utiliser. C'est dans cette optique que nous proposons une méthode de déformation 3D automatique utilisant Pixel2Mesh++, un algorithme d'apprentissage profond effectuant une déformation dense sur un modèle générique. Nos expérimentations se concentrent sur l'utilisation d'une paire de DRR où le fémur est en position face/profil ainsi que sur l'impact de l'utilisation de radiographies additionnelles dans le processus de reconstruction et montrent que notre méthode permet d'obtenir une reconstruction très précise, et ce même lorsque seulement deux images sont utilisées.

Mots-clés: reconstruction 3D, fémur, apprentissage profond, imagerie multivues, recalage, EOS, déformation 3D

Automatic 3D deformation of the femur based on an arbitrary number of calibrated EOS images

Francis TOUPIN

ABSTRACT

3D reconstruction of the femur is useful for orthopedic surgeons in order to plan their surgery as well as the type of implants to be used. In partnership with the company EOS Imaging, we will use their calibrated biplane X-ray images in order to propose a precise 3D reconstruction method of the femur allowing for an arbitrary number of calibrated EOS images to be used. This research project's objective is to replace the semi-automatic 3D reconstruction method currently used in EOS Imaging's commercial platform, SterEOS. Our review of the literature has shown that the 3D reconstruction algorithms currently used in bone reconstruction from x-ray images are mainly based on non-rigid 3D/2D registration algorithms. These methods, although robust and accurate, have several limitations and are complex to use. It is in this perspective that we propose a 3D deformation method using Pixel2Mesh++, a deep learning algorithm performing a dense deformation on a generic model. Our experiments focus on the use of a pair of DRR where the femur is seen from the face and the side view as well as on the impact of using additional radiographs in the reconstruction process and show that our method makes it possible to obtain a very precise 3D reconstruction, even when a single acquisition is used.

Keywords: 3D reconstruction, femur, deep learning, multiview imaging, registration, EOS, 3D deformation

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 CONTEXTE	5
1.1 Anatomie du fémur et paramètres cliniques	5
1.2 La cabine et les radiographies EOS	9
1.3 Méthode de reconstruction 3D du fémur utilisée dans SterEOS	13
1.4 Conclusion	19
CHAPITRE 2 REVUE DE LA LITTÉRATURE	21
2.1 Représentations du modèle 3D	22
2.2 Reconstruction 3D par recalage 3D/2D non rigide	24
2.2.1 Modèle statistique de forme	25
2.2.2 Modèle statistique de forme et d'intensité	31
2.2.3 Autres méthodes	37
2.2.4 Conclusion	42
2.3 Reconstruction 3D par apprentissage profond	43
2.3.1 Reconstruction 3D par estimation de déformation 3D	46
2.3.2 Reconstruction 3D sans modèle initial	50
2.3.3 Conclusions	52
2.4 Nombre et points de vue utilisés	54
2.4.1 Impact de la pose dans l'image	54
2.4.2 Impact du nombre d'images utilisées	56
2.5 Évaluation des méthodes de reconstruction 3D	59
2.6 Conclusions	61
CHAPITRE 3 PROBLÉMATIQUES, OBJECTIFS ET PROPOSITIONS MÉTHODOLOGIQUES	65
CHAPITRE 4 MÉTHODOLOGIE	71
4.1 Modifications appliquée à Pixel2Mesh++	71
4.2 Description des données utilisées	74
4.2.1 Extraction de la pose et de l'échelle	74
4.2.2 Génération des DRR	77
4.2.3 DRR depuis plusieurs points de vue	77
4.2.4 Préparation à l'entraînement	82
4.3 Recherche des valeurs d'hyperparamètres	83
4.4 Entraînement du réseau de neurones	86
4.5 Validation de la méthode	87
4.5.1 Reconstruction avec les DRR face/profil	87
4.5.2 Reconstruction multi vues	87

4.5.3	Impact des points de vue choisi	89
CHAPITRE 5 RÉSULTATS ET DISCUSSION		91
5.1	Entraînement du modèle	91
5.2	Reconstruction avec les DRR face/profil	93
5.2.1	Résultats qualitatifs	93
5.2.2	Erreurs avant/après la déformation	94
5.2.3	Régions avec les erreurs les plus importantes	96
5.2.4	Reconstruction à partir de radiographies EOS	101
5.2.5	Précision des paramètres cliniques	103
5.3	Reconstruction multivues	106
5.4	Impact des points de vue choisis	108
5.4.1	Impact des rotations individuelles par axe	109
5.4.2	Meilleures configurations de points de vue	110
5.5	Discussion générale	111
CONCLUSION ET RECOMMANDATIONS		115
6.1	Recommandations	116
ANNEXE I	RECALAGE GÉOMÉTRIQUE À L'AIDE D'UN MODÈLE STA- TISTIQUE DE FORME	119
ANNEXE II	REVUE APPROFONDIE DES MÉTHODES DE RECONSTRUC- TION 3D PAR APPRENTISSAGE SANS MODÈLE INITIAL	121
ANNEXE III	DÉTAILS DU FONCTIONNEMENT DE PIXEL2MESH++	123
BIBLIOGRAPHIE		133

LISTE DES TABLEAUX

	Page
Tableau 2.1	Méthodes de reconstruction 3D par recalage avec SSM 30
Tableau 2.2	Méthodes de reconstruction 3D par recalage avec SSIM 36
Tableau 2.3	Méthodes de reconstruction 3D par recalage n'utilisant pas de SSM ou de SSIM 41
Tableau 2.4	Erreurs des méthodes de reconstruction 3D multivues en fonction du nombre de vues utilisées 57
Tableau 4.1	Hyperparamètres de Pixel2Mesh++ avec les intervalles de recherche proposés à Hyperband 86
Tableau 5.1	Hyperparamètres optimaux obtenus pour l'entraînement 92
Tableau 5.2	Statistiques des erreurs post-déformation lorsque la position face/profil est utilisée 95
Tableau 5.3	Comparaison des erreurs (moy. signées et 2*écarts-types) pour les paramètres cliniques étudiés entre notre méthode et celle de Chaibi (2010) 105
Tableau 5.4	Impact sur l'erreur P2S moyenne (mm) des rotations individuelles. Les meilleures erreurs sont en gras 110
Tableau 5.5	Amélioration des erreurs P2S moyenne et SHD moyenne sur le fémur global lorsque les meilleures configurations d'acquisitions sont utilisées 111
Tableau 5.6	Comparaison des erreurs avec la littérature en fonction de la région du fémur reconstruite, lorsque les radiographies face/profil sont utilisées 113

LISTE DES FIGURES

	Page
Figure 0.1	Méthode de reconstruction 3D de SterEOS 3
Figure 1.1	Anatomie du fémur avec régions 6
Figure 1.2	Paramètres cliniques du fémur 8
Figure 1.3	Système de coordonnées de référence pour le système EOS 9
Figure 1.4	Radiographies EOS et la géométrie épipolaire 11
Figure 1.5	Vue rapprochée du pelvis 12
Figure 1.6	Processus de reconstruction actuel du fémur dans SterEOS 13
Figure 1.7	Déplacement et mise à l'échelle d'un point de contrôle MLS 15
Figure 1.8	Reconstruction du fémur proximal avec la méthode de Chaibi (2010) 17
Figure 1.9	Reconstruction du fémur distal avec la méthode de Chaibi (2010) 18
Figure 2.1	Représentation d'un maillage 3D 22
Figure 2.2	Représentation d'une grille de voxels 23
Figure 2.3	Processus de recalage généralisé 24
Figure 2.4	Exemple d'utilisation du filtre de Canny sur radiographies EOS 27
Figure 2.5	Processus de génération de DRR 32
Figure 2.6	Génération de DRR depuis un maillage 3D 33
Figure 2.7	Processus généralisé de l'apprentissage machine supervisé 44
Figure 2.8	Processus du CNN 45
Figure 2.9	Processus du GCN 45
Figure 2.10	Résultats qualitatifs Pixel2Mesh++ 49
Figure 2.12	CycleGAN appliqué d'une radiographie à une DRR 51

Figure 2.13	Impact de la prise de vues de deux radiographies sur la reconstruction 3D	55
Figure 2.14	Détails du calcul de l'erreur P2S	60
Figure 4.1	Architecture de Pixel2Mesh++	71
Figure 4.2	Architecture proposée	72
Figure 4.3	Modèle générique régionalisé de notre algorithme	73
Figure 4.4	Positionnement du modèle générique dans le référentiel EOS	75
Figure 4.5	DRR générée depuis un modèle surfacique de fémur	78
Figure 4.7	Triplets de rotations identiques	81
Figure 4.8	Exemples de points de vue de DRR pour un fémur	81
Figure 4.9	Rognage automatique des DRR	83
Figure 4.10	Méthode Hyperband	85
Figure 5.1	Courbes d'apprentissage de l'algorithme	92
Figure 5.2	Exemples de reconstructions 3D obtenues par Pixel2Mesh++	93
Figure 5.3	Erreurs avant/après déformation avec les DRR en position face/profil	94
Figure 5.4	Carte d'erreur maximale des reconstructions avec une paire de DRR	96
Figure 5.6	Courbure naturelle du grand trochanter	98
Figure 5.7	Erreurs petit trochanter	99
Figure 5.8	Problèmes de visibilité du petit trochanter dans les DRR	100
Figure 5.9	Comparaison de la reconstruction 3D avec deux radiographies EOS vs. deux DRR	102
Figure 5.10	Bland-Altman de la torsion fémorale	103
Figure 5.11	Bland-Altman de l'angle anatomique/mécanique	104
Figure 5.12	Bland-Altman de l'angle cervico-diaphysaire	104
Figure 5.13	Évolution de l'erreur en fonction du nombre de points de vue	106

Figure 5.14	Reconstruction dégradée avec points de vue orthogonaux	107
Figure 5.15	Cartes d'erreurs moyennes par point de vue avec une paire de DRR	109

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

DRR	Radiographie simulée
CT Scan	Tomodensitométrie assistée par ordinateur
CBCT	Tomodensitométrie assistée par ordinateur à faisceaux coniques
TF	Torsion Fémorale
HKS	Angle anatomique/mécanique du fémur
NSA	Angle cervico-diaphysaire
SSM	Modèle statistique de forme
SSIM	Modèle statistique de forme et d'intensité
ACP	Analyse en composantes principales
SHD	Distance symétrique de Hausdorff
SCD	Distance symétrique de Chamfer
P2S	Distance points à surface
ASD	Distance surfacique moyenne
IoU	Intersection sur union
ICP	Point le plus près itératif
MLS	Moindres carrés mobiles
FFD	Déformation de forme libre
SDM	Modèle de déformation statistique
NCC	Corrélation croisée normalisée
MI	Information mutuelle
CNN	Réseau de neurones à convolution
GCN	Réseau de neurones à convolution sur les graphes
RNN	Réseau de neurones récurrent
GAN	Réseau antagoniste génératif

INTRODUCTION

L'analyse en 3D du fémur permet entre autres de faire l'analyse de la cinématique du genou (Baka *et al.*, 2012), de diagnostiquer plusieurs pathologies du membre inférieur (Chaibi, 2010) et de mieux planifier la pose d'implants et des chirurgies et de les guider lors de ces dernières (Laporte, Skalli, De Guise, Lavaste & Mitton, 2003; Cresson, Branchaud, Chav, Godbout & de Guise, 2010; Baka *et al.*, 2011). La tomodensitométrie assistée par ordinateur (CT scan) peut être utilisée afin d'obtenir une image 3D des os d'un patient, mais il est aussi possible de procéder à une reconstruction 3D d'os à partir de radiographies (Melhem, Assi, El Rachkidi & Ghanem, 2016). Comme le CT scan est de 200 à 2000 fois plus irradiant qu'une radiographie (Mettler, Huda, Yoshizumi & Mahesh, 2008), il n'est pas souhaitable de soumettre les patients à ces acquisitions régulièrement.

Notre partenaire industriel de recherche, EOS Imaging, a mis au point une cabine de radiographies qui permet l'acquisition simultanée de deux radiographies orthogonales calibrées où le patient est en position debout. C'est un avantage comparativement au CT scan où le patient est en position couchée, car la position du patient joue un rôle important sur le calcul de paramètres cliniques utilisés par les chirurgiens (Hasegawa, Okamoto, Hatsushikano, Caseiro & Watanabe, 2018). Grâce au logiciel commercial accompagnant la cabine EOS, SterEOS, il est possible de créer des modèles 3D du rachis, du pelvis et des membres inférieurs à partir de ces radiographies (Wybier & Bossard, 2013). De ces modèles peuvent être extraits des distances, des angles et des paramètres cliniques autrement difficiles à obtenir avec des radiographies conventionnelles (Huang *et al.*, 2020).

La méthode de reconstruction 3D actuelle du fémur dans le logiciel SterEOS est une méthode semi-automatique, où un opérateur formé en imagerie médicale doit identifier et manipuler des points clés superposés aux radiographies afin de déformer un modèle 3D de fémur dont les contours sont projetés dans les images. L'objectif est de faire correspondre les contours projetés

du modèle 3D aux contours visibles du fémur du patient dans les radiographies. La méthode existante (Chaibi, 2010), dont le résultat est présenté à la figure 0.1, a été développée afin d'être relativement rapide à exécuter par l'opérateur et pour calculer des paramètres cliniques sur le fémur reconstruit (Chaibi, 2010). Cette méthode possède deux limitations majeures. Premièrement, elle est semi-automatique et le temps de reconstruction par l'opérateur est de cinq minutes par membre inférieur, ce qui en limite son utilisation clinique. Deuxièmement, elle ne s'appuie que sur la superposition des contours des membres inférieurs reconstruits en 3D sur les contours, souvent bruités, des os dans les radiographies, qui sont en 2D, ce qui limite l'information utilisée pour procéder à la reconstruction (Chaibi, 2010).

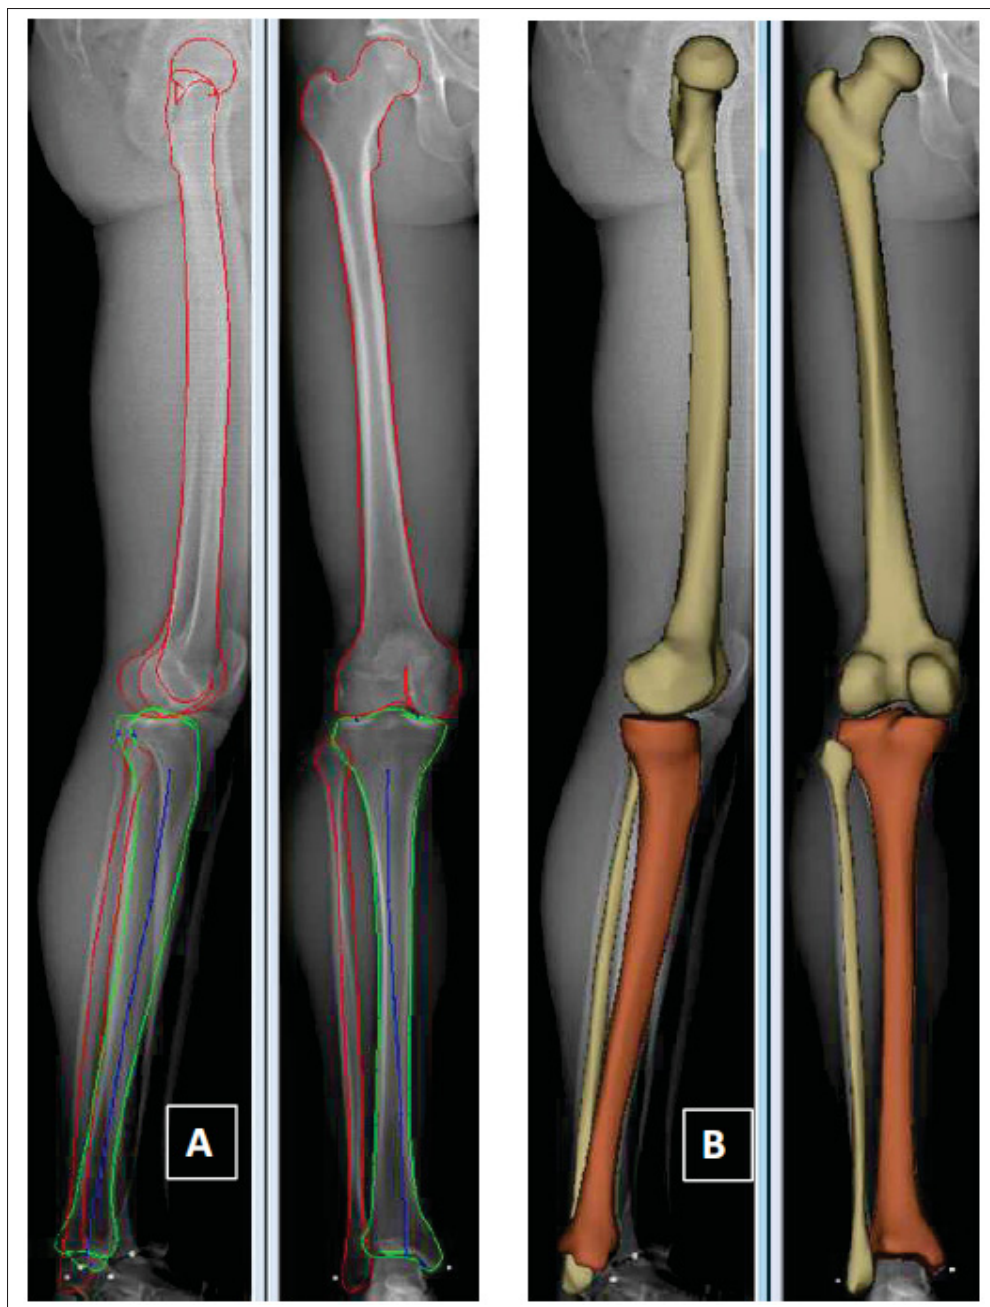


Figure 0.1 Méthode de reconstruction 3D des membres inférieurs
de SterEOS
Tirée de Chaibi (2010)

Le but de notre projet de recherche est de proposer une nouvelle méthode de reconstruction du fémur en 3D qui permettra de compenser les faiblesses de la méthode actuelle (la reconstruction

semi-automatique basée sur les contours) ainsi que de celles qui seront étudiées à la section 1.3. Notre projet de recherche porte aussi sur l'impact du nombre de radiographies EOS utilisées et de la pose du fémur dans la cabine EOS lors de l'acquisition. La pose du fémur se définit par la position du fémur du patient dans l'espace lorsque l'acquisition EOS a été faite. Dépendamment de la pose du fémur, différentes informations sont visibles dans les radiographies. Il arrive, dans certains cas, qu'un patient ait plusieurs radiographies EOS et s'il est possible d'utiliser l'ensemble de ces radiographies lors de la reconstruction, il serait possible d'améliorer la précision de la forme du modèle 3D reconstruit (Baka *et al.*, 2012; Kanhonou, 2017).

Ce mémoire est divisé en cinq chapitres. Le chapitre 1 permettra d'abord d'établir le contexte du projet de recherche. Dans le chapitre 2, nous effectuerons une revue de la littérature portant sur les méthodes de reconstruction 3D. Suite à cette revue, nous poserons, dans le chapitre 3, les objectifs spécifiques du projet de recherche et nous présenterons une proposition méthodologique servant à répondre à ces derniers. Le chapitre 4 servira à décrire la méthodologie utilisée pour mettre en place notre méthode de reconstruction 3D du fémur ainsi qu'à présenter la méthode de validation. Le chapitre 5 présentera les résultats obtenus ainsi qu'une discussion. Finalement, une conclusion du mémoire sera présentée où les différents constats trouvés lors de ce projet seront résumés et où des recommandations seront faites pour l'avenir.

CHAPITRE 1

CONTEXTE

L'objectif de cette section est de mettre en place le contexte du projet de recherche. D'abord, l'anatomie du fémur et les paramètres cliniques associés seront présentés. Ensuite, le système EOS et les radiographies qui en sont produites seront présentés de manière à exposer les avantages des radiographies calibrées EOS pour la reconstruction 3D, mais aussi pour expliquer les difficultés présentes à modéliser une structure osseuse en 3D à partir de radiographies. La méthode de reconstruction 3D du fémur utilisée dans SterEOS sera présentée de manière à identifier les forces et les faiblesses de cette dernière. La conclusion de ce chapitre permettra de résumer le contexte dans lequel s'effectue notre projet de recherche.

1.1 Anatomie du fémur et paramètres cliniques

La figure 1.1 présente l'anatomie du fémur. Le fémur est composé de trois régions principales : la région proximale, qui englobe le haut du fémur jusqu'au début de la diaphyse, la diaphyse elle-même, qui représente la plus longue section du fémur, et la région distale, qui est constituée de deux condyles qui s'appuient sur le plateau tibial. Le fémur proximal interagit avec le pelvis alors que la région distale interagit avec le tibia et la rotule.

Les paramètres cliniques du fémur qui seront évalués dans ce mémoire sont : la torsion fémorale (voir figure 1.2a), l'angle cervico-diaphysaire (voir figure 1.2b) et l'angle entre l'axe mécanique et anatomique du fémur (HKS) (voir figure 1.2c). Ces trois paramètres cliniques sont des angles et sont présentés avec les axes utilisés pour les calculer à la figure 1.2. Il est possible de calculer ces paramètres cliniques en 2D directement depuis les radiographies, mais les mesures obtenues sont beaucoup moins précises que lorsqu'elles sont calculées à l'aide de la modélisation 3D obtenue à l'aide du logiciel SterEOS (Guenoun, Zadegan, Aim, Hannouche & Nizard, 2012; Melhem *et al.*, 2016).

La torsion fémorale (TF) est définie comme étant l'angle entre l'axe bicondylien et l'axe du col fémoral, tous deux projetés sur le plan orthogonal à l'axe diaphysaire (Chaibi, 2010). Ce

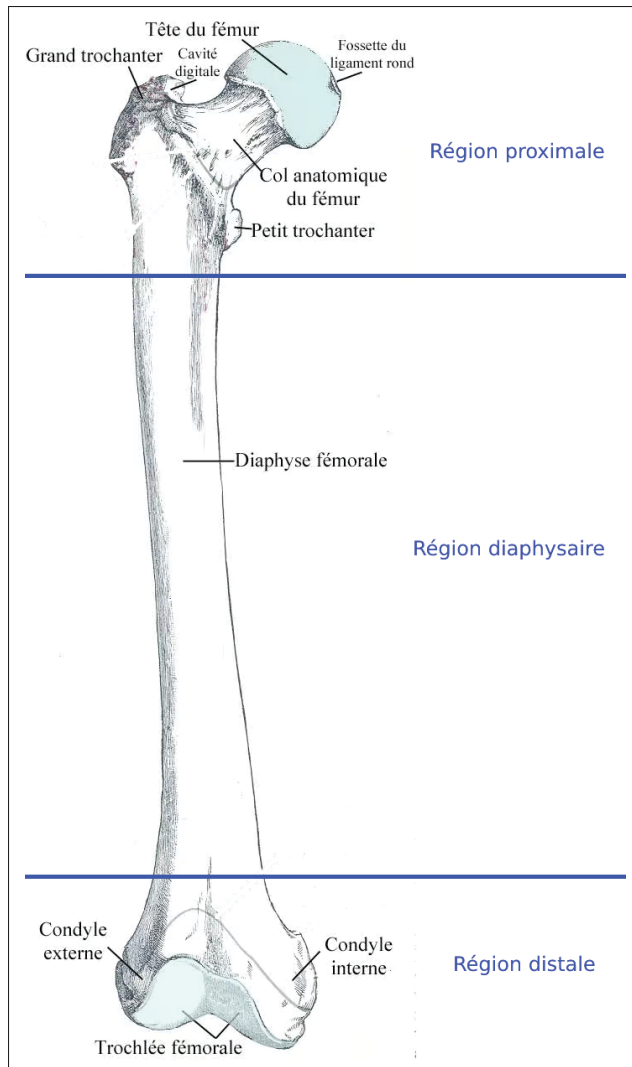


Figure 1.1 Anatomie du fémur
Modifiée de ©Bérichard, Wikimedia,
CC by-sa 3.0

paramètre clinique est difficile à obtenir à partir d'un CT scan, dû au fait qu'une seule coupe du CT ne peut pas bien représenter l'axe bicondylien (Chaibi, 2010). Par contre, il est possible d'extraire cet axe en 3D facilement d'un modèle 3D de fémur (Chaibi, 2010). La figure 1.2a présente l'axe bicondylien et l'axe du col fémoral. L'axe bicondylien passe par l'extrémité arrière des deux condyles tandis que l'axe du col fémoral passe quant à lui par le centre de la tête fémorale et le centre de la limite inférieure du col fémoral. Cette torsion représente un angle moyen de 15 degrés chez les adultes (Chaibi, 2010).

L'angle cervico-diaphysaire (ACD), présenté dans la figure 1.2b, est l'angle entre l'axe du col fémoral et l'axe diaphysaire. L'axe diaphysaire passe par le centre de la diaphyse et par le centre la section supérieure de la diaphyse. Chaibi (2010) notent que les manières de représenter l'axe diaphysaire peuvent toutefois différer dans la littérature. En fonction de ces différentes manières de représenter cet axe, l'ACD moyen est d'environ 130 degrés (Chaibi, 2010).

Enfin, l'angle entre l'axe mécanique du fémur et l'axe diaphysaire (HKS), aussi appelé axe anatomique, est présenté dans la figure 1.2c. L'axe mécanique du fémur passe par le centre de la tête fémorale et par le centre des condyles au niveau de la trochlée. L'angle moyen est d'environ 6 degrés (Chaibi, 2010).

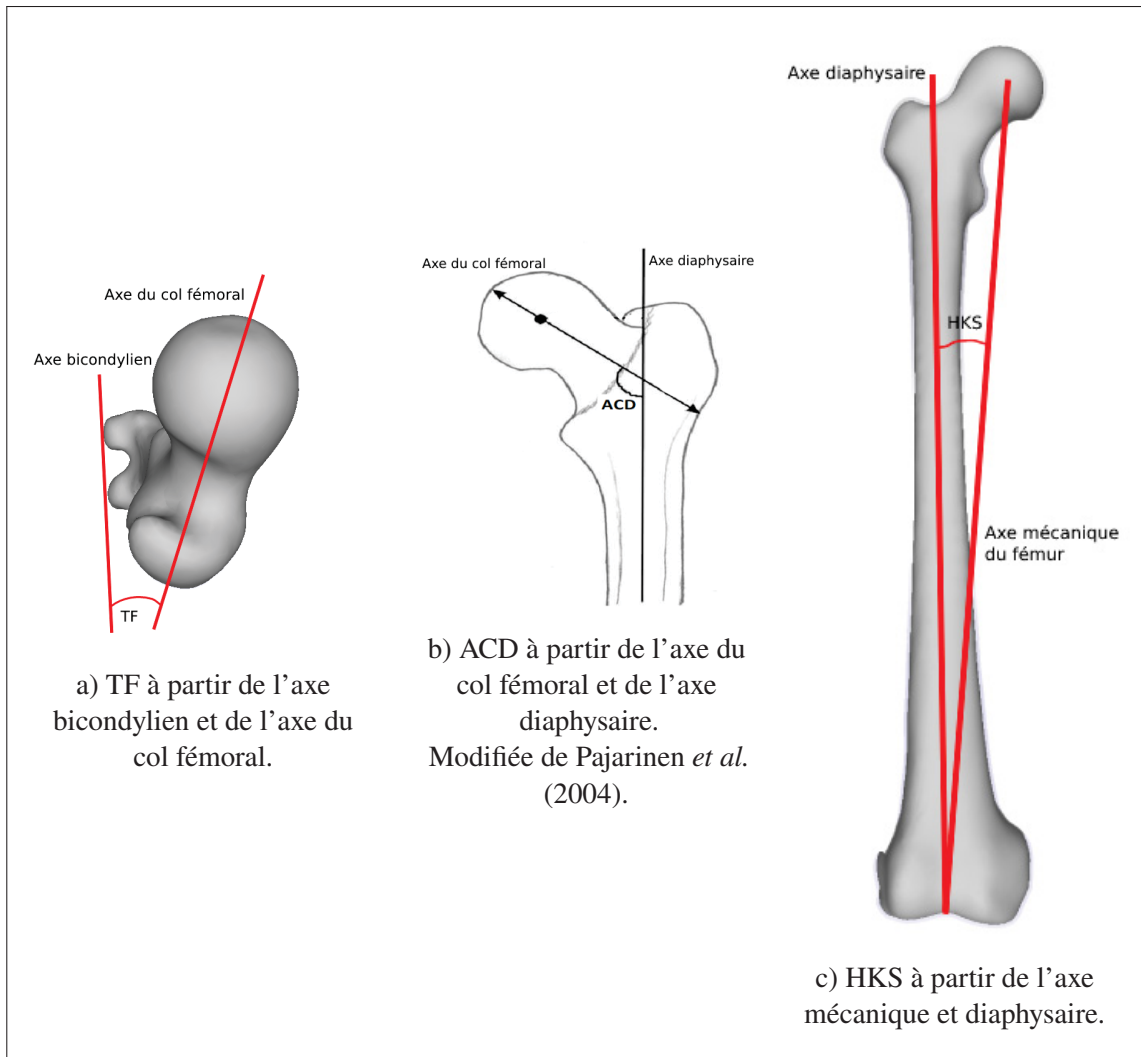


Figure 1.2 Les différents axes du fémur utilisés pour calculer la torsion fémorale (à gauche), l'angle cervico-diaphysaire (au centre) et l'angle HKS (à droite)

1.2 La cabine et les radiographies EOS

La cabine EOS permet d'obtenir deux radiographies orthogonales calibrées du corps entier avec une très haute résolution (254 μ m) et avec 65,536 tons de gris (Dubousset *et al.*, 2005). Basées sur les travaux de Georges Charpak, les radiographies acquises à l'aide de la cabine EOS sont de 8 à 10 fois moins irradiantes que des radiographies biplanes conventionnelles (Dubousset *et al.*, 2005), faisant en sorte qu'elles peuvent être obtenues avec moins de dangers pour les patients. La figure 1.3 présente la cabine EOS ainsi que son système de coordonnées. On retrouve l'axe coronal en X (rouge dans la figure), l'axe sagittal en Y (vert) et l'axe transversal en Z (bleu).



Figure 1.3 Système de coordonnées de référence pour le système EOS. On y retrouve l'axe transversal Z, en bleu ; l'axe sagittal Y, en vert ; et l'axe coronal X, en rouge. L'image de la cabine EOS est obtenue de EOS Imaging

La calibration des radiographies EOS est un aspect essentiel à la reconstruction 3D à partir de ces dernières. C'est grâce à ces paramètres de calibration qu'il est possible d'établir une relation

entre un point 2D et une droite de projection dans le monde réel en 3D. Cette caractéristique nous permet d'effectuer la stéréo correspondance entre des points présents dans les deux images. Comme les deux émetteurs de rayons X de la cabine EOS sont installés de manière perpendiculaire et que les paramètres de calibration intrinsèques sont connus, il est possible de retrouver dans la radiographie latérale une droite $f(x_l, y_l)$, la droite épipolaire d'un point (x_f, y_f) , sur laquelle se trouve nécessairement un point dans la radiographie frontale (Groisser, 2019) (voir figure 1.4). Il en est de même pour un point dans la radiographie latérale. Comme les émetteurs de rayons X se trouvent sur des rails qui se déplacent à la même vitesse et qui se trouvent donc à la même hauteur en tout temps, cette droite épipolaire dans l'espace 2D est d'équation $(0 * x_l) + 1 * y_l - x_f = 0$, c'est-à-dire qu'elle est d'inclinaison 0 et qu'elle possède la même coordonnée en Y que son point correspondant dans l'autre image. Comme on peut le voir à la figure 1.4, cette droite épipolaire peut être utilisée pour retrouver la coordonnée 3D d'un point identifié dans les deux radiographies.

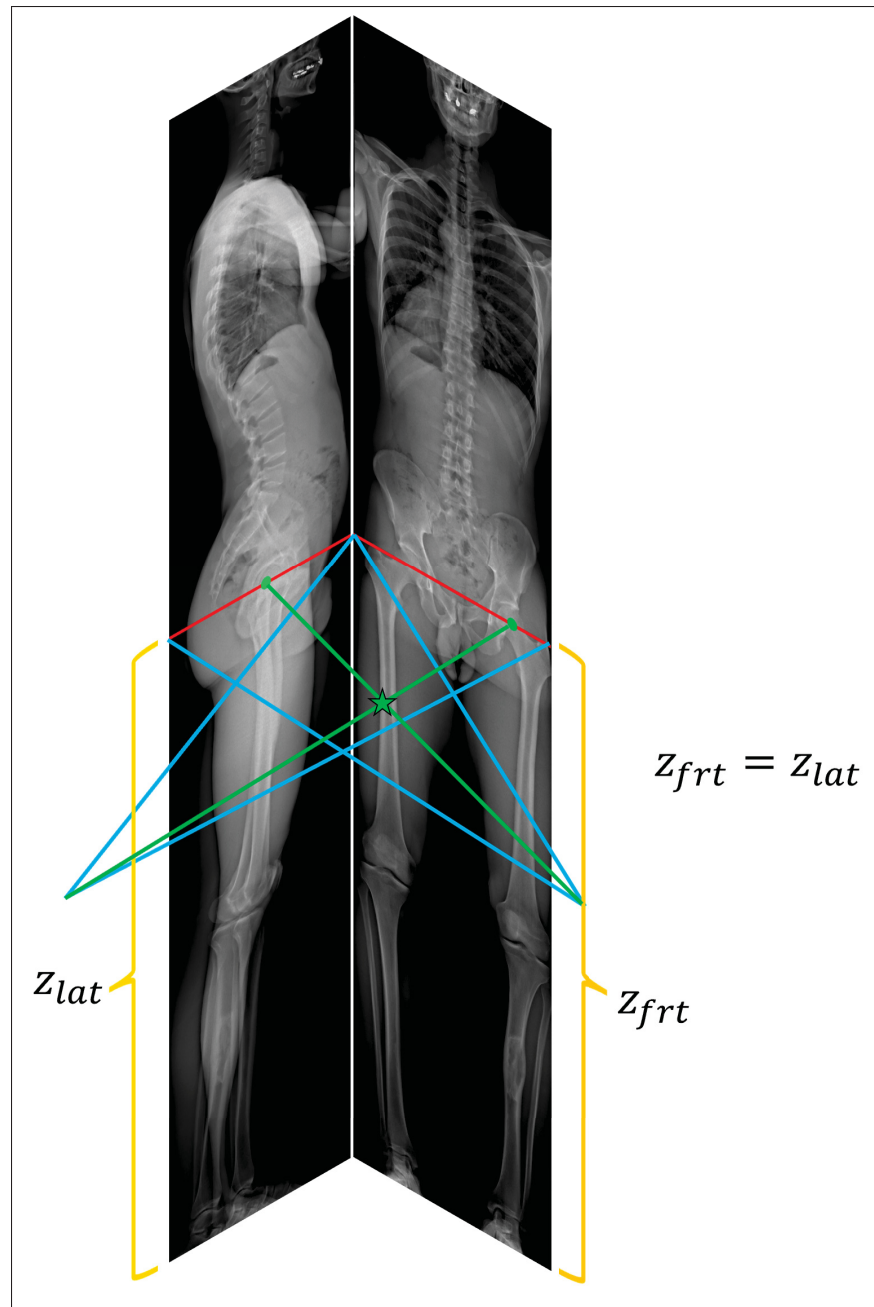


Figure 1.4 Radiographies EOS du corps entier en position frontal/latéral avec la géométrie épipolaire. Pour le centre de la tête fémorale illustré en vert dans les deux radiographies, les lignes épipolaires partagent la même hauteur. Cela fait en sorte que la coordonnée 3D du centre de la tête fémorale (l'étoile verte dans l'image) peut être retrouvée à l'intersection des deux droites de projection issues des radiographies frontale et latérale

Malgré la haute résolution et la grande plage dynamique des images EOS (Dubousset *et al.*, 2005), la reconstruction 3D automatique du fémur à partir de radiographies EOS présente de grands défis liés d'abord au fait qu'il n'y a pas toute l'information nécessaire en 2D pour procéder facilement à la reconstruction (Goswami & Kr., 2015). La nature des images radiographiques est aussi une source de défis. Comme le montre la figure 1.5, la superposition des deux fémurs dans la radiographie latérale, en plus de la superposition du pelvis dans la région proximale, complique la tâche de différencier chaque fémur. Les radiographies sont bruitées à cause de la dispersion des rayons X lorsqu'ils rencontrent différentes structures et aux artefacts possiblement présents dans le corps inspecté (Manson *et al.*, 2019). Ce bruit fait en sorte qu'il est difficile de distinguer les contours de l'os dans les images, mais aussi d'utiliser les intensités de pixels dans les images pour procéder à la reconstruction 3D (Baka *et al.*, 2012).

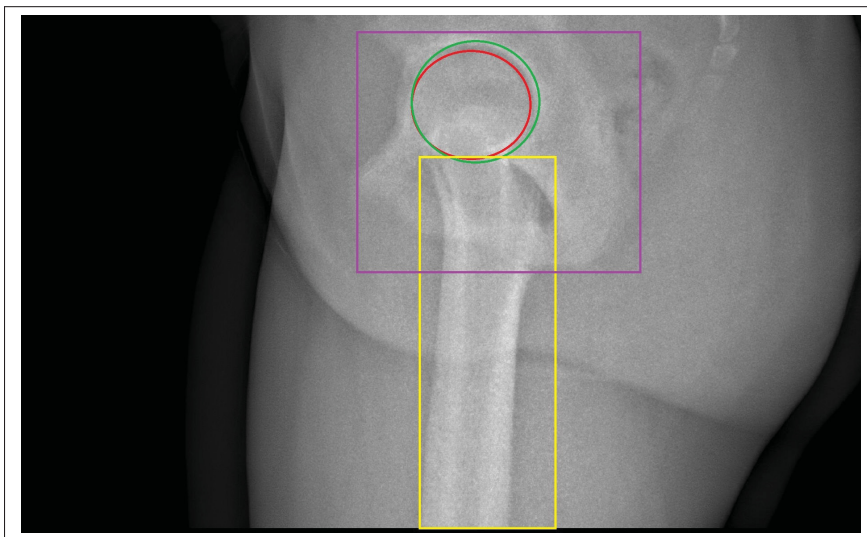


Figure 1.5 Vue rapprochée du pelvis permettant de voir la faible visibilité des fémurs en vue latérale dans la région du pelvis. On peut voir les deux têtes fémorales en vert et en rouge qui sont distinguables seulement à cause de l'effet de perspective. Les diaphyses des deux fémurs, en jaune, sont, à notre avis, pratiquement impossibles à distinguer dans cette vue. De plus, le pelvis, dans la boîte mauve, diminue la visibilité des deux fémurs

1.3 Méthode de reconstruction 3D du fémur utilisée dans SterEOS

La méthode de reconstruction actuellement utilisée dans la plateforme commerciale SterEOS est une méthode semi-automatique qui nécessite un opérateur formé et possédant de l'expérience en imagerie médicale. Cette méthode s'appuie sur la déformation par l'utilisateur d'un modèle générique, dans l'objectif de faire correspondre au mieux les contours projetés du modèle 3D aux contours du fémur dans les radiographies frontale et latérale du patient, comme on peut le voir dans la figure 1.6c. Le modèle 3D est déformé grâce à la méthode Moving Least Squares (MLS) (Zhu & Gortler, 2007). Cette méthode permet de déformer un modèle 3D générique de fémur en déplaçant les sommets d'un maillage 3D en fonction de leur proximité à un ensemble de points de contrôle (numérotés dans la figure 1.6) manipulés par l'opérateur (Cresson *et al.*, 2010).

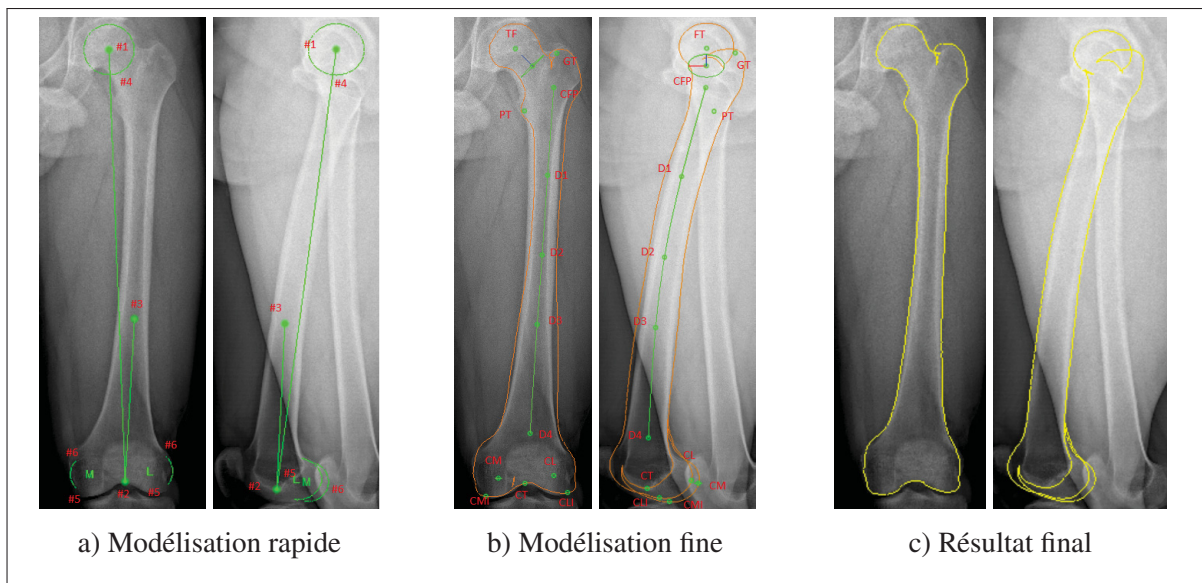


Figure 1.6 Processus en trois étapes de reconstruction du fémur dans SterEOS. À l'étape de modélisation rapide, seulement trois points sont visibles. À l'étape de modélisation fine, il est possible de déplacer davantage de points et leur déplacement affecte la projection du contour en orange. Lorsque la modélisation est terminée, les contours du modèle 3D apparaissent en jaune

La reconstruction du fémur s'effectue en deux étapes (Figure 1.6) : la modélisation rapide et la modélisation fine (Chaibi, 2010). Pour la modélisation rapide, l'opérateur doit identifier dans les

radiographies frontale et latérale cinq points et trois rayons : le centre de la tête fémorale (#1), le centre de la trochlée (#2), le centre du premier tiers du bas de la diaphyse (#3), le rayon de la tête fémorale (#4), les centres des condyles (#5) et le rayon de ces derniers (#6) (voir figure 1.6a). La position du modèle générique 3D dans les radiographies est ensuite déterminée et le modèle subit une transformation de pose ainsi qu'une déformation MLS de manière à le positionner dans les radiographies sans nécessairement faire correspondre parfaitement les contours.

Dès cette étape, des défis se présentent. Dans la radiographie latérale, comme nous l'avons vu à la figure 1.5, l'identification de la tête fémorale et de son rayon est complexe puisque les deux têtes fémorales sont pratiquement superposées et que le pelvis se trouve entre les deux. La superposition des structures ainsi que l'épaisseur d'os traversée par les rayons X font en sorte que le contraste est peu élevé dans cette région de la radiographie. Il est parfois difficile, même pour les experts en imagerie médicale formés avec cette méthode de reconstruction 3D, de savoir quels contours appartiennent au fémur droit ou au fémur gauche.

Après la modélisation rapide, le modèle 3D est initialisé et ses contours sont projetés sur les radiographies frontale et latérale (voir figure 1.6b). La phase de modélisation fine peut commencer. Huit nouveaux points de contrôle appartenant au fémur sont projetés sur les deux radiographies, permettant de déformer le modèle 3D avec plus de précision. Ces points, identifiés à la figure 1.6b, sont, de haut en bas, le centre du grand trochanter (GT), le centre du fémur proximal (CFP), le centre du petit trochanter (PT), trois points répartis sur la diaphyse (D1, D2, D4) et les extrémités inférieures de chacun des deux condyles (CMI, CLI). Dans cette phase, l'opérateur ajustera la position (voir figure 1.7a) et l'échelle locale (voir figure 1.7b) de chaque point de contrôle, ce qui engendrera une déformation MLS. Les treize points peuvent être ainsi déplacés afin d'optimiser la correspondance entre les contours projetés du modèle 3D et de ceux du fémur dans la radiographie. À la fin de cette étape de modélisation fine, la superposition des contours du modèle 3D devrait être optimale avec ceux du fémur dans les radiographies (voir figure 1.6c).

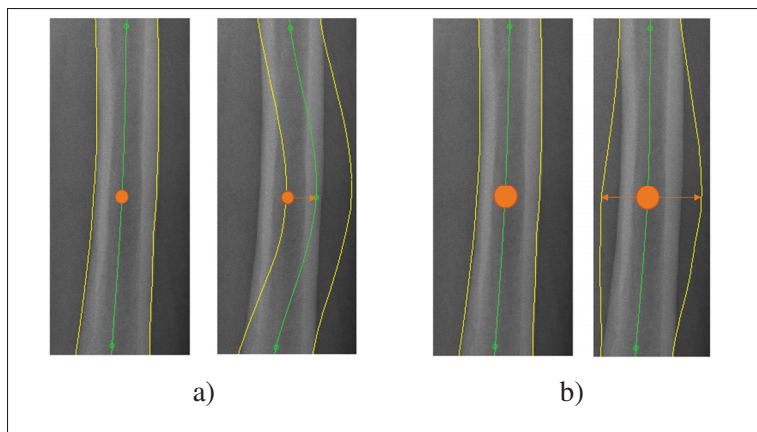


Figure 1.7 Déplacement (a) et mise à l'échelle (b) d'un point MLS de la diaphyse du fémur

La reconstruction 3D proposée par cette méthode possède plusieurs avantages : la modélisation est relativement rapide (environ 5 minutes par membre inférieur pour un opérateur expérimenté (Chaibi, 2010)), il est possible de réajuster le modèle au fil du processus, la méthode de déformation est intuitive et les paramètres cliniques obtenus à l'aide de cette méthode sont fiables et reproductibles (Melhem *et al.*, 2016). Évaluée sur 11 fémurs secs avec deux radiographies EOS et un CT scan segmenté par fémur, la méthode permet d'obtenir une erreur point à surface moyenne (P2S moy.) de 1mm, une erreur Root Mean Squared (RMS)(95%) de 2.4mm et une erreur maximale de 6.6mm (Chaibi, 2010). Les paramètres cliniques obtenus à l'aide de cette méthode sont suffisamment près des paramètres obtenus à l'aide du CT scan pour être utilisables en clinique (Melhem *et al.*, 2016). Guenoun *et al.* (2012) étudient la répétabilité intra- et inter-opérateurs de l'estimation des paramètres cliniques depuis les modélisations 3D obtenues à l'aide de la méthode de Chaibi (2010) en comparant deux reconstructions 3D de deux opérateurs différents pour la répétabilité inter opérateurs et du même opérateur pour la reproductibilité intra-opérateur. Pour la répétabilité inter opérateurs, les coefficients de corrélation linéaire entre les paramètres cliniques HKS, HKA et NSA obtenus de reconstructions de deux opérateurs différents sont respectivement de 89.4%, 99.3% et 76.5% et les différences moyennes d'angle pour ces trois paramètres sont de 0.51°, 0.49° et 2.93°. La répétabilité intra-opérateur est de 87.6%, 99.4% et 84.5% pour les trois mêmes paramètres. Guenoun *et al.* (2012) indiquent

que ces valeurs de répétabilité sont excellentes et qu'elles sont meilleures que les valeurs obtenues lorsque les radiologistes obtiennent ces paramètres cliniques directement à partir de radiographies. Les auteurs indiquent ne pas avoir été en mesure de comparer les paramètres cliniques obtenus à l'aide de la méthode de Chaibi (2010) à ceux obtenus à l'aide de CT scans, ce qui aurait été plus intéressant considérant que la méthode de reconstruction 3D se veut un remplacement au CT scan lorsque possible. Tout de même, les valeurs représentant la répétabilité par Guenoun *et al.* (2012) nous semblent excellentes, surtout en considérant les différences moyennes d'angle qui sont très basses (la valeur de 2.93° étant la plus haute est associée à l'angle cervico-diaphysaire, dont la valeur moyenne est d'environ 130° (Chaibi, 2010)).

Cette méthode a été développée dans l'optique de calculer des paramètres cliniques avec précision et de manière à ce qu'ils soient répétables intra- et inter opérateurs, mais n'obtient pas nécessairement une reconstruction 3D précise de la géométrie de l'os (Chaibi, 2010). Un petit ensemble de points de contrôle guide l'ensemble de la déformation, nous pouvons donc dire que cette méthode a un petit nombre de degrés de liberté. Le nombre de degrés de liberté, dans notre contexte, se définit par le nombre de paramètres qui contrôlent la déformation appliquée au modèle générique de fémur (Sotiras, Davatzikos & Paragios, 2013). La figure 1.8 présente les contours du modèle 3D suivant la modélisation fine sur le fémur proximal présent dans les radiographies.

Comme chacun des deux trochanters n'est déformé que par un point de contrôle, la déformation appliquée à chacune de ces régions fait en sorte qu'il est difficile, voire parfois impossible, de superposer les contours si ces derniers n'ont pas une forme similaire à ceux du modèle générique. Cette limitation s'applique aussi à l'ensemble des régions du fémur : certaines régions comme la diaphyse sont plus simples à représenter avec un petit nombre de degrés de liberté, mais il n'en reste pas moins que la déformation y est limitée par le nombre de points de contrôle. Un autre bon exemple est la déformation de la tête fémorale. Comme il n'y a qu'une seule poignée de contrôle au centre de la tête fémorale, seuls le rayon et le centre de la tête fémorale peuvent être modifiés par l'opérateur. La fovéa, une région creuse de la tête fémorale où s'insère le ligament de la tête fémorale, ne peut pas être représentée précisément par cette méthode. Il serait possible d'ajouter




Figure 1.8 Reconstruction du fémur proximal avec la méthode de Chaibi (2010).
 À gauche, les contours du modèle 3D avant déformation. À droite, après
 l'ajustement de la position et de l'échelle

des points de contrôle et donc d'augmenter le nombre de degrés de liberté dans les régions où les déformations doivent être plus précises, mais cet ajout compliquerait la déformation par l'opérateur et augmenterait le temps de reconstruction (Cresson *et al.*, 2010). De plus, pour une région complexe comme celle du grand trochanter, la superposition des contours frontal et latéral n'indique pas nécessairement que la forme de ce dernier est correctement reconstruite par l'algorithme puisque le grand trochanter peut se superposer à lui-même à cause de sa forme non convexe.

La reconstruction du fémur distal est aussi complexe dû au positionnement des poignées et à la superposition des deux condyles dans la vue latérale. La figure 1.9 présente une reconstruction 3D du fémur distal produite à l'aide de la modélisation fine de Chaibi (2010) projetée sur deux radiographies EOS. Les points rouges sont les points de contrôle postérieurs des deux condyles, les points orange sont les points de contrôle inférieurs des deux condyles et le point en bleu le point de contrôle représentant le centre de la trochlée. Ces points de contrôle ne permettent pas à eux seuls d'obtenir une grande précision dans la région du fémur distal, mais sont plutôt positionnés afin d'optimiser le calcul des paramètres cliniques (Chaibi, 2010). Comparativement

aux autres points de contrôle du fémur qui se retrouvent généralement au centre de leur région, les points de contrôle postérieurs (en rouge) et les inférieurs (en orange) sont situés aux extrémités des condyles. Les points de contrôle postérieurs (en rouge) sont plus faciles à positionner dans la vue latérale, tandis que les points inférieurs (en orange) sont plus faciles à positionner en vue frontale. Cette situation complexifie la déformation de la région distale du fémur générique par l'opérateur. Comme ces points sont relativement rapprochés l'un de l'autre sur la surface des condyles et qu'il n'y a pas d'autres points de contrôles sur les condyles, les sommets du modèle générique qui sont éloignés des deux ensembles de points de contrôle se trouvent à être légèrement déformés par le déplacement ou la mise à l'échelle locale de tous ces derniers. Les sommets qui se trouvent à distance égale entre les points de contrôles sont très influencés par la position ou l'échelle de ces derniers. Cela fait en sorte qu'il peut être difficile pour un opérateur moins expérimenté d'ajuster la position et l'échelle des poignées postérieures et inférieures des condyles de manière à bien ajuster les contours du modèle générique sur les contours du fémur dans les radiographies.




Figure 1.9 Reconstruction du fémur distal avec la méthode de Chaibi (2010). À gauche, la vue frontale. À droite, la vue latérale

Finalement, la méthode étant semi-automatique, l'expérience de l'opérateur influence la reconstruction et est une source d'introduction d'erreurs potentielles dans la forme finale (Melhem *et al.*, 2016). De plus, la reconstruction nécessite évidemment qu'un opérateur soit disponible, ce qui complique son utilisation clinique.

1.4 Conclusion

Considérant les faiblesses actuelles de la méthode de reconstruction utilisée dans la plateforme commerciale SterEOS, une nouvelle méthode de reconstruction 3D du fémur devrait permettre l'automatisation de la reconstruction 3D et un plus haut nombre de degrés de liberté dans la déformation 3D. Ce plus haut nombre de degrés de liberté permettrait de reconstruire le fémur en 3D avec une forme plus précise, au risque que l'optimisation des paramètres de déformation soit plus complexe (Sotiras *et al.*, 2013). La revue de littérature qui suivra permettra de ressortir les méthodes existantes de reconstruction 3D à partir de radiographies qui répondent à ces deux critères.

CHAPITRE 2

REVUE DE LA LITTÉRATURE

La reconstruction 3D d'os à partir de radiographies peut être effectuée avec seulement l'information 2D extraites des radiographies ou en ajoutant des connaissances a priori au processus de reconstruction, ce qui permet l'obtention d'une méthode de reconstruction plus robuste et qui offre généralement une meilleure précision (Filippi, Motyl & Bandera, 2008; Goswami & Kr., 2015; Hosseinian & Arefi, 2015; Reyneke *et al.*, 2019).

Ces connaissances a priori peuvent être ajoutées au processus de reconstruction par l'utilisation d'un modèle 3D générique et/ou par apprentissage profond. Le modèle générique sera déformé durant le processus de reconstruction pour obtenir la forme de l'os du sujet à l'aide d'un algorithme de recalage 3D/2D non rigide (Markelj, Tomaževič, Likar & Pernuš, 2012). L'apprentissage profond utilise une base de données de radiographies et de modèles 3D attendus et entraîne un algorithme à apprendre à reconstruire l'os en fonction des images d'entrée qu'il observe (Han, Laga & Bennamoun, 2019).

La revue de la littérature portant sur la reconstruction 3D du fémur à partir de radiographies explorera ces deux avenues pour déterminer quelle méthode de reconstruction devrait être développée afin de pallier aux limitations de la méthode actuellement utilisée dans la plateforme SterEOS décrite au chapitre précédent. D'abord, les manières de représenter un modèle 3D seront présentées. Ensuite, une revue des méthodes de reconstruction 3D par recalage 3D/2D non rigide sera faite, suivie d'une revue des méthodes d'apprentissage profond. Dans la section suivante, nous étudierons l'impact des différents points de vue et du nombre de radiographies utilisées sur la précision de la forme et de la robustesse de la reconstruction 3D. Pour terminer, les méthodes d'évaluation de la précision de forme de la géométrie 3D des modèles seront présentées.

Les forces et faiblesses des différentes méthodes de reconstruction 3D devraient permettre d'établir des constats clairs sur les problèmes encore non résolus et de définir une nouvelle méthodologie appropriée.

2.1 Représentations du modèle 3D

Le modèle 3D utilisé lors du processus de reconstruction d'os à partir de radiographies est principalement représenté sous deux formes : un maillage 3D ou une grille de voxels. Le maillage 3D (voir figure 2.1) $M(S, E, F)$ est représenté à l'aide d'un ensemble de sommets S où $s_i \in \mathbb{R}^3, \forall s_i \in S$. Ces sommets sont liés par des arêtes E où $e_i = \{s_a, s_b\}, \forall e_i \in E$ et forment des faces F où $f_i = \{s_a, s_b, s_c\}, \forall f_i \in F$. Il existe d'autres méthodes de représenter un modèle 3D qui sont davantage utilisées en apprentissage profond : les fonctions de distance signées, les nuages de points, l'octree et les fonctions d'occupation (Xiao, Lai, Zhang, Li & Gao, 2020). Par contre, nous n'avons relevé aucune méthode utilisant ces différentes représentations dans notre revue de la littérature qui pourraient être appliquées à notre contexte.

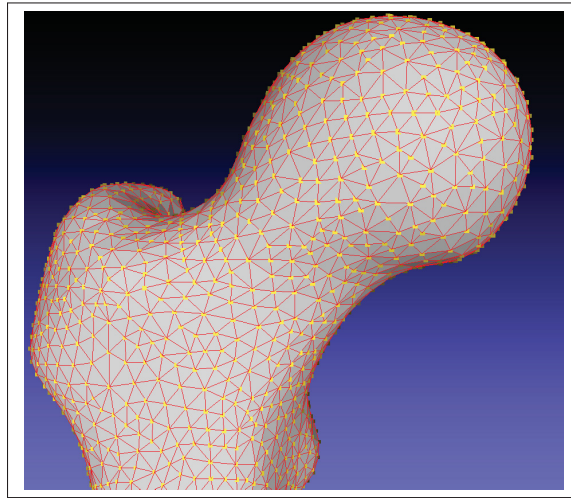


Figure 2.1 Un maillage 3D représentant le fémur constitué de sommets (en jaune), d'arêtes (en rouge) et de faces (en gris)

La grille de voxels utilise une grille 3D uniforme de la même manière qu'une image 2D peut être représentée par une grille 2D uniforme de pixels. La grille, de dimension *Profondeur * Largeur * Hauteur*, est constituée de voxels qui peuvent prendre la valeur 0 si le voxel ne fait pas partie du modèle 3D ou la valeur 1 s'il en fait partie (Figure 2.2).




Figure 2.2 Grille de voxels représentant la tête fémorale

En recalage 3D/2D, la majorité des méthodes utilisent un maillage 3D pour représenter la surface de l'os à reconstruire. Certaines méthodes utilisent la grille de voxels pour représenter la densité osseuse en plus de la surface (Reyneke *et al.*, 2019), ce qui peut être nécessaire dans certaines applications, mais qui ne s'applique pas vraiment dans le contexte de notre projet de recherche où nous nous intéressons à la surface de l'os. En apprentissage profond, Han *et al.* (2019) indiquent que l'utilisation des maillages 3D serait théoriquement plus performante en reconstruction 3D puisqu'elle est beaucoup plus efficace en termes de mémoire que les grilles de voxels, ce qui permettrait d'utiliser un maillage 3D plus dense qui représenterait mieux les détails dans la reconstruction 3D finale. Fu, Peng, He & Zhang (2021) indiquent que les maillages 3D ne sont pas recommandés lorsque la topologie du modèle générique est trop différente de celle des objets à reconstruire, mais que sinon cette représentation permettrait d'obtenir une reconstruction 3D plus précise que la grille de voxels. Fahim, Amin & Zarif (2021) indiquent que les maillages 3D ont l'avantage de mieux représenter les courbures que les grilles de voxels et que cela ferait en sorte que les maillages permettraient d'obtenir une reconstruction 3D plus précise. Le seul avantage que semble posséder la grille de voxels comparativement au maillage 3D en apprentissage profond est que ce type de représentation est mieux adapté aux réseaux de neurones à convolution existants (Han *et al.*, 2019; Fu *et al.*, 2021; Fahim *et al.*, 2021).

2.2 Reconstruction 3D par recalage 3D/2D non rigide

Le recalage sert à minimiser la distance entre des caractéristiques extraites de deux objets en appliquant une transformation estimée par l’algorithme à l’un des objets pour le superposer sur le second (Maintz & Viergever, 1998). Dans notre contexte, le recalage 3D/2D non rigide cherchera à minimiser la distance entre le modèle 3D générique et l’os observable dans les radiographies en estimant d’abord une transformation non rigide au modèle 3D puis en l’appliquant à ce modèle. Les articles de Brown (1992), Maintz & Viergever (1998) et Markelj *et al.* (2012) sont d’excellentes revues de la littérature pour comprendre plus en détails les différentes caractéristiques des algorithmes de recalage et leurs spécificités.

La figure 2.3 présente le processus suivi par un algorithme de recalage 3D/2D utilisé dans le contexte de la reconstruction 3D à partir de radiographies. D’abord, des caractéristiques doivent être extraites des radiographies et du modèle 3D pour être mises en correspondance aux caractéristiques du modèle 3D. Ces correspondances sont ensuite utilisées afin d’optimiser une fonction de coût, qui estimera les paramètres de déformation du modèle générique, jusqu’à ce que l’algorithme converge. Le recalage se termine généralement après un nombre d’itérations fixe, lorsque la distance entre les caractéristiques mises en correspondances atteint un seuil ou encore lorsque les paramètres de déformation du modèle cessent de changer.

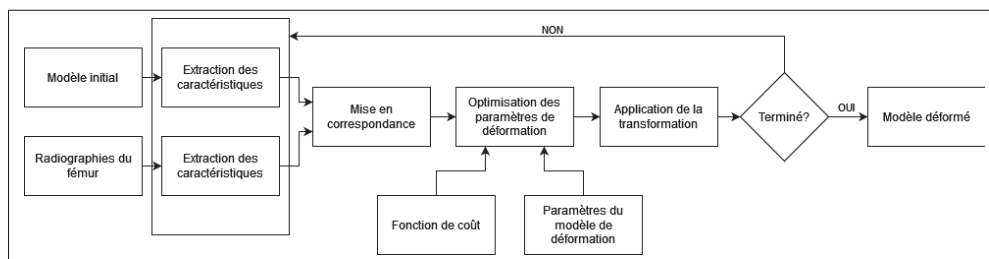


Figure 2.3 Processus généralisé de recalage 3D/2D non rigide

Plusieurs choix doivent être effectués lors de l’utilisation d’un algorithme de recalage, puisqu’il n’y a pas un seul algorithme de recalage qui soit systématiquement plus performant que les autres dans tous les scénarios (Markelj *et al.*, 2012; Villena-Martinez *et al.*, 2020). Nous avons établi une catégorisation des algorithmes de recalage 3D/2D non rigide qui s’appuie sur la méthode de

déformation utilisée pour déformer le modèle générique. Nous avons séparé les méthodes en trois catégories : les méthodes utilisant les modèles statistiques de forme, celles utilisant les modèles statistiques de forme et d'intensité et les autres méthodes.

2.2.1 Modèle statistique de forme

Le modèle statistique de forme (SSM) (Cootes, Taylor, Cooper & Graham, 1995) permet de déformer un modèle 3D en fonction des variations observées grâce à l'analyse en composantes principales (ACP) (Jolliffe, 2002) dans une base de données de modèles 3D de la même classe d'objets. Ce type de modèle de déformation est utilisé conjointement avec des caractéristiques géométriques qui sont extraites des radiographies et du modèle 3D. L'extraction des caractéristiques géométriques des images diminue le bruit et l'incertitude dans le recalage à la condition que le processus d'extraction soit précis et robuste, car les erreurs effectuées dans l'extraction des caractéristiques influenceront la précision de la forme obtenue par le processus de recalage 3D/2D (Markelj *et al.*, 2012). L'annexe I permet d'explorer plus en détails le fonctionnement du modèle statistique de forme ainsi que la manière dont les caractéristiques géométriques sont obtenues à partir du modèle 3D.

Fleute & Lavallée (1999) construisent un SSM à partir de 10 fémurs distaux secs et évaluent leur méthode de reconstruction sur les contours projetés des modèles 3D attendus, ce qui implique qu'il n'y a aucune erreur dans l'extraction des contours. Lorsque les contours provenant d'une vue de face et de profil sont utilisés, l'erreur obtenue sur leur seul fémur de test est de 0.99mm (P2S RMS). Zheng *et al.* (2009) utilisent un SSM construit à partir de 30 CT scans segmentés de fémurs proximaux sains afin de reconstruire de manière semi-automatique le fémur proximal. La méthode est semi-automatique puisqu'un opérateur doit identifier manuellement de 4 à 50 points appartenant au contour du fémur à reconstruire dans les radiographies du patient. Ces points sont utilisés afin d'interpoler une spline cubique qui représente le contour complet du fémur. Deux radiographies orthogonales calibrées sont acquises de 22 fémurs cadavériques afin d'évaluer la méthode et une erreur point à surface moyenne (P2S. moy.) de 0.9mm est observée. Cerveri, Sacco, Olgiati, Manzotti & Baroni (2017) utilisent un ensemble de 80 CT scans de

fémurs distaux avec des dommages sévères au cartilage afin de créer leur modèle statistique. 20 segmentations de CT scans sont utilisés afin de générer deux radiographies simulées (DRR pour *digitally reconstructed radiography*) orthogonales. Les contours du modèle de référence sont utilisés afin d'évaluer la méthode et une erreur point à surface RMS de 0.97mm est observée.

Le filtre de Canny (Canny, 1986) est une technique de traitement d'images utilisée pour extraire des contours d'une image. Un exemple des contours obtenus à l'aide de ce filtre est disponible à la figure 2.4. Lamecker, Wenckebach & Hege (2006) utilisent ce filtre sur une radiographie simulée afin de définir les contours du pelvis. Un opérateur doit ajuster manuellement les paramètres du filtre afin d'obtenir des contours précis et ce dernier doit positionner le pelvis moyen dans les radiographies. La méthode est évaluée à l'aide de la méthode Leave-One-Out (LOO) (Molinaro, Simon & Pfeiffer, 2005). À partir d'une base de données de 23 CT scans de pelvis sains, 23 modèles statistiques sont entraînés à l'aide de 22 CT scans et le dernier CT scan disponible est utilisé pour l'évaluation. Pour chaque CT scan utilisé pour l'évaluation, une DRR frontale est générée et une erreur surfacique moyenne (ASD moy.) de $2.4 \pm 0.4\text{mm}$ est obtenue.

Girion *et al.* (2020); Gajny *et al.* (2022) utilisent l'algorithme Minimal Path Algorithm (MPA) (Vincent, 1998), initialisé à partir de points posés manuellement par un opérateur, afin d'extraire les contours du fémur (Girion *et al.*, 2020) et du tibia (Gajny *et al.*, 2022). Girion *et al.* (2020) utilisent 120 modèles 3D de fémurs afin de construire le SSM de fémur et Gajny *et al.* (2022) en utilisent 176 pour le tibia. Des radiographies EOS de 20 patients (10 asymptomatiques et 10 avec une pathologie du genou) sont utilisées afin de valider les méthodes de reconstruction 3D. Des erreurs de $1.0 \pm 0.7\text{mm}$ (P2S moy.) pour le fémur et de $1.1 \pm 0.8\text{mm}$ (P2S moy.) pour le tibia sont obtenues.

Boussaid *et al.* (2011) utilisent l'algorithme Active Contours (Kass, Witkin & Terzopoulos, 1988) afin de segmenter de manière semi-automatique les contours de radiographies de fémurs proximaux. Un SSM est créé à partir de 17 CT scans segmentés de fémurs proximaux. 12 radiographies EOS de fémurs secs sont utilisées pour évaluer la méthode et l'erreur est de $1.97 \pm 0.99\text{mm}$ (P2S RMS).

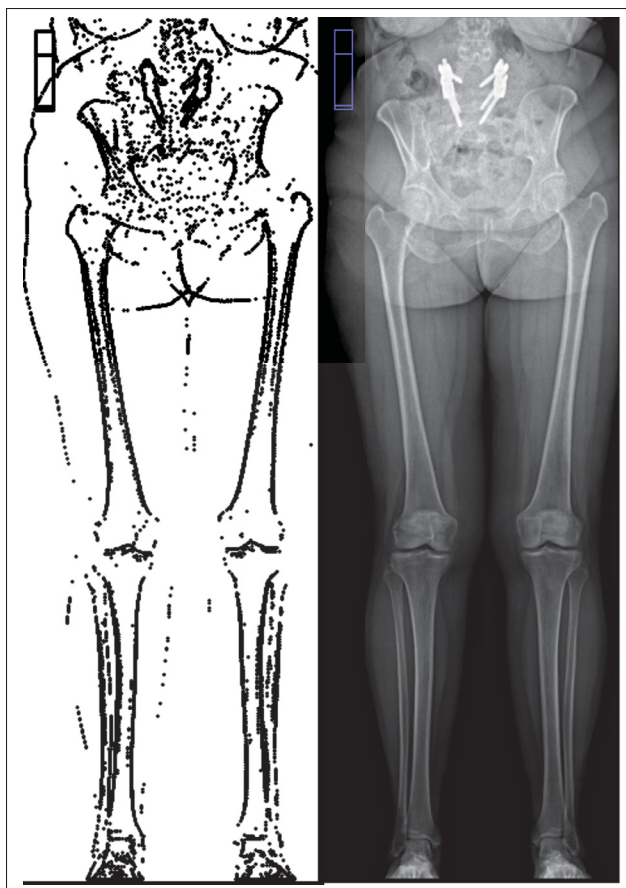


Figure 2.4 Exemple d'utilisation du filtre de Canny sur radiographies EOS

Baka *et al.* (2011, 2012); Zhu & Li (2011); Tsai *et al.* (2015) utilisent le filtre de Canny sur des images fluoroscopiques de patients sains sans intervention d'un utilisateur. Ils misent sur un algorithme de mise en correspondance des contours comparant les gradients des contours extraits des radiographies et les normales projetées des sommets du modèle 3D formant les contours 2D. Baka *et al.* (2011) utilisent un SSM créé à partir de 43 CT scans de fémurs distaux et évaluent la reconstruction 3D à partir d'une fluoroscopie. L'erreur est de 1.68mm (P2S RMS). Zhu & Li (2011) utilisent 40 IRM de fémurs distaux afin de créer leur SSM et deux fluoroscopies calibrées à 45° sont acquises pour 10 patients sains afin de valider la méthode ; l'erreur est de 1 ± 1.16 mm (P2S moy. signée). Tsai *et al.* (2015) construisent un SSM à partir de 152 CT scans de fémurs distaux sains et évaluent leur algorithme dans le même contexte que Zhu & Li (2011),

sur quatre fémurs distaux appartenant à deux patients sains, et obtiennent une erreur de $0.67 \pm 0.09\text{mm}$ (P2S moy.)

Trois principaux facteurs peuvent influencer les résultats obtenus par les différentes méthodes présentées dans cette revue : la méthode de segmentation des contours utilisée, la base de données utilisée pour construire le SSM et le type de données utilisé pour l'évaluation. Le tableau 2.1 présente un résumé des méthodes de reconstruction 3D présentées dans cette section. Il est plus difficile de distinguer la contribution à l'erreur de la méthode de segmentation et de la population utilisée pour le SSM, puisque les articles considèrent le processus de reconstruction 3D dans son ensemble.

Il faut prendre en compte que les algorithmes de segmentation automatique n'ont jamais une précision de 100%. La méthode de Tsai *et al.* (2015), la plus performante utilisée sur des images réelles, construit le SSM avec une base de données de 152 modèles 3D de genoux issus de la segmentation de CT scans, soit près de trois fois plus que les méthodes de Baka *et al.* (2011) (43) et Zhu & Li (2011) (40). L'utilisation du SSM permet d'obtenir un algorithme de reconstruction 3D qui est très robuste aux erreurs de segmentation ou de mise en correspondance de contours, mais qui limite les déformations admissibles aux déformations observées dans la base de données du SSM (Cootes *et al.*, 1995; Sotiras *et al.*, 2013). Habituellement, les composantes principales (ou vecteurs propres) représentant 95% ou 99% de la variance sont conservées (Lindner, 2017), ce qui fait en sorte que le SSM ne sera pas en mesure de recréer parfaitement un modèle 3D d'os de la même nature que ceux présents dans la base de données. Lamecker *et al.* (2006); Baka *et al.* (2012) déterminent la précision de forme maximale de leur modèle statistique de forme en calculant l'erreur obtenue avec un recalage non rigide 3D/3D et obtiennent des erreurs de 2mm (ASD moy.) et 1.42mm (P2S RMS). En comparant les erreurs minimales aux erreurs obtenues par ces méthodes lors de la reconstruction 3D à partir de radiographies, présentées dans le tableau 2.1, nous pouvons constater que l'erreur minimale du modèle statistique de forme représente une proportion non négligeable de l'erreur du recalage ($2.4 \pm 0.4\text{mm}$ vs. 2mm pour Lamecker *et al.* (2006) et 1.97mm vs 1.42mm pour Baka *et al.* (2012)). Lorsque le modèle statistique est construit à partir d'un grand ensemble de fémurs, comme c'est le cas dans la

méthode de Tsai *et al.* (2015), la précision de forme augmente (voir tableau 2.1). Ce type de méthode est efficace lorsqu'elle est utilisée avec une grande base de données.

Tableau 2.1 Méthodes de reconstruction 3D par recalage avec SSM

Méthode	Seg.	Os	Type d'image	BD SSM	Auto	BD éval	Erreur
Fleute & Lavallée (1999)	Manuelle	Fémur distal	Contours	10 fémurs secs	Non	1	0.99mm RMS (P2S)
Lamecker <i>et al.</i> (2006)	Canny	Pelvis	DRR depuis CT	23 CT	Non	22	2.4 ± 0.4mm (ASD moy.)
Zheng <i>et al.</i> (2009)	Canny	Fémur proximal	Radiographies de fémur cadavérique	30 CT	Non	22	0.9mm (P2S moy.)
Zhu & Li (2011)	Canny	Fémur distal	Fluoroscopie	40 IRM	Oui	10	1 ± 1.16mm (P2S moy. signée)
Baka <i>et al.</i> (2011)	Canny	Fémur distal	Radiographies	43 CT	Oui	2	1.68mm RMS (P2S)
Boussaid <i>et al.</i> (2011)	Active Contours	Fémur proximal	Acq. EOS de fémurs secs	17 CT	Non	12	1.97 ± 0.99mm (P2S RMS)
Tsai <i>et al.</i> (2015)	Canny	Fémur distal	Fluoroscopie	152 CT	Oui	2	0.67 ± 0.09mm (P2S moy.)
Cerveri <i>et al.</i> (2017)	Canny	Fémur distal	DRR depuis CT	80 CT	Non	20	0.97mm RMS (P2S)
Girion <i>et al.</i> (2020)	MPA	Fémur complet	Acq. EOS	120 modèles 3D	Non	20	1 ± 0.7mm (P2S moy.)

2.2.2 Modèle statistique de forme et d'intensité

Les modèles statistiques de forme et d'intensité (SSIM) ont un fonctionnement similaire au SSM, mais ils permettent d'obtenir de l'information sur la densité de l'os en plus de la forme (Yao, 2001), ce qui permet de planifier des chirurgies et le design d'implants (Reyneke *et al.*, 2019). Les modèles de type SSIM peuvent être séparés en trois catégories : les modèles indépendants (Matthews & Baker, 2004), combinés (Matthews & Baker, 2004) et moyen (Sadowsky, 2007). Les modèles indépendants nécessitent que deux ACP soient calculées : une pour la forme et une pour l'intensité, comparativement aux modèles combinés qui en calculent une seule. Les modèles SSIM moyens calculent l'ACP pour la forme, mais n'utilisent que l'intensité moyenne. Reyneke *et al.* (2019) présentent une revue des modèles de type SSIM et de leur utilisation en recalage 3D/2D non rigide appliqué à la reconstruction 3D à partir de radiographies.

Le recalage avec SSIM utilise des caractéristiques iconiques issues des intensités de pixels présents dans les radiographies. Ce type de méthode a l'avantage d'éviter l'étape d'extraction des caractéristiques nécessaire dans le recalage géométrique (Markelj *et al.*, 2012). McLaughlin *et al.* (2005); Markelj *et al.* (2012); Reyneke *et al.* (2019) indiquent dans leur revue de la littérature que ces méthodes permettent généralement d'obtenir un recalage plus précis puisque l'algorithme de recalage peut utiliser l'ensemble de l'information présente dans les images et qu'il n'y a pas de dégradation de performance due à l'extraction des caractéristiques. Par contre, ces méthodes de recalage sont bien plus propices à converger vers un minimum local lors de l'optimisation due à la non-convexité des métriques de similitude couramment utilisées (Reyneke *et al.*, 2019).

Afin de comparer le modèle 3D avec les radiographies 2D, des DRR sont simulées depuis les modèles génériques. Une DRR peut être générée à partir d'un modèle de voxels ou bien d'un maillage 3D. La figure 2.5a présente le processus de génération de DRR depuis un volume 3D. À l'aide des paramètres de calibration des radiographies, le volume 3D est positionné devant un point représentant la source des rayons X. La DRR est générée à l'aide du lancer de rayons. La valeur d'intensité de chaque pixel de la DRR est obtenue à partir des intensités traversées par son rayon correspondant dans le volume 3D (Reyneke *et al.*, 2019). Yao (2001) utilisent un

maillage 3D tétraédrique afin d'ajouter l'information sur la densité du modèle générique à un maillage surfacique standard. Le maillage tétraédrique contient des sommets à l'intérieur du maillage et à chacun de ces tétraèdres est associé une valeur d'intensité. Le lancer de rayon est ensuite effectué de la même manière qu'avec un volume 3D pour générer la DRR. La figure 2.5b présente la manière dont les rayons traversent les tétraèdres afin de calculer l'intensité d'un pixel. Ehlke, Ramm, Lamecker, Hege & Zachow (2013) expliquent en détail le processus de génération de la DRR à partir d'un modèle tétraédrique.

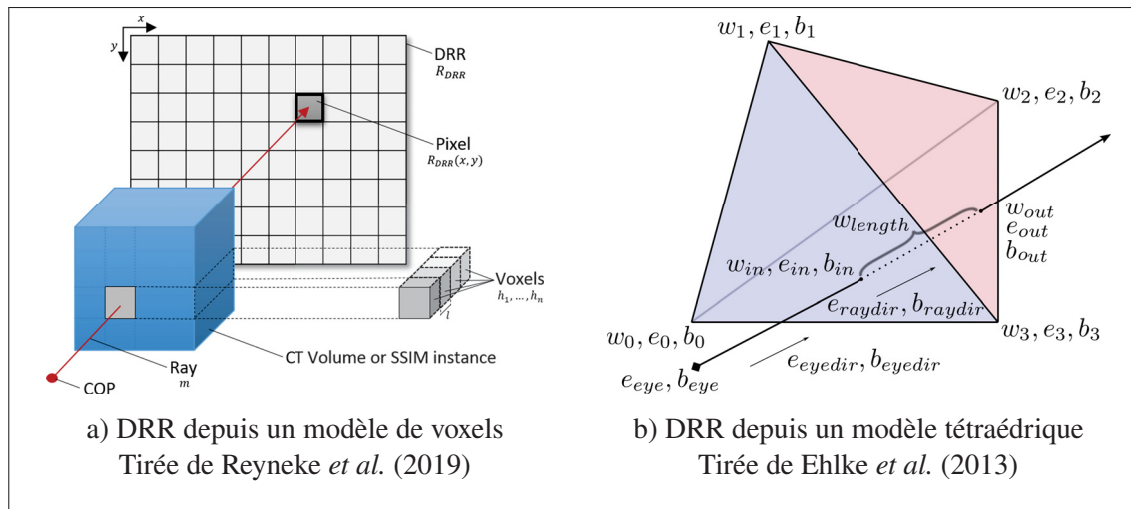


Figure 2.5 Processus de génération d'une DRR depuis un volume (a) et un maillage (b)

Il est aussi possible de générer une DRR à partir d'un maillage 3D standard (Vidal & Villard, 2016). La figure 2.6 présente le processus déterminant la valeur d'intensité d'un pixel en fonction de la distance parcourue par un rayon partant de la source des rayons X à ce pixel à l'intérieur de la surface observée. Afin de rendre la DRR plus réaliste, Serrurier, Quijano, Nizard & Skalli (2012) associent à chaque sommet du modèle 3D une constante représentant l'épaisseur de la couche corticale du fémur à cette position. Ces épaisseurs de couche corticale sont estimées à partir de 20 fémurs sains. Serrurier *et al.* (2012) génèrent des DRR plus réalistes du fémur à l'aide de cette information puisque le coefficient d'absorption des rayons X dans la couche corticale n'est pas le même que dans la région poreuse de l'os.

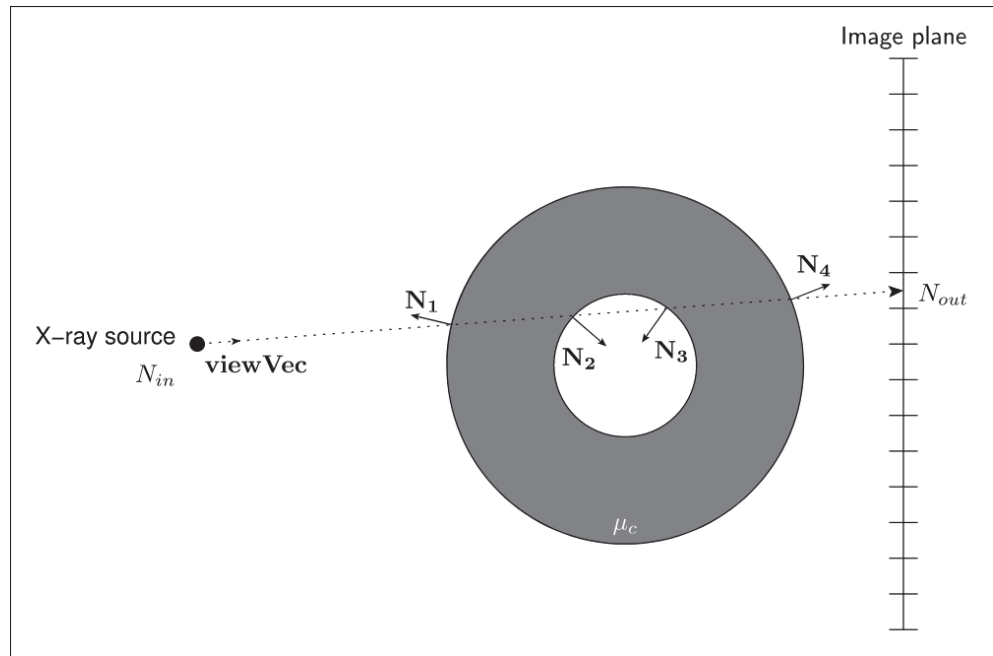


Figure 2.6 Le processus de génération d'une DRR depuis un maillage 3D. La valeur d'intensité finale d'un pixel est définie par la distance parcourue par le rayon dans la surface

Tirée de Vidal & Villard (2016)

La comparaison entre la DRR et la radiographie s'effectue à l'aide de métriques de similitude (Markelj *et al.*, 2012). Il existe plusieurs métriques de similitude qui peuvent s'appuyer sur l'intensité moyenne du voisinage d'un pixel ou sur les gradients de l'image, mais le choix de la métrique doit être effectué en fonction des distributions d'intensités des radiographies et des DRR (Markelj *et al.*, 2012).

L'information mutuelle (Shannon, 1948) est la métrique de similitude la plus utilisée en recalage iconique. Elle est utilisée par Zheng (2011, 2013) pour reconstruire le fémur proximal de manière automatique à l'aide d'un modèle SSIM moyen construit à partir de 20 CT scans de fémurs secs. Zheng (2011) évaluent leur algorithme sur 10 fémurs secs où deux radiographies orthogonales calibrées sont utilisées et obtiennent une erreur de 1.5mm (P2S moy.). Zheng (2013) utilisent la méthode de validation leave one out (Molinaro *et al.*, 2005) pour construire leur SSIM et évaluer leur méthode à l'aide de 20 fémurs secs. Deux DRR sont générées en position face/profil

depuis les CT scans de ces fémurs et l'erreur obtenue est de 0.77mm (p2S moy.). L'information mutuelle normalisée (NMI) (Shannon, 1948) est utilisée avec un SSIM indépendant par Klima, Kleparnik, Spanel & Zemcik (2016) afin de reconstruire automatiquement le fémur. Klima *et al.* (2016) utilisent 22 CT scans de fémurs afin de construire le SSIM et génèrent deux DRR pour 8 CT de fémurs de test et l'erreur obtenue sur ces derniers est de 1.18 ± 1.57 mm (P2S moy.).

Tchinde Fotsin, Vazquez, Cresson & De Guise (2019) calculent la différence entre les intensités de pixels afin d'optimiser les paramètres de déformation d'un modèle statistique de forme et de densité moyenne, de la relation géométrique et de la pose des structures osseuses (fémur, rotule, tibia) qui forment l'articulation du genou. Le modèle statistique est construit à partir de 200 modèles de fémurs distaux, tibias proximaux et péronés reconstruits à l'aide de la méthode de Chaibi (2010). 18 modèles sont utilisés afin de valider la méthode : des DRR sont générées à partir de ces modèles afin d'être utilisées dans le processus de reconstruction. Les erreurs P2S RMS obtenues sur le fémur distal, la rotule et le tibia proximal sont respectivement de 0.72mm, 0.82mm et 0.99mm.

Wu & Mahfouz (2021) utilisent une fonction de coût hybride qui permet de minimiser la corrélation croisée normalisée et la distance entre les contours du modèle 3D projeté et de ceux extraits à l'aide d'un filtre de Canny afin de reconstruire le fémur distal de manière automatique à partir d'une seule image fluoroscopique et obtient une erreur de 1.19 ± 0.36 mm (P2S RMS). Leur SSIM est construit à partir de 166 CT scans de fémurs distaux et la base de données d'évaluation en contient cinq.

Aubert, Cresson, De Guise & Vazquez (2022) reconstruisent automatiquement les vertèbres à l'aide d'un SSM et une épaisseur de corticale de 1mm est ajouté lors de la génération de la DRR afin de présenter l'information de densité. Ils utilisent un réseau de neurones Pix2Pix (Isola, Zhu, Zhou & Efros, 2018) pour transformer une radiographie EOS dans le style d'une DRR générée depuis un maillage surfacique. Ce transfert de style fait en sorte que la corrélation croisée normalisée (NCC) peut être utilisée pour comparer les deux images. La moyenne des erreurs P2S RMS obtenue sur les vertèbres C7, T8, T12 et L4 est de 1.1mm avec la méthode de

transfert de style, tandis qu'elle est de 9.77mm sans. Un ensemble de 40 radiographies EOS ainsi que leur reconstruction 3D semi-automatique (Humbert, 2008) est utilisée afin de valider la méthode.

Nous avons relevés quatre facteurs importants permettant d'expliquer l'erreur obtenue dans ce contexte de recalage. Comme pour les SSM, le contexte d'évaluation et la population utilisée sont importants. S'ajoutent à ces deux aspects la métrique de similitude et le type de SSIM utilisé. Le tableau 2.2 présente un résumé des méthodes de reconstruction 3D utilisant un modèle statistique de forme et d'intensité. La majorité des méthodes que nous avons relevées utilisent l'information mutuelle comme métrique de similitude, sans doute parce qu'elle offre un bon compromis entre la capacité à converger vers le minimum global et la précision de forme qui peut en être obtenue (Kim *et al.*, 2007). Contre-intuitivement, plusieurs revues de métriques de similitude appliquées au recalage indiquent que l'information mutuelle ne serait pas la métrique la plus appropriée en recalage 3D/2D puisque les distributions d'intensité entre les radiographies et les DRR seraient trop différentes pour permettre un recalage optimal (Russakoff *et al.*, 2003; Škerl, Likar & Pernuš, 2006; Kim *et al.*, 2007). Le transfert de style utilisé par Aubert *et al.* (2022) permet de rapprocher les distributions d'intensité à l'aide d'un transfert de style. Ce transfert de style influence grandement la qualité de la reconstruction 3D finale. Comme pour les SSM, les méthodes de reconstruction 3D utilisant un SSIM ont aussi une limitation de précision de forme liée à l'utilisation de l'ACP. Wu & Mahfouz (2021) obtiennent une erreur minimale de 0.6mm (P2S RMS) en recalant leur modèle statistique de fémur distal, construit à partir de 166 CT, directement sur la segmentation du fémur distal dans le CT scan. En comparaison à ce 0.6mm, ils obtiennent une erreur de 1.1mm (P2S RMS) lors du processus de reconstruction 3D à partir de radiographies.

Tableau 2.2 Méthodes de reconstruction 3D par recalage avec SSIM

Méthode	Simi.	Os	Type d'image	BD SSM	Auto	BD éval	Erreur
Zheng (2011)	MI	Fémur proximal	Radiographies	20 CT de fémurs secs	Oui	10	1.5mm moy. (P2S)
Zheng (2013)	MI	Fémur proximal	DRR depuis CT	20 CT de fémurs secs	Oui	19	0.77mm moy. (P2S)
Klima <i>et al.</i> (2016)	NMI	Fémur complet	DRR depuis CT	22 CT	Oui	8	1.18 ± 1.57mm (P2S moy.)
Tchinde Fot-sin <i>et al.</i> (2019)	DI	Fémur distal	DRR de modèles 3D	200 modèles 3D	Oui	18	0.7mm RMS (P2S)
Wu & Mahfouz (2021)	NCC / Canny	Fémur distal	Fluoroscopie	166 CT	Oui	5	1.1mm RMS (P2S)
Aubert <i>et al.</i> (2022)	NCC	Vertèbres	Acq. EOS	N/D	Oui	40	1.1mm RMS (P2S)

2.2.3 Autres méthodes

Les méthodes de recalage 3D/2D présentées dans cette section s'appuient soit sur des caractéristiques géométriques ou iconiques, mais n'utilisent pas de modèles statistiques. Les méthodes de déformation présentées ici sont basées sur l'interpolation. Ces méthodes estiment la position des sommets en fonction du déplacement appliqué à des points de contrôle (Sotiras *et al.*, 2013).

Mitton *et al.* (2000); Laporte *et al.* (2000); Mitulescu *et al.* (2001); Le Bras, Laporte, Mitton, de Guise & Skalli (2003); Laporte *et al.* (2003); Pomero, Mitton, Laporte, de Guise & Skalli (2004); Mitton *et al.* (2006) utilisent un algorithme de krigeage (Trochu, 1993) afin de déformer un modèle 3D générique à partir d'un ensemble de points ou de contours extraits des radiographies de manière manuelle ou semi-automatique. Mitton *et al.* (2000); Mitulescu *et al.* (2001); Le Bras *et al.* (2003) reconstruisent les vertèbres à l'aide de deux radiographies orthogonales calibrées en identifiant manuellement des points clés dans les radiographies et déforment un modèle générique à l'aide du krigeage avec des erreurs respectives de 1.2mm (P2S RMS), 1.1mm (P2S moy.) et 0.8mm (P2S RMS). Mitton *et al.* (2000) utilisent 18 vertèbres cadavériques afin de valider leur méthode, Mitulescu *et al.* (2001) utilisent 26 vertèbres cadavériques et Le Bras *et al.* (2003) en utilisent 36. Le pelvis est reconstruit par Laporte *et al.* (2000); Mitton *et al.* (2006) avec des erreurs de 2.8mm (P2S moy.) et 1.6mm (P2S moy.). Finalement, le krigeage appliqué à la reconstruction du fémur par Laporte *et al.* (2003) permet d'obtenir une reconstruction 3D avec une erreur de 1mm (P2S moy.).

Pomero *et al.* (2004) utilisent un modèle de déformation paramétrique basé sur des primitives géométriques ainsi qu'un modèle de régression multilinéaire afin de reconstruire de manière semi-automatique des vertèbres scoliotiques et obtiennent une erreur de 1.5mm (P2S moy.).

Cresson *et al.* (2010) utilisent la déformation Moving Least Squares (MLS) (Zhu & Gortler, 2007) afin de reconstruire de manière semi-automatique le fémur et obtiennent une erreur de 1.68 ± 0.35 mm (P2S moy.). Chaibi (2010) appliquent la déformation Moving Least Squares (MLS) avec des inférences statistiques afin de reconstruire les membres inférieurs de manière

semi-automatique et obtient une erreur de 1mm (P2S moy.). La déformation MLS (Zhu & Gortler, 2007) appliquée à un maillage 3D calcule une transformation de similitude (translation, rotation et mise à l'échelle) à appliquer à chaque sommet $s \in S$ d'un modèle générique en fonction du déplacement d'un ensemble de poignées de contrôle P . Dans le cas de la méthode de Chaibi (2010), le positionnement de ces poignées est décrit à la section 1.3. La transformation de similitude estimée pour un sommet du modèle générique est calculée en fonction de la distance du sommet à l'ensemble des points de contrôle ainsi que du déplacement appliqué à ces derniers. Plus un point de contrôle est éloigné du sommet, moins il a d'influence sur sa transformation. Cette méthode de déformation a l'avantage de produire des déformations lisses et réalistes, mais nécessiterait davantage de points de contrôle afin d'être en mesure de représenter de manière précise les détails du fémur. À notre avis, ajouter des points de contrôle au modèle générique n'est pas une tâche si simple. Les points devraient se trouver dans des régions anatomiques facilement repérables par l'opérateur de manière à conserver la répétabilité intra- et inter-opérateurs, tout en se trouvant suffisamment loin des autres points de contrôle pour être utiles lors de la déformation de régions moins bien représentées.

Karade & Ravi (2015) utilisent une déformation laplacienne (Sorkine *et al.*, 2004) afin de reconstruire le fémur distal à l'aide de caractéristiques géométriques. La déformation laplacienne permet de déformer un modèle 3D à partir de déplacements appliqués à un sous-ensemble de sommets $c \in C$, appelés contraintes de déformation, en minimisant la déformation appliquée à un sommet par rapport à ses voisins (Sorkine *et al.*, 2004). Plus spécifiquement, cette déformation minimise la différence du différentiel des sommets (les coordonnées laplaciennes \mathcal{L}) du modèle 3D avant et après la déformation. La coordonnée laplacienne d'un sommet s est déterminée par sa position par rapport à la moyenne de son voisinage \mathcal{N} (voir équation 2.1). La déformation laplacienne estime pour chaque sommet $s \in S$ une transformation de similitude T_s qui minimise l'énergie à l'équation 2.2, où s' représente la nouvelle position d'un sommet s et c' la nouvelle position d'une contrainte c .

$$\mathcal{L}(s) = s - \frac{1}{|\mathcal{N}|} * \sum_i^{|\mathcal{N}|} \mathcal{N}_i \quad (2.1)$$

$$E = \sum_i^{|\mathcal{S}|} \|\mathcal{L}(s_i) - \mathcal{L}(s'_i)\|^2 + \sum_j^{|\mathcal{C}|} \|c_j - c'_j\|^2 \quad (2.2)$$

Comparativement aux modèles statistiques qui sont habituellement utilisés avec un petit nombre de degrés de liberté, la déformation laplacienne peut en utiliser davantage. En ajoutant des vecteurs propres au SSM, les nouveaux vecteurs ajoutés apportent des déformations de moins en moins importantes (Jolliffe, 2002). Avec la déformation laplacienne (Sorkine *et al.*, 2004), il est possible d'ajouter des contraintes de déformation dans des régions particulières où les variations de forme seraient statistiquement moins importantes, ce qui fait en sorte qu'elles ne se retrouveraient pas dans les principaux modes de variations du SSM, mais importantes en application clinique. L'augmentation du nombre de degrés de liberté diminue nécessairement la robustesse de la méthode aux erreurs de segmentation ou d'identification de points clés (Sotiras *et al.*, 2013; Lindner, 2017). Dans l'application de Karade & Ravi (2015), les contraintes sont situées uniquement sur les contours projetés du modèle 3D dans les radiographies. Cela fait en sorte que la déformation dans les régions absentes de ces contours, comme la trochlée ou l'intérieur du grand trochanter, ne serait guidée que par des contraintes éloignées de ces régions. La reconstruction 3D obtenue serait plus encline à conserver la forme originale du modèle générique, qui ne serait pas nécessairement représentative du fémur du patient visible dans les radiographies. La méthode de Karade & Ravi (2015) permet d'obtenir une erreur de 1.2 ± 0.1 mm (P2S moy.) lorsqu'elle est évaluée sur des contours extraits manuellement de 5 paires de radiographies frontales et latérales du fémur distal.

Yu & Zheng (2015); Yu, Chu, Tannast & Zheng (2016) utilisent un modèle de déformation B-Spline Free Form Deformation (B-Spline FFD) (Rueckert *et al.*, 1999) avec l'information mutuelle afin de reconstruire le fémur proximal. La méthode de déformation B-Spline FFD utilise une grille de points de contrôle définie autour du modèle 3D à déformer (Sederberg,

1986). Lorsqu'un point de la grille est déplacé, le modèle est déformé localement autour de ce point. Évaluées sur 10 fémurs cadavériques, les méthodes de Yu & Zheng (2015); Yu *et al.* (2016) obtiennent des erreurs respectives de 1.4mm (P2S moy.), 1.29mm (P2S moy.). Yu, Tannast & Zheng (2017) reprennent la méthode de Yu *et al.* (2016), mais en créant un modèle statistique basé sur l'ACP qui apprend les modes de variation des points de contrôle du modèle B-Spline FFD (Rueckert, Frangi & Schnabel, 2003). Ce modèle est évalué sur 10 CT scans de fémurs in vivo et l'erreur obtenue est de 1 ± 0.2 mm (ASD moy.). La déformation par B-Spline FFD a l'avantage d'être efficace à calculer comparativement à une méthode comme la déformation laplacienne (Sorkine *et al.*, 2004) car la déformation de chaque élément du modèle 3D (que ce soit une grille de voxels ou un maillage 3D) peut être calculée comme une combinaison linéaire du déplacement de chaque point de contrôle. Par contre, les déformations applicables au modèle 3D sont limitées en fonction de la géométrie de la grille (Cohen-Or, 2009). Par exemple, les méthodes de Yu & Zheng (2015); Yu *et al.* (2016, 2017) proposent d'utiliser une grille de déformation où les points de contrôle sont équidistants. Certaines régions du fémur, comme les condyles ou le grand trochanter, nécessiteraient un plus grand nombre de points de contrôle et donc une résolution de grille plus grande afin de proposer des déformations précises. La création de la grille de déformation devient un défi puisque le positionnement des points de contrôle influence grandement les déformations possibles (Cohen-Or, 2009).

Le tableau 2.3 présente un résumé des méthodes de recalage présentées dans cette section. Nous pouvons constater que ces méthodes permettent d'obtenir des reconstructions précises, mais que la majorité de ces méthodes ne sont pas des méthodes automatiques ou qu'elles ne sont pas évaluées sur des radiographies réelles. Les méthodes de déformation 3D utilisées dans cette section permettent théoriquement d'obtenir une précision de forme plus grande que les modèles statistiques puisqu'ils ne sont pas limités par la base de données d'apprentissage du modèle statistique. En pratique, les méthodes de reconstruction 3D s'appuyant sur un modèle statistique sont plus facilement automatisables et permettent d'obtenir une précision de forme similaire.

Tableau 2.3 Méthodes de reconstruction 3D par recalage n'utilisant pas de SSM ou de SSIM

Méthode	Carac.	Seg. Simi.	/	Déformation	Os	Type d'image	Auto	BD éval	Err.	Notes
Mitton <i>et al.</i> (2000)	Géo.	N/A		Krigeage	Vertèbre cervicale (sèche)	Radiographies	Non	18	1.1mm (P2S RMS)	-
Laporte <i>et al.</i> (2000)	Géo.	N/A		Krigeage	Pelvis (sec)	Radiographies	Non	6	2.8mm (P2S moy.)	-
Mitulesscu <i>et al.</i> (2001)	Géo.	N/A		Krigeage	Vertèbre (sèche)	Radiographies	Non	26	1.2mm (P2S RMS)	-
Le Bras <i>et al.</i> (2003)	Géo.	N/A		Krigeage	Vertèbre (sèche)	Radiographies	Non	36	0.8mm (P2S RMS)	-
Laporte <i>et al.</i> (2003)	Géo.	N/A		Krigeage	Fémur distal (sec)	Radiographies	Non	8	1mm (P2S moy.)	-
Pomero <i>et al.</i> (2004)	Géo.	N/A		Param.	Vertèbre	Radiographies	Non	58 (14 patients)	1.5mm (P2S moy.)	-
Mitton <i>et al.</i> (2006)	Géo.	Active Contours		Krigeage	Pelvis	Radiographies	Non	3	1.6mm (P2S moy.)	-
Cresson <i>et al.</i> (2010)	Géo.	N/A		MLS	Fémur (sec)	Acq. EOS	Non	6	1.68mm (P2S moy.)	-
Chaibi (2010)	Géo.	N/A		MLS + inf. stat.	Fémur (sec)	Acq. EOS	Non	11	1mm (P2S moy.)	-
Karade & Ravi (2015)	Géo.	N/A		Laplacian	Fémur distal	Contours simulés	Non	5	1.2 (P2S moy.)	-
Yu & Zheng (2015)	Icon.	MI		B-Spline FFD	Fémur prox. (sec)	C-arm	Non	10	1.4mm (P2S moy.)	-
Yu <i>et al.</i> (2016)	Icon.	MI		B-Spline FFD	Fémur prox. (sec)	C-arm	Oui	10	1.29mm (P2S moy.)	-
Yu <i>et al.</i> (2017)	Icon.	MI		B-Spline FFD SDM	Fémur prox. (sec)	C-arm	Oui	10	1 mm (ASD moy.)	40 fémurs pour le SSM

2.2.4 Conclusion

Dans cette section de la revue de littérature, les méthodes de reconstruction 3D par recalage 3D/2D non rigide ont été explorées. Pour la reconstruction du fémur, les méthodes sont évaluées sur des os cadavériques, sur des DRR ou encore à partir de radiographies où les contours ont été extraits semi-automatiquement, ce qui facilite le recalage et permet d'obtenir une meilleure précision de forme ainsi qu'une meilleure robustesse. Trois familles de méthodes ont été relevées, les méthodes utilisant un modèle statistique de forme, d'intensité et celles qui n'en utilisent pas. Les méthodes de Tsai *et al.* (2015); Tchinde Fotsin *et al.* (2019) permettent d'obtenir des erreurs de reconstruction similaires de respectivement 0.67 ± 0.09 mm (P2S moy.) et 0.7mm (P2S RMS). Considérant que la méthode de Tsai *et al.* (2015) utilisent un modèle statistique de forme avec des contours extraits à l'aide d'un filtre de Canny et que la méthode de Tchinde Fotsin *et al.* (2019) utilisent un modèle statistique d'intensité où la différence d'intensité de pixels est utilisée comme fonction d'optimisation, il est difficile de déterminer avec assurance qu'une des deux familles de méthodes est meilleure que l'autre. Les deux méthodes ont comme similarité que leur modèle statistique a été construit avec une grande base de données, 152 modèles pour Tsai *et al.* (2015) et 200 pour Tchinde Fotsin *et al.* (2019). Notre étude de la littérature sur ce type de modèle semble donc indiquer qu'une des clés du succès des algorithmes de recalage par déformation statistique réside dans la population utilisée pour créer le SSM (Lindner, 2017). Les autres méthodes de déformation 3D étudiées dans cette revue se basent sur l'interpolation plutôt que sur l'usage de statistiques. Comparativement aux méthodes statistiques, ces méthodes ne nécessitent pas de bases de données et peuvent exploiter un plus grand nombre de degrés de liberté (Lindner, 2017). Par contre, en pratique, les méthodes de recalage statistique permettent d'obtenir une meilleure précision de forme et elles sont très robustes aux erreurs de mise en correspondance (Sotiras *et al.*, 2013).

Les méthodes de recalage utilisant des caractéristiques géométriques pourraient être améliorées à l'aide des réseaux de neurones à convolution (CNN) (Olory Agomma, Cresson, De Guise & Vazquez, 2022). Pour les méthodes de recalage iconique, des métriques de similitude plus adaptées aux différentes modalités utilisées pourraient être exploitées, ce qui permettrait de diminuer

l'impact des différences de distributions d'intensité. Toutefois, nous n'avons pas trouvé dans la littérature de métrique de similitude qui serait plus performante que celles présentées dans cette revue.

2.3 Reconstruction 3D par apprentissage profond

L'apprentissage profond permet de laisser un modèle apprendre la relation entre les radiographies et les modèles 3D de référence, évitant les étapes complexes que l'on retrouve dans les algorithmes de recalage (Villena-Martinez *et al.*, 2020). Le domaine de la reconstruction 3D par apprentissage profond est très concentré sur la reconstruction à partir d'images optiques et non de radiographies, mais peu de littérature indique que ces méthodes ne s'appliqueraient pas aussi à notre contexte. Han *et al.* (2019); Fu *et al.* (2021) offrent des revues assez complètes sur la reconstruction 3D à partir d'images optiques.

L'apprentissage profond est une classe d'algorithmes qui améliore sa capacité à effectuer une tâche selon une métrique de performance et un ensemble d'exemples de la tâche à effectuer (Mitchell, 1997). La figure 2.7 présente le processus général d'un algorithme d'apprentissage profond. Une donnée d'entrée est utilisée afin d'approximer une sortie, qui est ensuite comparée à un résultat attendu. Cette comparaison s'effectue au moyen d'une métrique, qui permet, via optimisation, de mettre à jour les paramètres de l'algorithme d'apprentissage en fonction des erreurs effectuées dans les approximations. Cette boucle est répétée sur plusieurs paires de données d'entrée et de sortie jusqu'à ce que l'algorithme converge. Dans notre cas, par exemple, l'algorithme d'apprentissage devrait être en mesure de reconstruire un modèle 3D du fémur en fonction des radiographies observées.

La reconstruction 3D s'effectue généralement en deux parties. Premièrement, un réseau de neurones à convolution (CNN) (LeCun *et al.*, 1989) est utilisé pour extraire des caractéristiques des images 2D, puis un autre réseau de neurones, soit un autre CNN ou bien un réseau de neurones à convolution sur les graphes (GCN) (Kipf & Welling, 2017) utilisent les caractéristiques précédentes pour procéder à la reconstruction 3D (Han *et al.*, 2019).

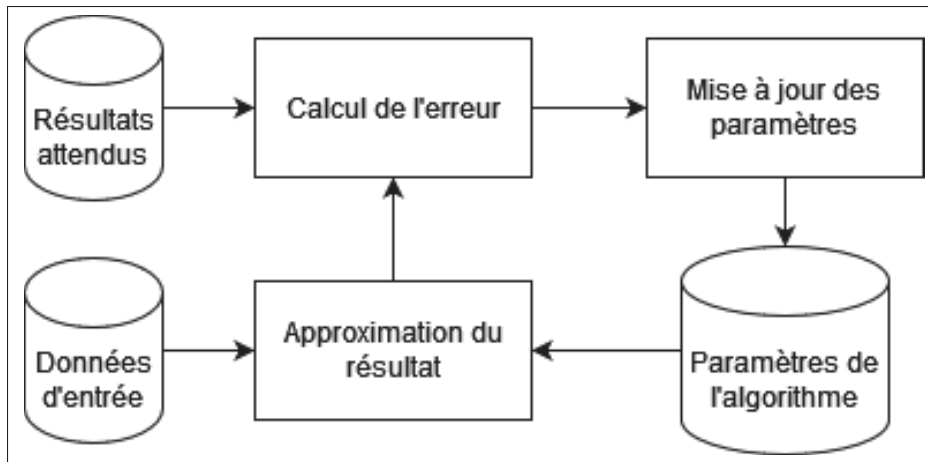


Figure 2.7 Processus généralisé de l'apprentissage profond supervisé

Les CNN sont utilisés pour traiter des données sous forme de grilles, comme des images ou des volumes 3D (Goodfellow, Bengio & Courville, 2016). Ces réseaux s'appellent ainsi parce qu'ils utilisent un opérateur nommé la convolution, qui calcule une moyenne pondérée pour chaque valeur de la grille en fonction de son voisinage. Les poids utilisés pour cette moyenne pondérée sont les paramètres appris pendant l'apprentissage. En reconstruction 3D, ces CNN sont utilisés afin d'extraire des caractéristiques complexes qui seront utilisées pour procéder à la reconstruction (Han *et al.*, 2019). Ce vecteur de caractéristiques est obtenu en appliquant itérativement des filtres de convolution et une opération de pooling sur l'image initiale, puis sur le résultat des filtres de convolution précédents (voir figure 2.8). Le pooling est une opération qui permet de conserver les caractéristiques les plus importantes extraites des filtres de convolution (Goodfellow *et al.*, 2016).

Les réseaux de neurones à convolution sur les graphes (GCN) (voir figure 2.9) sont utilisés, comme leur nom l'indique, sur des graphes. Un graphe est une structure composée de noeuds et d'arêtes, ce qui en fait un type de réseau approprié pour travailler avec les maillages 3D, qui ont une structure identique. Ces méthodes prennent en entrée un graphe et une matrice de caractéristiques où chaque colonne est associée à un noeud du graphe (Kipf & Welling, 2017). De manière similaire aux CNN, les caractéristiques extraites par le GCN à l'aide de filtres qui

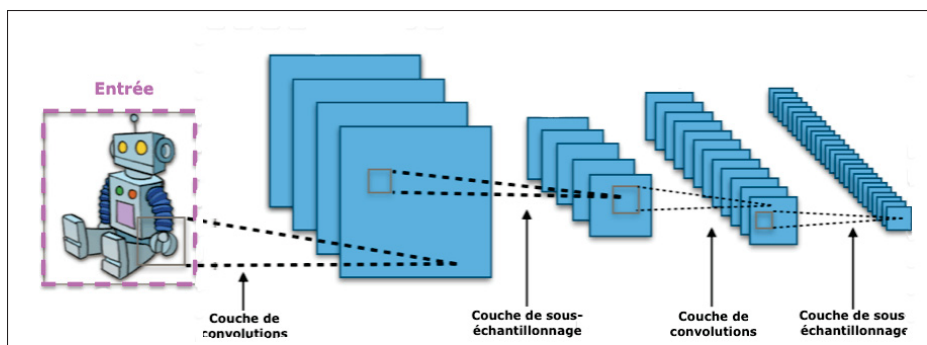


Figure 2.8 Processus du CNN
Tirée de Aphex32, CC BY-SA 3.0, via Wikimedia Commons

sont appliqués à chaque noeud et à leur voisinage, qui sont les autres noeuds connectés par des arêtes.

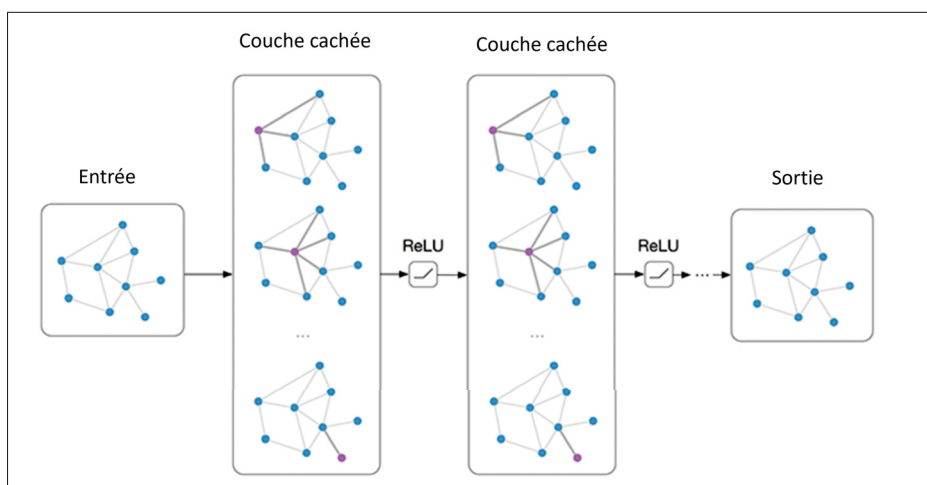


Figure 2.9 Processus du GCN
Tirée de Kipf & Welling (2017)

Les méthodes de reconstruction 3D basée sur l'apprentissage profond peuvent être séparées en deux catégories : celles qui estiment une déformation à appliquer sur un modèle générique, comme dans un algorithme de recalage, et celles qui reconstruisent un modèle sans information a priori. Pour ces deux familles, nous retrouvons une deuxième catégorisation importante : les méthodes utilisant des images optiques et des méthodes utilisant des DRR. Bien que notre projet porte sur l'utilisation d'acquisitions EOS, les méthodes d'apprentissage profond en imagerie

médicale n'utilisent généralement pas de radiographies réelles dû à la difficulté d'obtenir un modèle de référence et les radiographies associées. Nous choisissons d'étudier des méthodes utilisant des images optiques puisque les percées dans le domaine de l'apprentissage profond surviennent d'abord en imagerie optique puis sont reprises dans le domaine médical. En étudiant les méthodes utilisant des images optiques, nous serons en mesure de voir si une nouvelle méthode pourrait être utilisée dans notre contexte. La suite de cette revue présentera d'abord les méthodes comparables au recalage puis les méthodes sans modèle générique.

2.3.1 Reconstruction 3D par estimation de déformation 3D

Pei *et al.* (2017); Li *et al.* (2020) utilisent un réseau de type CNN afin d'estimer le déplacement à appliquer à des points de contrôle d'un modèle B-Spline FFD (Rueckert *et al.*, 1999) pour reconstruire le crâne à partir d'une radiographie.

La méthode de Pei *et al.* (2017) s'appuie sur un algorithme de recalage iconique avec l'information mutuelle et une déformation B-Spline FFD, où le déplacement à appliquer aux points de contrôle est estimé par un CNN qui prend en entrée une radiographie du crâne et une DRR générée à partir du volume 3D générique. L'erreur, de $0.41\text{mm} \pm 0.12\text{mm}$, est calculée à partir de la distance entre les contours 2D des DRR créées à partir des Cone Beam CT scan (CBCT) de référence et des volumes reconstruits, ce qui ne se traduit par nécessairement par une reconstruction 3D plus précise. Les limitations de l'information mutuelle et de la déformation B-Spline FFD font en sorte qu'il est difficile de considérer cette méthode pour résoudre notre problème.

La méthode de Li *et al.* (2020) utilise un CNN qui va régresser en une étape les paramètres d'une déformation B-Spline FFD SDM, dont la taille de la base de données n'est pas mentionnée, à partir d'une seule radiographie du crâne. La méthode minimise la corrélation croisée normalisée entre la DRR obtenue du volume 3D reconstruit et la DRR obtenue d'un CBCT scan de référence. Ce type de supervision est avantageux en imagerie médicale où les annotations 3D sont complexes et coûteuses à obtenir (Li *et al.*, 2020). Par contre, comme pour la méthode de Pei *et al.* (2017), la convergence de l'erreur 2D n'implique pas une bonne précision en 3D.

Cette méthode est évaluée sur deux ensembles de données : 2000 CBCT du crâne pour lesquels est générée une DRR par CBCT ainsi que 1000 radiographies réelles de crâne. 32 points clés sont numérisés manuellement sur les CBCT, en 3D, et sur les radiographies, en 2D. L'erreur euclidienne moyenne est utilisée afin d'évaluer le modèle. Pour les CBCT, la distance moyenne entre les points clés est de 1.34mm en 3D et de 0.8mm en 2D, tandis que pour les radiographies réelles l'erreur 2D est de 11.95mm. La différence d'erreur 2D entre les DRR et les radiographies réelles s'explique sans doute la différence de distribution d'intensité entre ces deux modalités (Kasten, Doktofsky & Kovler, 2020; Aubert *et al.*, 2022) et par la plus grande proportion de DRR dans l'ensemble d'entraînement.

Van Houtte, Gao, Sijbers & Zheng (2021) construisent un réseau de neurones de type CNN qui prennent en entrée deux radiographies orthogonales calibrées et pré segmentées du fémur proximal afin d'estimer les coefficients à appliquer à un modèle statistique de type B-Spline FFD SDM construit à partir de 40 CT scans de fémurs cadavériques. La fonction de coût permet de maximiser la corrélation croisée normalisée entre le modèle statistique volumique déformé et le volume de référence. La méthode est évaluée sur 22 CT scans segmentés du fémur proximal avec des DRR et permet d'obtenir une erreur surfacique moyenne de 1.29 ± 0.21 mm (ASD) alors que l'erreur initiale est de 2.16 ± 0.54 mm.

Van Houtte, Audenaert, Zheng & Sijbers (2022) proposent une amélioration à leur algorithme précédent en apprenant un champ de déformation dense à appliquer au modèle générique plutôt qu'en utilisant un modèle statistique. La déformation dense du modèle générique permettrait de mieux reconstruire les détails présents dans les modèles de référence. La méthode est évaluée sur 40 fémurs proximaux segmentés depuis des CT scans avec en entrée des DRR générées de ces derniers et permet d'obtenir une erreur de 0.84 ± 0.2 mm (ASD moy.). L'utilisation de la déformation dense permet de déformer le modèle générique de manière très précise. Dans les méthodes de recalage classique, ce type de déformation mène à une perte de robustesse puisque le nombre de degrés de liberté est trop élevé pour que l'algorithme d'optimisation puisse converger vers le minimum global. Comme il s'agit d'un algorithme d'apprentissage profond, la déformation dense reste régularisée en fonction des exemples présents dans la base

de données d'entraînement, ce qui permet d'utiliser un grand nombre de degrés de liberté en conservant une optimisation rapide qui pourrait mieux converger. Un désavantage que nous avons remarqué de cette méthode est que les fémurs soient pré segmentés dans les radiographies. Comme nous l'avons vu dans la section 2.2, la segmentation du fémur dans les radiographies est un sujet complexe où les algorithmes automatiques ne permettent pas d'obtenir une segmentation parfaite.

Wen, Zhang, Li & Fu (2019) proposent la méthode Pixel2Mesh++, une méthode de recalage 3D/2D basée sur la déformation d'un maillage 3D de la forme d'un ellipsoïde à partir d'images optiques en 2D. L'annexe III présente le fonctionnement détaillé de cette méthode ainsi que des détails sur les choix méthodologiques des auteurs de cette dernière. La déformation du modèle générique est effectuée en déterminant, par apprentissage profond, un déplacement à appliquer pour chaque sommet du modèle 3D. Cet algorithme est entraîné de manière à reconstruire 13 classes d'objets à partir d'un nombre arbitraire d'images optiques calibrées. La méthode est entraînée et évaluée sur la base de données ShapeNet (Chang *et al.*, 2015) et les images calibrées définies dans Choy, Xu, Gwak, Chen & Savarese (2016). L'algorithme d'apprentissage est entraîné à l'aide d'une combinaison de la distance de Chamfer, de la distance cosinus, d'une régularisation laplacienne et de longueur d'arête. Les résultats obtenus par cette méthode sont évalués à l'aide de la distance de Chamfer moyenne (Wang *et al.*, 2018). Cette distance, sur l'ensemble de tests de ShapeNet, est de 0.486. L'ensemble ShapeNet (Chang *et al.*, 2015) contient des formes dont la taille est normalisée entre $[-1, 1]$. Ces métriques permettent seulement de se comparer aux autres articles qui utilisent ShapeNet, comparativement aux méthodes évaluées sur des os, où il est possible de mettre en relation l'erreur obtenue dans une méthode de reconstruction comparativement à l'objet à reconstruire. La figure 2.10 permet d'observer les résultats qualitatifs obtenus par la méthode Pixel2Mesh++ en comparaison avec d'autres méthodes de la littérature. Les résultats obtenus par cette méthode sont intéressants compte tenu du fait que le modèle initial utilisé est un ellipsoïde.

Cette méthode est intéressante pour plusieurs raisons. Premièrement, le nombre de degrés de liberté dans la déformation 3D est très élevé. Un déplacement est estimé pour chaque



Figure 2.10 Résultats qualitatifs obtenus sur 4 classes d'objets lorsque deux images sont utilisées. La première rangée présente les images données en entrée au réseau de neurones, la rangée du milieu la sortie du réseau et la rangée du bas les modèles de référence. Les colonnes (1,2), (3,4), (5,6) et (7,8) représentent quatre reconstructions présentées sous deux points de vue différents, obtenues à l'aide des deux images de la première rangée
Modifiée de Wen *et al.* (2019)

sommet du modèle générique. Comparativement aux méthodes de déformation statistiques basées sur l'ACP couramment utilisées en recalage classique qui apprennent des relations linéaires entre les exemples de la base de données (Cootes *et al.*, 1995), le réseau de neurones peut apprendre des relations non linéaires entre les différents modèles 3D de référence. Cette non-linéarité permet d'apprendre des déformations plus complexes et plus représentatives de la base de données (Cootes *et al.*, 1995). La combinaison d'un nombre de degrés élevé lors de la déformation et de l'utilisation de l'apprentissage profond pour régulariser, avec un algorithme non linéaire, la forme obtenue permettrait potentiellement d'obtenir les avantages des méthodes de recalage 3D/2D statistique et du grand nombre de degrés de liberté dans la déformation. Deuxièmement, comparativement aux méthodes de recalage géométrique classiques qui n'utilisent que quelques sommets pour établir des correspondances, le réseau Pixel2Mesh++ extrait des caractéristiques pour l'ensemble des sommets du modèle, ce qui devrait permettre de déformer le modèle générique avec plus de contrôle. Troisièmement, la fonction de coût utilisée dans cette architecture cherche à maximiser la précision de forme et la robustesse de la reconstruction 3D en comparant directement le modèle 3D reconstruit au modèle de référence, ce qui s'aligne bien à notre problématique de recherche. Toutefois, la méthode Pixel2Mesh++

(Wen *et al.*, 2019) nécessite que l'initialisation de la pose du modèle générique soit déjà faite. L'initialisation de la pose n'étant pas une simple tâche, il s'agit d'une limitation importante de la méthode. Aussi, comme la méthode estime un champ de déformation dense et que la fonction de coût ne s'appuie que sur des composantes qui observent les sommets du maillage 3D et non les faces, il est possible que les reconstructions 3D obtenues par Pixel2Mesh++ possèdent des faces qui s'intersectent.

2.3.2 Reconstruction 3D sans modèle initial

Kasten *et al.* (2020) utilisent un réseau de type V-Net (Milletari, Navab & Ahmadi, 2016) (figure 2.11) afin de reconstruire les os du genou à partir de deux radiographies orthogonales où un seul genou est visible à l'aide d'une grille de voxels. Le réseau de neurones est entraîné sur des DRR de CT scans segmentés du genou. Afin d'éviter d'obtenir des erreurs liées à la différence de distribution d'intensité entre les radiographies et les DRR, un réseau de type CycleGAN (Zhu, Park, Isola & Efros, 2020) est entraîné afin de transformer les radiographies en DRR. La figure 2.12 présente le transfert de style effectué par la méthode de Kasten *et al.* (2020). Le changement de distribution d'intensité fait en sorte que le réseau de neurones généralise beaucoup mieux à de vraies radiographies.

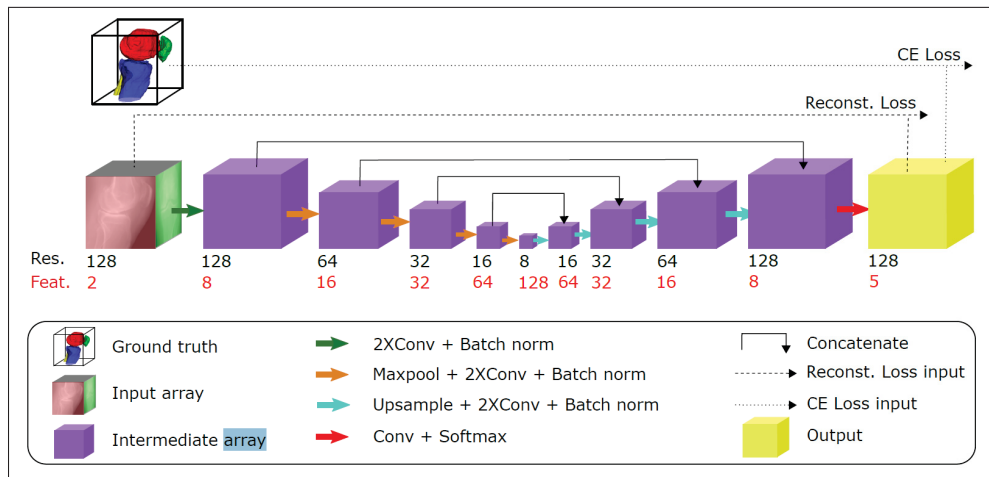


Figure 2.11 Méthode de reconstruction 3D des os du genou proposée par Kasten *et al.* (2020)
Tirée de Kasten *et al.* (2020)

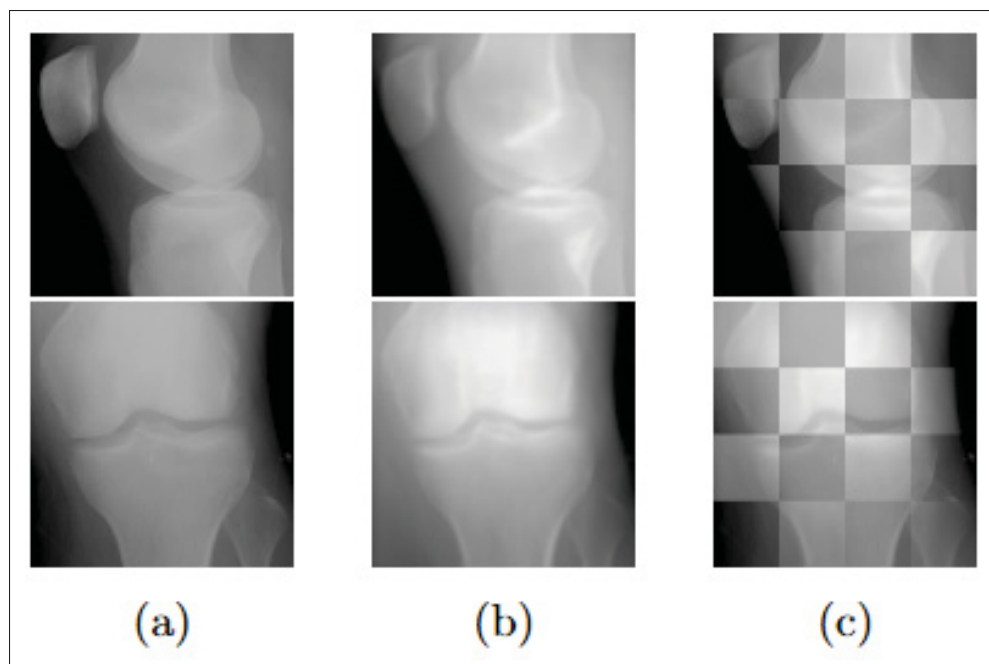


Figure 2.12 Transfert de style appliqué d'une radiographie (a) à la DRR correspondante (b) avec la comparaison d'entrée et de sortie du réseau (c)

Tirée de Kasten *et al.* (2020)

Le modèle est entraîné à l'aide d'une fonction de coût à deux composantes : le coefficient DICE entre les volumes reconstruits et les volumes de référence et la corrélation croisée normalisée des gradients entre les DRR des volumes reconstruits et des volumes de références. Deux ensembles de données sont utilisés pour évaluer la méthode : un ensemble de 20 CT scans du genou segmenté avec les DRR obtenus de ces CT et un ensemble de radiographies réelles où les os du fémur ont été segmentés en 2D par des cliniciens. Lorsque les DRR des 20 CT de genou segmentés sont utilisés, l'erreur symétrique de Chamfer moyenne est de 1.29mm. Avec les radiographies sans modèle de référence, l'erreur symétrique de Chamfer moyenne entre les contours du fémur en 2D et les contours projetés de la reconstruction 3D est de 1.77mm lorsque le transfert de style est utilisé. Sans le transfert de style, l'erreur SCD moyenne sur les os du genou grimpe à 6.146mm. Kasten *et al.* (2020) assument que les radiographies sont créées à l'aide de sources de rayons X perpendiculaires alors que la cabine EOS utilise une source de

type "fan beam" (Groisser, 2019), il faudrait adapter la manière dont le volume initial est créé afin qu'il corresponde à la géométrie EOS.

L'annexe II présente d'autres méthodes utilisant l'apprentissage profond pour reconstruire un objet en 3D à partir d'images optiques. Ces méthodes n'ont pas une précision suffisante pour être considérée dans notre application.

2.3.3 Conclusions

Les méthodes de reconstruction 3D présentées dans cette section utilisent l'apprentissage profond pour procéder à la reconstruction 3D. Deux catégories de méthodes ont été présentées : les méthodes qui estiment une transformation à appliquer à un modèle générique et celles qui n'utilisent pas de modèles initiaux.

Les méthodes de reconstruction 3D sans modèle déformable, proposées par Choy *et al.* (2016); Yang, Wang, Markham & Trigoni (2020); Xie, Yao, Zhang, Zhou & Sun (2020), permettent de reconstruire des volumes à partir d'un nombre arbitraire d'images optiques. Ces méthodes ne permettent pas d'obtenir une reconstruction 3D précise sur l'ensemble ShapeNet (Chang *et al.*, 2015). Kasten *et al.* (2020) proposent une méthode de reconstruction 3D des os du genou à partir de deux radiographies où un seul genou est visible en face/profil. La précision des surfaces obtenues par cette méthode de reconstruction 3D est intéressante. Elle s'appuie sur une méthode de transfert de style afin de transformer la distribution d'intensité des radiographies réelles en celle des DRR utilisées pour entraîner le modèle 3D comme le fait Aubert *et al.* (2022) en recalage.

Les méthodes déformant un modèle générique s'appuient presque toutes sur les fondements des algorithmes de recalage. Les méthodes de Pei *et al.* (2017); Li *et al.* (2020) permettent de reconstruire le crâne à partir d'une radiographie. Ces deux méthodes sont évaluées à l'aide de points clés identifiés en 2D, ce qui fait en sorte qu'il est difficile d'évaluer la précision du modèle 3D complet. L'utilisation de ces modèles de déformation avec un petit nombre de degrés de liberté nous semble contre-intuitive dans un contexte d'apprentissage profond, où nous

devrions chercher à maximiser le contrôle de la déformation estimée. Les méthodes proposées par Van Houtte *et al.* (2021, 2022) permettent d'obtenir une représentation volumique du fémur précise, mais nécessite que le fémur soit pré segmenté. De plus, les auteurs indiquent que la méthode proposée par Kasten *et al.* (2020) permet d'obtenir une meilleure reconstruction 3D de la surface.

La méthode proposée par Kasten *et al.* (2020) possède quelques désavantages. Premièrement, elle est adaptée à une projection parallèle et la convertir vers une projection de type "fan-beam" comme celle de la cabine EOS serait complexe. De plus, l'utilisation de la grille de voxels n'est pas efficace d'un point de vue computationnel, ce qui fait en sorte que la résolution de la reconstruction 3D finale doit être basse (1mm^3). La méthode de Wen *et al.* (2019) est une méthode qui provient de l'imagerie optique. Elle permet de reconstruire différentes classes d'objets à partir d'un nombre arbitraire d'images et elle obtient les meilleures erreurs de reconstruction. En plus de la performance de cette méthode dans son domaine d'application, la méthode apprend à déformer un maillage 3D. Les revues de Han *et al.* (2019); Fu *et al.* (2021); Fahim *et al.* (2021) indiquent que l'utilisation des maillages en reconstruction 3D par apprentissage profond permettrait une reconstruction 3D plus précise et que la seule limitation à son adoption est que peu d'architectures sont disponibles pour traiter ce type de données. De plus, comparativement aux méthodes de recalage classique, la méthode apprend à estimer un champ de déformation dense à appliquer au modèle 3D générique. La déformation dense fait en sorte que le réseau de neurones a le contrôle total sur la forme finale de l'objet à reconstruire. En utilisant un modèle 3D générique de fémur plutôt qu'un ellipsoïde, comme les auteurs le font, et que nous n'entraînions le réseau de neurones qu'à reconstruire le fémur, il est possible de croire que la reconstruction 3D pourrait être plus précise que les autres méthodes proposées dans la littérature et robuste malgré son haut nombre de degrés de liberté. Comme l'extraction des caractéristiques et la déformation sont toutes deux apprises par le même réseau de neurones, avec la même fonction de coût, nous croyons que cette méthode pourrait permettre de diminuer les erreurs de correspondances qui peuvent se produire habituellement en reconstruction 3D classique, comme nous l'avons vu à la section 2.2. Toutefois, la méthode de Wen *et al.* (2019)

est une méthode qui n'a jamais été expérimentée sur des radiographies. Il est donc possible que les caractéristiques extraites par le CNN pour chaque sommet du modèle générique ne soient pas bien représentatives de la position du sommet dans la radiographie.

Finalement, il est important de noter que peu de méthodes sont évaluées dans des contextes réalistes. Les images utilisées pour entraîner ou valider le modèle sont souvent des images de synthèse où la pose de l'objet est connue d'avance et où ce dernier est déjà segmenté.

2.4 Nombre et points de vue utilisés

Dans le protocole d'acquisition clinique standard de la cabine EOS, deux radiographies sont produites : une de face et une de profil. Il est parfois possible qu'un patient ait à subir plusieurs acquisitions EOS dans des positions différentes, par exemple lors du calcul de la pseudo-cinématique du genou (Kanhonou, 2017). Dans ces cas, il pourrait être souhaitable d'utiliser l'ensemble des radiographies disponibles pour un patient afin d'améliorer la reconstruction 3D du fémur, ce qui serait complexe avec la méthode actuelle de Chaibi (2010), puisque l'opérateur aurait à poser les points de contrôle et superposer les contours sur plusieurs radiographies ce qui demanderait une grande charge cognitive et beaucoup plus de temps. Nous étudierons ici l'impact de la pose de l'objet dans les images utilisées ainsi que le nombre d'images utilisées pour procéder à la reconstruction 3D.

2.4.1 Impact de la pose dans l'image

Jianhua Yao & Taylor (2003) évaluent l'impact de la position du patient dans la cabine et de l'angle entre les radiographies sur la reconstruction du pelvis, lorsque deux radiographies calibrées sont utilisées. La figure 2.13 présente le pourcentage de superposition des volumes reconstruits et des volumes de référence pour deux ensembles de données. La figure de gauche permet de constater que la superposition est à son maximal lorsque les deux radiographies sont orthogonales, ce qui est déjà le cas pour les radiographies EOS. La figure de droite permet de constater que la position du patient dans la cabine, lorsque les radiographies sont orthogonales,

n'influence pas vraiment la qualité de la reconstruction 3D finale. La reconstruction 3D optimale est obtenue lorsque l'angle entre deux radiographies est de 90 degrés. Van Houtte *et al.* (2022) évaluent l'impact de l'angle entre les radiographies ainsi que de la position du patient et détermine que d'avoir deux radiographies avec un angle de $[80, 100]^\circ$ où le patient est visible de face sur la première radiographie permet d'obtenir la reconstruction 3D la plus précise.

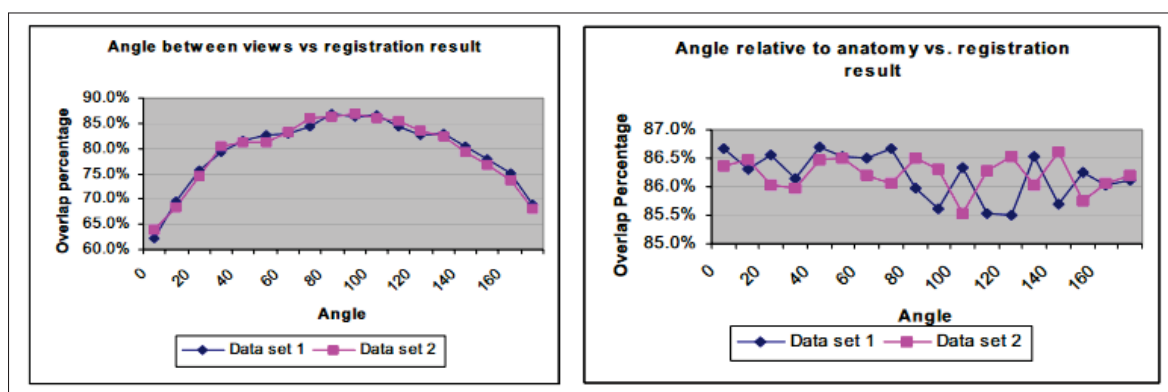


Figure 2.13 Impact de l'angle entre les deux radiographies sur la précision de forme de la reconstruction 3D (gauche) et impact de la position du patient lorsque deux radiographies orthogonales sont utilisées (droite)
Tirée de Jianhua Yao & Taylor (2003)

Nous avons remarqué que les combinaisons de points de vue utilisés lors des expérimentations utilisant plusieurs radiographies ne sont pas toujours bien décrites dans les articles. Jianhua Yao & Taylor (2003) ne présentent pas les points de vue utilisés pour évaluer leur algorithme en multivues. Sadowsky (2007) proposent d'utiliser des radiographies à 0, 30, 45 ou 90 degrés avec des translations du fémur sans indiquer quels points de vue sont utilisés lorsque deux ou trois radiographies sont utilisées. Zhu & Li (2011) ajoutent des radiographies où le fémur est vu en incréments de 18 degrés de rotation. Il est donc légitime de se demander si la précision de forme maximale de 0.3mm (ASD moy.), obtenue à 19 radiographies, aurait pu être obtenue plus rapidement si l'écart entre les radiographies utilisées avait été plus grand. Zheng *et al.* (2009) utilisent les vues faces/profil et ajoutent une radiographie à 45 degrés. Baka *et al.* (2012) évaluent l'algorithme sur une séquence d'images fluoroscopiques d'un patient. À notre avis, un problème avec cette solution est qu'il faut constamment ré-estimer la position du fémur à travers les radiographies alors que lorsque système EOS est utilisé, la pose du fémur peut

être estimée une seule fois à l'aide de toutes les radiographies présentes. Cerveri *et al.* (2017) évaluent leur algorithme de reconstruction avec des radiographies face/profil en ajoutant une vue à 45 degrés, une à 135 et une à 180 pour finalement atteindre 5 vues. En s'appuyant toujours sur l'expérimentation de Jianhua Yao & Taylor (2003), nous croyons que d'utiliser N radiographies avec un angle de $\frac{180}{N}$ permet d'obtenir un maximum d'information. Comme le montre le tableau 2.4, les erreurs de reconstruction obtenues par Cerveri *et al.* (2017) diminuent davantage lorsque les radiographies à 0, 45 et 90 degrés sont utilisées et moins lorsque les radiographies à 135 et 180 degrés sont utilisées. Ces résultats nous semblent logiques puisque l'information disponible dans une radiographie à 0 et 180 degrés de rotation axiale est pratiquement la même à cause de la transparence des os dans les radiographies. Pour les méthodes de reconstruction 3D multivues en apprentissage profond, les points de vue utilisés sont générés aléatoirement (Choy *et al.*, 2016; Kar, Häne & Malik, 2017; Wen *et al.*, 2019; Yang *et al.*, 2020). Ces méthodes ne cherchent pas à évaluer quels points de vue permettent d'obtenir la reconstruction 3D la plus précise, mais seulement à évaluer si l'ajout d'images permet d'améliorer la précision de forme. Comme nous pouvons le voir dans le tableau 2.4, l'ajout d'images au processus de reconstruction permet d'améliorer substantiellement la précision de forme de la reconstruction 3D pour les premières images ajoutées, mais l'ajout d'images subséquentes influence moins la précision de forme de la reconstruction finale.

2.4.2 Impact du nombre d'images utilisées

Nous avons relevé dans la littérature plusieurs méthodes de reconstruction 3D qui permettent d'utiliser un nombre arbitraire d'images. Ces méthodes ainsi que l'évolution de leur métrique d'évaluation en fonction du nombre d'images utilisées sont présentées dans le tableau 2.4. La suite de cette section portera sur l'étude de ce tableau et des constats qui peuvent en sortir.

En recalage classique, Jianhua Yao & Taylor (2003); Sadowsky (2007); Zheng *et al.* (2009); Zhu & Li (2011); Baka *et al.* (2012); Cerveri *et al.* (2017) estiment la transformation à apporter à leur modèle 3D en optimisant la somme de leur fonction de coût sur l'ensemble des radiographies utilisées. Le tableau 2.4 permet de montrer une amélioration de la précision de forme des

Tableau 2.4 Erreurs des méthodes de reconstruction 3D multivues en fonction du nombre de vues utilisées

Article et métrique	Nombre de vues utilisées et résultats									
	Par recalage 3D/2D non rigide									
Jianhua Yao & Taylor (2003)	1	2	3	4	5	6				
IoU (%)	64.2	86.3	87.9	88.4	89.3	90.1				
Zheng et al. (2009)	2				3					
SHD moy. (mm)	1.1				0.92					
Sadowsky (2007)	3			6			8			
P2S moy. (mm)	2.17			2.08			2.08			
Zhu & Li (2011)	1	2	5	10	15	19				
ASD moy. (mm)	0.84	0.46	0.33	0.33	0.3	0.3				
Baka et al. (2012)	1				125					
P2S moy. (mm)	1.53				1.48					
Cerveri et al. (2017)	2		3		4		5			
P2S RMS	1		0.75		0.75		0.73			
	Par apprentissage machine									
Choy et al. (2016)	1	2	3	4	5					
IoU (%)	45.5	48.9	50.1	50.6	51.2					
Kar et al. (2017)	1		2		3		4			
IoU (%)	61.5		72.1		76.2		78.2			
Wen et al. (2019)	2		3		4		5			
SCD moy.	0.52		0.48		0.46		0.45			
Xie et al. (2020)	1	2	3	4	5	8	12	16	20	
IoU (%)	66.1	68.6	69.3	69.7	69.9	70.2	70.4	70.5	70.6	
Yang et al. (2020)	1	2	3	4	5	8	12	16	20	24
IoU (%)	64.2	66.2	67.1	67.6	67.8	68.6	68.8	69.3	69.4	69.4

méthodes de reconstruction 3D en fonction de l'ajout de radiographies. Les méthodes de Jianhua Yao & Taylor (2003); Zhu & Li (2011) présentées dans ce tableau permettent de montrer que l'erreur diminue surtout lorsque l'on passe d'une radiographie à deux, où leur erreur diminue respectivement de 35.8% à 13.7% (IoU) et de 0.84mm à 0.46mm (ASD moy.). Les ajouts subséquents de radiographies permettent tout de même d'améliorer la précision de la reconstruction 3D, mais avec moins d'impact. Zheng et al. (2009); Zhu & Li (2011); Baka et al. (2012); Cerveri et al. (2017) utilisent tous un recalage 3D/2D non rigide basé sur un modèle de déformation SSM avec une extraction de contours, ce qui indique que ce type de

méthodes pourrait être mieux adapté à la reconstruction 3D multivues du fémur. Škerl *et al.* (2006) indiquent aussi que les méthodes de recalage iconique seraient moins robustes lorsque des images sont ajoutées, parce que l'optimisation de la fonction de coût est plus susceptible de converger vers un minimum local dû au volume de correspondances à établir entre les différentes radiographies. Bien que cet article soit relativement vieux, nous n'avons pas trouvé dans la littérature d'autres méthodes de recalage iconique utilisant plus de deux vues.

En apprentissage profond, nous avons relevé à la section 2.3 différentes méthodes d'effectuer des reconstructions multivues. Comme nous l'avons indiqué plus haut, les points de vue utilisés pour les méthodes de Choy *et al.* (2016); Kar *et al.* (2017); Wen *et al.* (2019); Xie *et al.* (2020); Yang *et al.* (2020) sont aléatoires. Cela fait en sorte qu'il est difficile de comparer les résultats d'une méthode à l'autre, surtout en considérant que l'algorithme de reconstruction 3D ainsi que l'algorithme de fusion d'information ne sont pas les mêmes. De plus, l'ensemble de ces méthodes, à l'exception de celle de Wen *et al.* (2019), reconstruisent le modèle sous forme de volume 3D et comme les résolutions sont différentes d'une méthode à l'autre, la comparaison des métriques de performance n'est pas pertinente non plus. Toutefois, nous pouvons constater que l'ajout d'images permet d'améliorer la précision de la reconstruction 3D jusqu'à un certain point. Les méthodes de Xie *et al.* (2020); Yang *et al.* (2020) évaluent leur algorithme avec une vingtaine d'images, mais nous pouvons constater que la précision de la reconstruction 3D croît de manière logarithmique en fonction du nombre d'images ajoutées.

Cette section a permis de démontrer l'utilité d'ajouter des radiographies au processus de reconstruction 3D afin d'améliorer la précision, peu importe la méthode de reconstruction 3D choisie. Par contre, nous avons aussi constaté que peu d'études relatent de l'impact des différents points de vue choisis lors d'une reconstruction 3D multivues. Une étape plus approfondie à ce sujet pourrait mener à constater qu'il est possible d'obtenir de grands gains de précision de forme avec peu de radiographies si les bons points de vue sont choisis.

2.5 Évaluation des méthodes de reconstruction 3D

Afin de comparer la méthode que nous développerons à la littérature, nous devons d'abord recenser les métriques utilisées pour quantifier la qualité d'une reconstruction 3D par rapport à un modèle de l'os attendu. Ce modèle attendu peut être obtenu par segmentation d'un CT scan, par numérisation d'un os cadavérique ou encore à l'aide d'une autre méthode de reconstruction 3D (Jannin *et al.*, 2002). Il est important de noter que les différentes méthodes présentées dans les sections précédentes ne sont généralement pas évaluées sur les mêmes bases de données. Les bases de données peuvent provenir de modalités différentes et contenir des patients plus ou moins sains. Par exemple, Cerveri *et al.* (2017) construisent une base de données à partir de patients sains et de patients ayant une arthrose sévère du genou. Considérant cela, il est difficile de comparer directement les méthodes proposées dans la littérature puisqu'une base de données utilisée pour une méthode pourrait contenir des patients plus sains ou bien des patients plus similaires ce qui permettrait d'obtenir de meilleurs résultats que lorsque des fémurs pathologiques sont utilisés. Les erreurs présentées au fil de la revue de la littérature permettent tout de même d'établir un ordre de grandeur des erreurs obtenues en fonction des méthodes utilisées.

La littérature scientifique sur la reconstruction 3D utilise principalement trois métriques pour valider la qualité d'une reconstruction 3D. Ces métriques sont utilisables dans des contextes différents et permettent d'évaluer la reconstruction 3D selon différents critères. Les métriques qui seront présentées par la suite sont : la **distance point à surface** (Mitulescu *et al.*, 2001) et la **distance symétrique de Hausdorff** (Aspert, Santa-Cruz & Ebrahimi, 2002). **La distance de Chamfer** (Wang *et al.*, 2018), aussi appelée distance surfacique moyenne (Yeghiazaryan & Voiculescu, 2018), est une autre métrique utilisée dans la littérature, son équation a déjà été présentée dans la description détaillée de la méthode Pixel2Mesh++ (Wen *et al.*, 2019) à l'annexe III.

Considérons que \hat{M} est un modèle 3D de référence avec ses sommets $\hat{s}_i \in \hat{S} \subset R^3$ et M le modèle 3D reconstruit, avec ses sommets s_i .

1. **Distance point à surface moyenne (AP2S)** (équation 2.3) : Distance euclidienne moyenne entre S et la surface de \hat{M} . La distance P2S d'un point par rapport à un maillage 3D est calculée en projetant ce point sur la face la plus proche de ce dernier dans M (Mitulescu *et al.*, 2001).

$$AP2S(M, \hat{M}) = \frac{1}{|S|} * \sum_{i=1}^{|S|} \|S_i - proj(S_i, \hat{M})\|^2 \quad (2.3)$$

La fonction $proj(S_i, \hat{M})$ projette le sommet S_i à sa position la plus près dans le modèle de référence \hat{M} . Pour se faire, trois plans sont créés pour chaque face du maillage 3D. Pour rappel, un plan p est formé d'une origine O et d'une normale N . Posons f , une face composée des sommets s_i, s_j, s_k . La figure 2.14 illustre la manière dont ces plans sont créés. Pour cette face, trois plans p_{ij}, p_{jk}, p_{ki} sont créés. L'origine O de p_{ij} est située au milieu de s_i et s_j et la normale de ce plan est le vecteur perpendiculaire à la normale de la face f qui passe par l'origine O . Comme ces plans sont formés pour chaque face du modèle 3D, on peut ensuite trouver la projection de S_i sur le modèle 3D en cherchant pour quelles faces est-ce que S_i se trouve à l'intérieur des trois plans de ces faces (dans la région 5 de la figure 2.14), en projetant s_i sur chacune de ces faces et en prenant la position dont la distance perpendiculaire est la plus petite. Si s_i ne se trouve pas à l'intérieur d'aucune face, s_i est projetée sur le sommet de \hat{M} le plus près.




Figure 2.14 Plans délimitant la face composée des sommets a,b,c utilisé pour calculer la distance point à surface
Tirée de Aspert *et al.* (2002)

Aspert *et al.* (2002) expliquent en détail le fonctionnement de cette projection.

2. **Distance symétrique de Hausdorff (SHD)** (équation 2.4) : Plus grande distance des distances minimales de S vers \hat{S} et de \hat{S} vers S (Aspert *et al.*, 2002). Plus spécifiquement, les distances de Hausdorff (HD) $HD(S, \hat{S})$ et $HD(\hat{S}, S)$ sont d'abord évaluées. :

$$HD(S, \hat{S}) = \max_i(\min_j(\|s_i - \hat{s}_j\|^2))$$

$$SHD(S, \hat{S}) = \max(HD(S, \hat{S}), HD(\hat{S}, S))$$
(2.4)

3. **Distance de Chamfer moyenne (ACD)** (équation 2.5) : Moyenne des plus petites distances euclidiennes de S vers \hat{S} (Wang *et al.*, 2018). Wen *et al.* (2019) proposent de ré-échantillonner des sommets de manière uniforme sur les formes prédites et de références des sommets de manière à obtenir une erreur plus robuste aux artefacts présents dans les reconstructions 3D. Dans notre contexte, comme la forme initiale et prédite ont la même topologie et que les sommets sont déjà dispersés de manière uniforme sur les fémurs de référence, nous choisissons d'utiliser la distance de Chamfer à sa forme la plus simple.

$$ACD(S, \hat{S}) = \frac{1}{|S|} \sum_i^{|S|} \operatorname{argmin}_j \|s_i - \hat{s}_j\|^2$$
(2.5)

2.6 Conclusions

Cette revue de la littérature a permis d'explorer les méthodes de reconstruction 3D à partir d'images 2D, dans le but de reconstruire le fémur en 3D de manière automatique, à partir de radiographies orthogonales calibrées EOS. Nous avons d'abord étudié les méthodes de recalage 3D/2D non rigide ainsi que les méthodes d'apprentissage profond, pour ensuite étudier l'impact du nombre de radiographies utilisées ainsi que leur point de vue sur la qualité de la reconstruction 3D.

Les méthodes de reconstruction 3D que nous avons étudiées peuvent être catégorisées comme étant une méthode de recalage 3D/2D non rigide ou d'apprentissage profond. En recalage 3D/2D, les méthodes de déformation statistiques sont très communes et permettent d'obtenir une reconstruction 3D qui est précise et robuste. Toutefois, la précision de forme maximale de l'algorithme est déterminée par la base de données utilisée pour construire le modèle statistique. La majorité des méthodes de déformation statistiques s'appuient sur l'analyse en composantes principales, qui est une méthode de réduction de dimensions linéaire. Cootes *et al.* (1995) indiquent que l'utilisation d'une méthode linéaire limite la complexité des déformations qui peuvent être observées par l'ACP. Bien que ces méthodes soient très populaires et qu'elles aient fait leurs preuves, nous croyons qu'il serait possible d'obtenir une reconstruction 3D plus précise et robuste à l'aide d'un algorithme d'apprentissage profond, puisque ces méthodes peuvent apprendre des relations non linéaires complexes entre les éléments de la base de données d'entraînement (Goodfellow *et al.*, 2016). De plus, les méthodes d'apprentissage profond pourraient permettre d'obtenir de meilleures reconstructions 3D pour des populations qui ne sont pas bien représentées dans la base de données initiales que les méthodes s'appuyant sur les modèles statistiques de forme.

Nous avons relevé deux méthodes intéressantes dans notre revue des méthodes de reconstruction 3D par apprentissage profond. La première est celle de Kasten *et al.* (2020), qui reconstruit la surface des os du genou à partir de deux radiographies orthogonales calibrées, sans modèle a priori. Par contre, la méthode n'est pas conçue pour être utilisée avec plus de deux radiographies et notre revue de littérature montre que nous aurions intérêt à pouvoir utiliser toutes les radiographies disponibles pour un patient afin de procéder à la reconstruction 3D. La deuxième méthode que nous avons relevée est Pixel2Mesh++ (Wen *et al.*, 2019). Il s'agit d'une méthode de reconstruction 3D appliquée en imagerie optique, sur ShapeNet (Chang *et al.*, 2015). Cette méthode permet de déformer un maillage 3D de manière dense, c'est-à-dire qu'un vecteur de déplacement est estimé pour chaque sommet du modèle initial, ce qui permettrait théoriquement de reconstruire n'importe quel fémur. Cette méthode peut intégrer facilement un nombre arbitraire d'images et intègre toutes les étapes du recalage classique en un seul réseau de neurones, où

l'apprentissage de chaque étape se fait directement en fonction des erreurs obtenues entre les modèles reconstruits et les modèles de référence. Cela veut dire que le CNN d'extraction des caractéristiques serait entraîné à identifier le fémur dans les radiographies, à associer des régions dans les radiographies aux régions du modèle générique de fémur 3D et donc d'éviter les difficultés et limitations connues des algorithmes de recalage classiques présentés dans la section 2.2.

La section 2.4 présente l'influence du nombre de radiographies utilisées lors de la reconstruction 3D. Cette section nous a permis de constater que d'augmenter le nombre d'images dans le processus de reconstruction 3D permet aussi d'améliorer la précision de la reconstruction 3D finale, et ce, pour l'ensemble des méthodes présentées. Il serait donc avantageux de développer un algorithme de reconstruction 3D capable d'utiliser un nombre variable de radiographies afin d'augmenter la précision de la reconstruction 3D lorsque plusieurs radiographies sont disponibles pour un patient. Les différents points de vue utilisés lorsque plusieurs radiographies sont utilisées ne sont pas clairement définis dans ces articles. Il serait crédible de penser que des points de vue présentant de l'information complémentaire permettraient d'obtenir une reconstruction 3D encore plus précise, mais nous n'avons pas été en mesure de trouver cette information dans la littérature, puisque la majorité des articles n'expliquent pas quelles combinaisons de vues sont utilisées lorsque plus de deux radiographies sont utilisées.

CHAPITRE 3

PROBLÉMATIQUES, OBJECTIFS ET PROPOSITIONS MÉTHODOLOGIQUES

Comme indiqué dans la section 1.3, la méthode de reconstruction 3D actuellement disponible dans la plateforme commerciale d'EOS Imaging, SterEOS, est optimisée pour reconstruire de manière semi-automatique le fémur en 3D afin d'obtenir des paramètres cliniques robustes et précis. À notre avis, cette méthode ne permet pas de déformer suffisamment localement le modèle générique de fémur utilisé pour reconstruire de manière précise les détails dans le fémur proximal et distal, dû aux limitations de la déformation MLS présentée à la section 2.2.3. De plus, l'intervention d'un opérateur formé en analyse d'images médicales est nécessaire pour obtenir la reconstruction 3D, ce qui en limite l'usage clinique. Nous chercherons donc à mettre en place une nouvelle méthode de reconstruction 3D du fémur qui permettrait d'obtenir une reconstruction plus précise sur l'ensemble du fémur 3D tout en limitant l'intervention d'un opérateur externe.

La revue de littérature au chapitre 2 nous a permis de relever quatre problèmes avec les méthodes de reconstruction 3D actuellement utilisées qui sont particulièrement contraignants dans notre application :

1. **Les méthodes de reconstruction 3D d'os à partir de radiographies utilisent majoritairement un modèle statistique basé sur l'ACP pour déformer le modèle 3D en fonction des déformations observées dans une base de données utilisée pour construire le modèle.** L'analyse en composantes principales étant une méthode de réduction de dimension linéaire, l'algorithme n'exploite pas au maximum l'information de forme présente dans les différents exemples de la base de données ;
2. **Les méthodes de déformation 3D utilisée dans la littérature, qu'elles soient statistiques ou non, sont souvent contrôlées par un petit ensemble de points de contrôle,** ce qui a l'avantage d'être moins lourd en termes de calcul et de faciliter le travail d'un opérateur dans le cas des algorithmes semi-automatiques. Par contre, ce petit nombre de degrés de

liberté fait en sorte que les déformations appliquées au modèle 3D générique sont plus globales et que certaines régions du fémur sont moins bien reconstruites ;

3. **L'analyse automatique des radiographies 2D est complexe car ces images sont bruitées, les différentes structures sont superposées et, comparativement aux images optiques, les structures ont un degré de transparence lié à leur capacité d'absorption des rayons X.** Ces défis font en sorte que l'extraction des caractéristiques des radiographies, qu'elles soient géométriques ou iconiques, est complexe et sujette à l'erreur. Les erreurs dans l'extraction des caractéristiques peuvent être atténuées lors de la mise en correspondance des caractéristiques 2D/3D, si l'algorithme utilisé est robuste à ce type d'erreur. Par contre, la mise en correspondance des caractéristiques 2D/3D est aussi un processus complexe, ce qui fait en sorte que des erreurs sont possibles même si la segmentation est excellente.
4. Les méthodes d'apprentissage profond tentent de résoudre la propagation des erreurs entre l'extraction des caractéristiques, la mise en correspondance de ces dernières et la déformation d'un modèle générique propre aux algorithmes classiques de recalage 3D/2D non rigide. Par contre, **ces méthodes sont majoritairement limitées par les architectures de réseaux de neurones mal adaptées pour représenter des structures comme des surfaces 3D.** La majorité des méthodes utilisent un réseau de neurones à convolution sur une grille de voxels, mais ces méthodes ne sont pas bien adaptées à représenter des surfaces lisses et sont très gourmandes en mémoire lors de l'apprentissage.

Une partie de ces problèmes se retrouvent autant dans l'initialisation de la pose que dans la déformation 3D du modèle générique. Nous croyons toutefois que l'amélioration et l'automatisation de la déformation 3D appliquée au modèle générique sont les étapes les plus complexes et les plus sujettes aux problèmes énoncés ci-dessus. C'est en considérant cela que nous posons trois sous-objectifs à notre projet de recherche qui permettront d'avancer dans la tâche d'automatiser la reconstruction 3D du fémur à partir de radiographies EOS calibrées :

1. **Développer une méthode de déformation automatique basée sur l'apprentissage profond permettant de déformer localement un maillage 3D générique.** Comme la

déformation du modèle 3D générique sera automatique, il sera possible d'utiliser un plus grand nombre de degrés de liberté dans la déformation 3D que lorsqu'un opérateur doit guider la déformation manuellement. Van Houtte *et al.* (2022) indiquent que d'estimer un champ de déformation dense à partir d'un réseau de neurones profond permet d'utiliser un haut nombre de degrés de liberté tout en conservant une régularisation de forme due aux exemples de la base de données. Cet objectif permettra de répondre aux problèmes 1, 2 et 4. Comme les algorithmes d'apprentissage profond permettent d'apprendre des relations non linéaires complexes entre les exemples de la BD d'entraînement et qu'ils sont excellents pour traiter des données brutes, comme des images, ce type d'algorithme devrait nous permettre d'obtenir une méthode de déformation automatique précise.

2. **Extraire des caractéristiques géométriques des radiographies calibrées pour l'ensemble des sommets du modèle 3D générique.** En attribuant des caractéristiques à chaque sommet du modèle 3D, nous évitons d'avoir à mettre en correspondance les caractéristiques géométriques extraites des radiographies avec celles du modèle 3D et nous ajoutons aussi beaucoup d'information qui pourra être utilisée par l'algorithme de déformation 3D. Ce processus d'extraction de caractéristiques fera partie du réseau de neurones estimant la déformation à appliquer au modèle générique, ce qui fait en sorte que l'apprentissage de l'extraction des caractéristiques sera directement lié à l'apprentissage de la déformation à appliquer. Cet objectif permettra d'attaquer le problème 2.
3. **Développer une méthode de reconstruction 3D multi vues.** Comme la section 2.4 nous l'a démontré, la précision de forme des algorithmes de reconstruction 3D augmente avec le nombre d'images utilisées. Cet objectif permettra de répondre au problème 2. En utilisant toutes les radiographies calibrées pour un patient, nous devrions être en mesure d'améliorer la robustesse de l'extraction des caractéristiques géométriques et de fournir encore plus d'information à l'algorithme de déformation 3D automatique, ce qui devrait en augmenter la précision de forme.

Dans le cadre de ce travail de maîtrise, afin de simplifier la problématique, nous avons fait le choix de développer une méthode qui ne s'appliquera qu'à des radiographies EOS calibrées pour lesquelles la pose et la taille du fémur dans les radiographies sont déjà connues.

L'adaptation de la méthode Pixel2Mesh++, proposée par Wen *et al.* (2019), nous permettra de répondre à nos trois sous-objectifs. Il s'agit d'une méthode de déformation 3D automatique utilisant l'apprentissage profond afin d'apprendre à déformer un maillage 3D générique en fonction de caractéristiques géométriques extraites d'un nombre arbitraire d'images dont la calibration est connue et pour lesquelles la pose de l'objet est connue.

Le succès de l'application de la méthode Pixel2Mesh++ (Wen *et al.*, 2019) dans notre projet de recherche dépend de deux hypothèses :

1. **Entraîner cet algorithme à ne reconstruire qu'une seule classe d'objets, le fémur, fera en sorte que l'algorithme pourra apprendre avec plus de précision les déformations admissibles à appliquer au modèle générique en fonction des radiographies EOS calibrées qui lui seront fournies.** Cette méthode obtient les meilleurs résultats de reconstruction 3D sur l'ensemble ShapeNet (Chang *et al.*, 2015), une base de données de référence très utilisée en reconstruction 3D à partir d'images optiques qui compte treize classes d'objets à la morphologie très différente. Ces classes d'objets ont une variabilité de forme intra-classe beaucoup plus grande que ce que l'on peut retrouver dans des fémurs. En reconstruisant qu'une seule classe d'objet avec une plus petite variabilité intra-classe, la précision géométrique obtenue devrait être plus élevée que celle qui a été obtenue par la méthode originale.
2. **Le CNN d'extraction de caractéristiques devrait pouvoir apprendre à distinguer des caractéristiques d'images pertinentes à la déformation 3D, malgré la superposition des contours bruités des os ainsi que la transparence des structures.** Comme la méthode Pixel2Mesh++ projette l'ensemble de ses sommets sur l'ensemble des images calibrées à sa disposition, la mise en correspondance des caractéristiques géométriques 2D et des sommets du modèle générique 3D est explicite, ce qui devrait faciliter le processus de reconstruction 3D.

Nos contributions méthodologiques sont :

1. D'adapter et d'entraîner Pixel2Mesh++ en remplaçant l'étape de génération grossière et l'ellipsoïde initial utilisés dans Wen *et al.* (2019) par un modèle 3D générique de fémur. Cette modification permettra de rapprocher le modèle générique des fémurs de référence et permettra au réseau de neurones de n'avoir qu'à apprendre des déformations locales. Le retrait de la déformation grossière permettra aussi de réduire le nombre de couches du CNN d'extraction de données ;
2. D'évaluer l'impact du nombre et de la prise de vues des différentes radiographies EOS calibrées utilisés pour la déformation 3D automatique. Cette évaluation permettra de déterminer si la combinaison de certaines prises de vues permet une meilleure précision de forme dans la déformation 3D que d'autres, de déterminer l'apport des nouvelles radiographies à la précision de forme et de potentiellement proposer des combinaisons de points de vue optimales qui pourraient être utilisées conjointement à notre méthode.

CHAPITRE 4

MÉTHODOLOGIE

Ce chapitre permet de décrire les modifications appliquées à Pixel2Mesh++ et les étapes effectuées afin d'entraîner le modèle Pixel2Mesh++ modifié et de l'évaluer.

4.1 Modifications appliquée à Pixel2Mesh++

Pour rappel, la méthode Pixel2Mesh++ (figure 4.1) est composée de trois modules (présentés à l'annexe III). Un CNN servant à extraire des caractéristiques des différentes images (*Perceptual Network* dans la figure 4.1); un modèle de génération grossière permettant de déformer un ellipsoïde initial vers la forme globale de l'objet à reconstruire (*Coarse Shape Generation*); et un module de déformation fine multivues qui affine le modèle 3D en déformant ce dernier sommet par sommet (*Multi-View Deformation Network*).

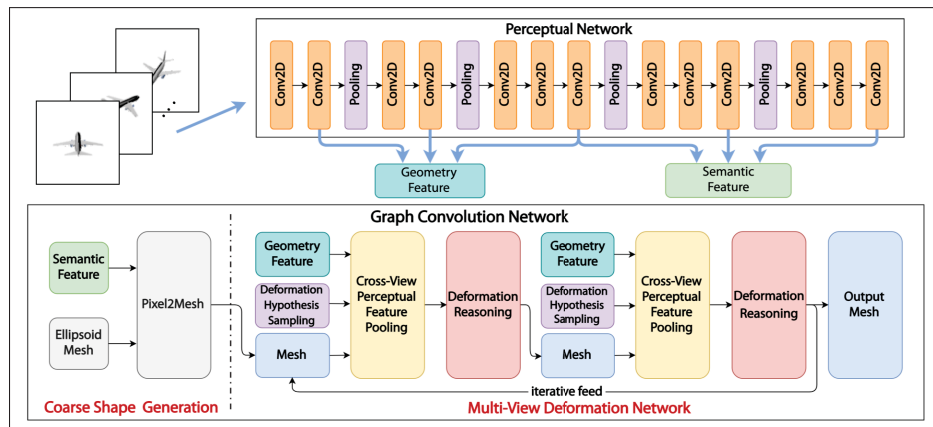


Figure 4.1 Architecture de l'algorithme Pixel2Mesh++
Tirée de Wen *et al.* (2019)

La figure 4.2 présente l'architecture proposée afin de déformer automatiquement le fémur générique à partir d'un nombre arbitraire de radiographies EOS à l'aide d'une version modifiée de Pixel2Mesh++. Chaque radiographie EOS sera donnée en entrée au CNN VGG8 afin d'en extraire les caractéristiques. Par la suite, les hypothèses de déplacement seront échantillonnées pour chaque sommet du modèle 3D de fémur générique de la méthode de Chaibi (2010). Ces

sommets et leurs hypothèses de déplacement seront projetés sur les différentes radiographies à l'aide des paramètres de calibration de ces dernières et à la pose connue du fémur dans les radiographies afin d'obtenir les caractéristiques extraites du CNN correspondant à chaque point 3D. Les moyennes, écarts-types et maximums des caractéristiques de chaque point 3D seront calculés en fonction du nombre de radiographies afin d'être concaténés dans un vecteur de caractéristiques final avec la position du point 3D correspondant. Chaque sommet du modèle 3D, avec son graphe d'hypothèses et les caractéristiques associées à chaque point, sera ensuite donné en entrée au GCN qui estimera le déplacement à effectuer sur le sommet de manière à déformer le modèle.

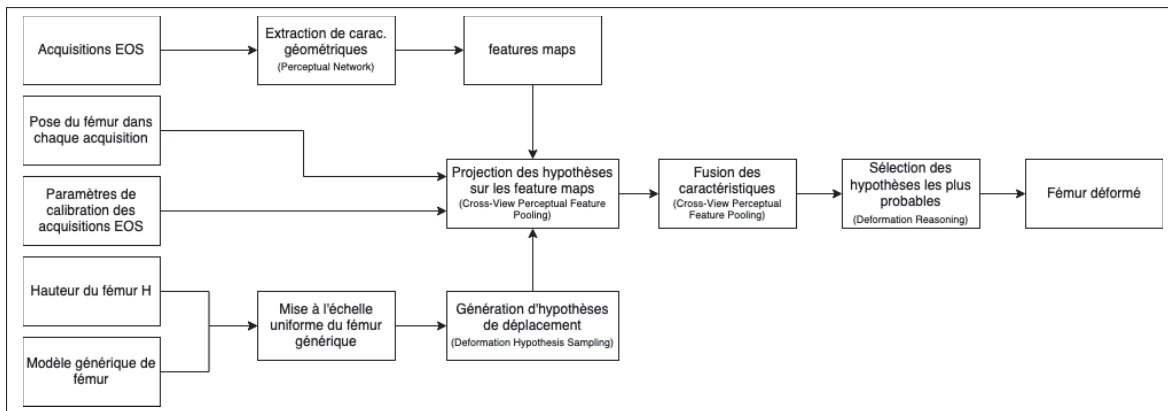


Figure 4.2 Architecture proposée

Comme nous l'avons indiqué au chapitre 3, notre principale modification est de remplacer le module de déformation grossière ainsi que l'ellipsoïde initial par un modèle générique de fémur. L'étape de génération grossière est nécessaire dans l'architecture originale puisque la classe d'objet à reconstruire n'est pas connue d'avance. Dans notre cas, nous voudrions toujours reconstruire un fémur, il n'est donc pas nécessaire de commencer le processus de déformation avec un ellipsoïde, qui est très loin de la forme d'un fémur. Ce remplacement devrait permettre, en théorie, de n'utiliser que le module de déformation fine multivues afin de déformer le modèle 3D de fémur en fonction des radiographies. Cela permettra aussi d'éviter d'utiliser le module de génération grossière qui doit apprendre des déformations complexes à partir d'un grand ensemble de données. De retirer ce module fait aussi en sorte que les caractéristiques sémantiques extraites

par le VGG16 ne sont plus nécessaires, puisqu'elles n'étaient utilisées que dans ce module. Comme la moitié des couches du réseau de neurones sont retirées, nous référerons maintenant au CNN d'extraction de caractéristiques par le nom VGG8. Le modèle initial, présenté à la figure 4.3 est le modèle générique de la méthode de Chaibi (2010), aussi utilisée dans la plateforme commerciale SterEOS. Nous avons choisi de conserver ce modèle 3D dans une optique de rétrocompatibilité avec les calculs de paramètres cliniques existants dans le logiciel SterEOS, mais aussi parce que des régions ont déjà été déterminées pour ce modèle 3D. Il s'agit d'un maillage 3D de fémur droit possédant 2433 sommets dont les sommets sont répartis de manière relativement uniforme.




Figure 4.3 Modèle générique régionalisé de fémur
Tirée de Chaibi (2010)

4.2 Description des données utilisées

Notre base de données contient 350 radiographies EOS calibrées pour lesquels 699 fémurs ont été reconstruits à l'aide de la méthode de Chaibi (2010) présentée à la section 1.3. L'utilisation de ces données est approuvée par le certificat d'éthique CE14.368-MITACS-MEDTEQ. Afin de faciliter l'apprentissage du réseau de neurones et d'avoir suffisamment de données pour apprendre au réseau à caractériser les différentes déformations possibles du fémur, seuls des fémurs droits sont utilisés pendant l'entraînement et l'évaluation. Les 349 fémurs gauches subissent une symétrie dans le plan coronal de manière à ce qu'ils ne deviennent des fémurs droits. Comme les fémurs de référence ont été reconstruits à partir de notre modèle de fémur générique, aussi utilisé dans la méthode de Chaibi (2010), les modèles de référence et le modèle générique ont la même topologie, ce qui devrait représenter un avantage au moment de l'entraînement puisque chaque sommet du modèle générique devrait pouvoir trouver une correspondance dans chaque modèle de référence. 80% des 699 fémurs (561) sont utilisés pour entraîner notre modèle d'apprentissage profond, 10% (69) pour valider les choix d'architecture ainsi que les hyperparamètres choisis et le 10% (69) final sera utilisé afin d'évaluer la méthode. Afin d'éviter tout biais dans notre méthode, nous nous assurons aussi que deux fémurs appartenant à un même patient se retrouvent toujours dans le même ensemble de données.

4.2.1 Extraction de la pose et de l'échelle

La pose et la taille de chacun des 699 fémurs sont extraites en fonction de leur position dans le référentiel patient par rapport au modèle générique. Ce modèle générique est positionné de manière à ce que le barycentre du modèle soit à l'origine $O = (0, 0, 0)$, que l'axe bicondylien (défini à la section 1.1) soit aligné avec l'axe sagittal (X) et que l'axe diaphysaire soit aligné avec l'axe transversal (Z) (voir figure 4.4).

La pose et la taille, qui devront être fournies en entrée à notre méthode de déformation 3D automatique, pourront ensuite être utilisées pour superposer le modèle générique aux fémurs présents dans les radiographies EOS calibrées. Ceci permettra d'initialiser le processus de




Figure 4.4 Positionnement du modèle générique dans le référentiel EOS

déformation en positionnant le modèle générique de la manière la plus précise possible sur les radiographies EOS. Avec cette initialisation, il ne restera donc qu'à déformer le modèle générique afin de reconstruire le fémur du patient. Afin de calculer la pose du fémur du patient, dont les sommets seront représentés par \hat{S} par rapport au fémur générique initial (\bar{S}) ainsi que sa taille, quatre étapes sont nécessaires. Nous décrirons ci-dessous les étapes permettant d'obtenir $T_{\hat{S} \leftarrow \bar{S}}$, la transformation affine permettant d'aligner le fémur du patient sur le fémur générique et d'avoir une taille similaire entre ces deux fémurs. En calculant $T_{\hat{S} \leftarrow \bar{S}}$, il est possible d'aligner tous les fémurs de référence avec le modèle générique, ce qui nous permet de ne prétraiter que le modèle générique pour le positionner adéquatement dans le référentiel patient et d'aligner au mieux l'axe diaphysaire avec l'axe Z, ce qui permettra une meilleure visualisation du fémur lors de l'évaluation. Comme la transformation est linéaire, nous pouvons calculer l'inverse de cette transformation $T_{\hat{S} \leftarrow \bar{S}}^{-1} = T_{\bar{S} \leftarrow \hat{S}}$ afin d'obtenir les transformations qui alignent le modèle générique sur les fémurs de référence, ce qui nous permettra de projeter les sommets du modèle générique.

L'équation 4.1 présente l'équation de la première transformation T_1 , qui applique une translation permettant de superposer les barycentres de \hat{S} et \bar{S} , considérant que le barycentre de \bar{S} se trouve à l'origine $O(0, 0, 0)$.

$$T_1 = \frac{-1}{|\hat{S}|} * \begin{bmatrix} 1 & 0 & 0 & \sum_{s \in \hat{S}} s_x \\ 0 & 1 & 0 & \sum_{s \in \hat{S}} s_y \\ 0 & 0 & 1 & \sum_{s \in \hat{S}} s_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.1)$$

Cette transformation permet de superposer très grossièrement les deux modèles. Par la suite, la méthode de recalage rigide *Iterative Closest Point* (Besl & McKay, 1992) est utilisée afin d'améliorer la superposition entre les modèles. Cette méthode estime la transformation rigide T_2 qui permet de minimiser la distance moyenne entre deux ensembles de points.

Comme deux fémurs n'ont pas nécessairement la même taille à cette étape du processus, il est probable que l'ICP (Besl & McKay, 1992) converge vers un minimum local, où la superposition des fémurs ne serait pas optimale. Afin de régler ce problème, nous calculons la différence de taille entre les modèles recalés à l'aide de l'équation 4.2 et appliquons la transformation T_α (voir équation 4.3) au modèle générique.

$$\alpha = \frac{\max(\hat{S}_z) - \min(\hat{S}_z)}{\max(\bar{S}_z) - \min(\bar{S}_z)} \quad (4.2)$$

$$T_\alpha = \begin{bmatrix} \alpha & 0 & 0 & 0 \\ 0 & \alpha & 0 & 0 \\ 0 & 0 & \alpha & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.3)$$

Finalement, l'ICP est utilisée une deuxième fois (transformation T_3) afin d'ajuster plus finement la pose du fémur du patient sur le fémur générique.

La transformation $T_{\hat{s} \leftarrow \bar{s}} = T_3 * T_\alpha * T_2 * T_1$ permet d'aligner le fémur du patient au fémur générique et d'ajuster la taille du fémur du patient. La transformation inverse permet d'aligner le fémur générique au fémur du patient, c'est cette transformation que nous conservons afin de la donner en entrée à notre réseau de neurones.

4.2.2 Génération des DRR

Comme indiqué plus haut, notre base de données contient 350 radiographies EOS. Ces radiographies pourraient être utilisées directement pour entraîner notre réseau de neurones, mais nous rencontrerions deux problèmes : les contours projetés du modèle 3D du fémur du patient reconstruit avec la méthode de Chaibi (2010) ne sont pas parfaitement superposés à ceux des fémurs visibles dans les radiographies. De plus, il ne nous serait pas possible d'évaluer notre algorithme sur plus de deux radiographies, ce qui fait partie des objectifs de notre projet de recherche.

Afin de contourner ces problèmes, nous générons des DRR à partir des modèles 3D des patients reconstruits et de la méthode de Serrurier *et al.* (2012) qui est implémentée dans la plateforme SterLIO, un logiciel de prototypage de reconstruction 3D interne au laboratoire de recherche. La figure 4.5 présente une DRR générée à l'aide de cette méthode.

4.2.3 DRR depuis plusieurs points de vue

Afin de générer des DRR depuis différents points de vue à partir de notre base de données de modèles surfaciques de patients, nous appliquons une rotation au modèle 3D avant de générer la DRR. Une matrice de rotation R composée de rotations autour des axes X, Y et Z est utilisée à ces fins. La rotation en X représente le varus/valgus du fémur, la rotation en Y la flexion du genou et la rotation en Z l'orientation du fémur dans la cabine (voir figure 4.6).



Figure 4.5 Une DRR générée depuis un modèle 3D surfacique de fémur à partir de la méthode de Serrurier *et al.* (2012)

Nous présenterons les différentes poses du fémur à l'aide d'un triplet $(X^\circ, Y^\circ, Z^\circ)$ représentant les trois rotations appliquées au fémur. Afin que la rotation ait comme centre le centre du fémur, cette matrice R est composée d'une translation à l'origine et de son inverse, créant la matrice suivante :

$$R = T_{origin}^{-1} * R_z * R_y * R_x * T_{origin}$$

$$\text{où } T_{origin} = \frac{1}{|S|} * \begin{bmatrix} 1 & 0 & 0 & -\sum_{s \in S} s_x \\ 0 & 1 & 0 & -\sum_{s \in S} s_y \\ 0 & 0 & 1 & -\sum_{s \in S} s_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.4)$$

Les intervalles de rotation admissibles pour chaque axe ont été déterminés de manière à ce que la DRR du fémur reste complètement dans le champ de capture de la cabine EOS, pour limiter le volume de poses sur lesquelles expérimenter et pour conserver des valeurs réalistes par rapport à

la mobilité du fémur. En X, l'angle de rotation peut prendre la valeur de -15, 0 ou 15 degrés. En Y, de 0, 10, 20 ou 30 degrés et en Z de 0 à 225 degrés avec des incréments de 45 degrés. Le schéma 4.6 présente les rotations applicables aux modèles de référence. Pour la rotation en Z, certaines rotations ont été omises par souci de clarté.

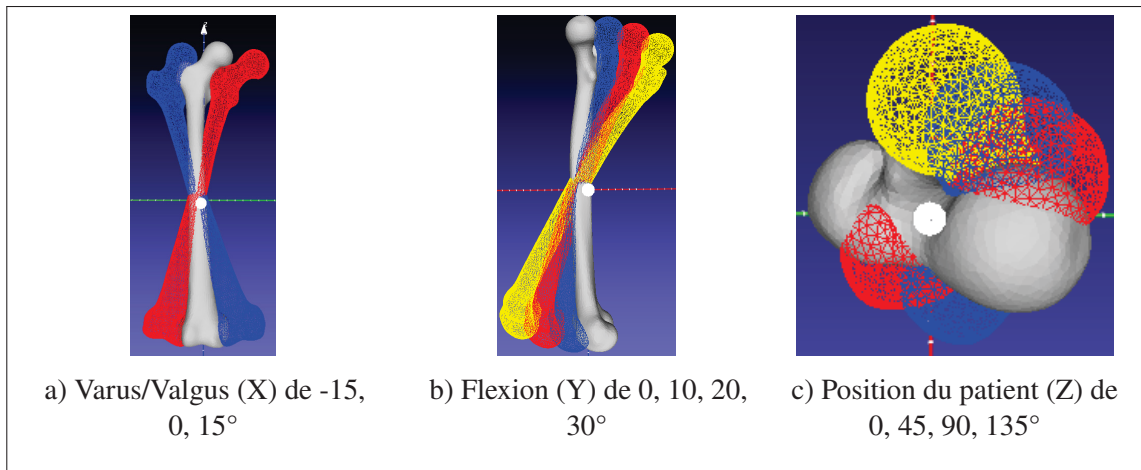


Figure 4.6 Schéma des rotations applicables au modèle de référence

La rotation en Z s'arrête à 225° puisque la deuxième radiographie acquise dans la cabine EOS lui est orthogonale. Elle aura donc un angle de $225 + 90 = 315^\circ$ avec la position "face" du fémur. Un autre ajout de 45° amènerait donc la radiographie latérale à l'angle 0 faisant en sorte que les triplets de rotation (0,0,270) et (0,0,0) présenteraient la même information. La figure 4.7 présente des DRR générées à partir de triplets de rotation avec des angles de rotation en Z de 0, 90 et 180 degrés pour un même modèle surfacique. Ces DRR présentent la même information à une symétrie et une permutation de la radiographie "frontale" et "latérale" près.

La figure 4.8 présente trois exemples de DRR acquises avec différentes poses pour un même modèle de référence.

À la fin de ce processus, nous possédons les données nécessaires pour entraîner et évaluer Pixel2Mesh++ : les DRR d'entrées, les fémurs de référence (reconstructions des fémurs patients), la taille des fémurs de référence et les paramètres de pose à appliquer au modèle générique. La prochaine étape est de traiter ces données pour maximiser l'efficacité computationnelle et la convergence de l'erreur du réseau de neurones.




Figure 4.7 Triplets de rotation menant à des radiographies identiques, à une permutation et/ou une symétrie près pour un même fémur de référence




Figure 4.8 Exemples de DRR obtenues à l'aide de triplets de rotation $(-15,0,0)$, $(0, 20, 45)$ et $(15, 20, 0)$ (de gauche à droite)

4.2.4 Préparation à l'entraînement

Deux prétraitements doivent être appliqués aux données utilisées pour l'entraînement et l'évaluation du réseau de neurones : la réduction de résolution des DRR et la normalisation des modèles 3D. La résolution des DRR en sortie du logiciel SterLIO est d'en moyenne 2000x8000 pixels, ce qui est beaucoup trop gros pour être facilement utilisable dans un contexte d'apprentissage profond. La normalisation des modèles 3D de référence et du modèle générique permettra de conserver la taille des modèles environ entre -1mm et 1mm lors de l'entraînement, ce qui fera en sorte que la magnitude des erreurs calculées lors de l'optimisation sera plus petite. La normalisation aurait pu être entre 0mm et 1mm, mais nous souhaitons conserver le barycentre du modèle générique à l'origine afin de simplifier notre processus de traitement des données. Cette manipulation est utile pour aider à l'optimisation du réseau de neurones, puisque des erreurs trop grandes peuvent mener à l'explosion des gradients (Goodfellow *et al.*, 2016).

Le processus de rognage est automatique et s'effectue en quatre étapes, présentées à la figure 4.9 : un seuillage est appliqué à l'image afin d'isoler la région de l'image contenant la DRR (4.9b). Les contours de l'image binarisée sont trouvés à l'aide de l'algorithme de Suzuki & be (1985) (4.9c) et les coordonnées du rectangle contenant ce contour sont extraites de l'image (4.9d), qui sont utilisées pour rogner l'image (4.9d). La coordonnée du sommet en haut à gauche du rectangle est conservée afin de réajuster la projection du modèle 3D dans les images.

La normalisation des modèles de référence et du modèle générique s'appuie sur une mise à l'échelle uniforme appliquée à l'ensemble des modèles de référence. Le facteur de mise à l'échelle appliqué à ces modèles, préalablement centrés à l'origine, est calculé de manière à ce que leurs coordonnées en Z soient dans l'intervalle $[-1, 1]$: $\alpha = \frac{1}{\max(\bar{S}_z) - \min(\bar{S}_z)}$. La mise à l'échelle est calculée à partir des coordonnées en Z car elles représentent la taille du fémur et qu'elles ont le plus grand écart entre la plus petite et la plus grande valeur dans cet axe. Cette mise à l'échelle est appliquée à tous les modèles de référence. Lorsque la fonction de coût est évaluée, les erreurs obtenues sont donc elles aussi diminuées d'un facteur α . Lorsque le modèle

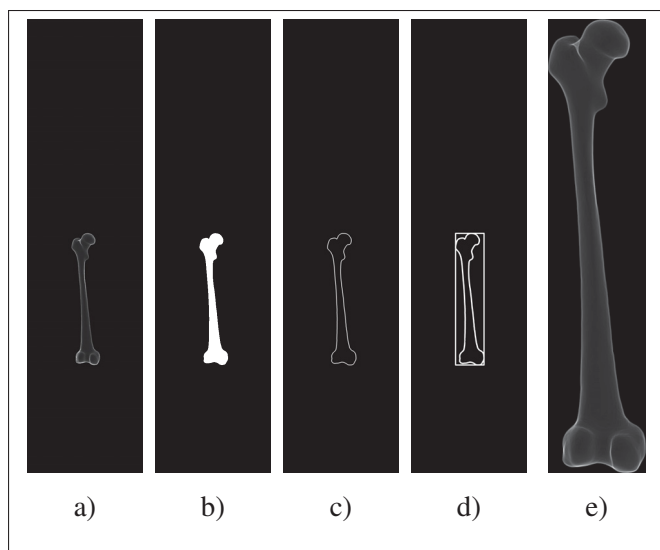


Figure 4.9 Processus de rognage automatique des DRR : un seuillage est appliqué (b), les contours sont extraits (c), une boîte englobante est définie autour du contour (d) et le rognage est effectué (e)

générique doit être projeté sur les DRR, l'inverse de cette mise à l'échelle est d'abord appliqué au modèle afin d'obtenir la bonne projection des sommets sur les DRR.

4.3 Recherche des valeurs d'hyperparamètres

Afin de maximiser la performance du réseau de neurones, les hyperparamètres du réseau de neurones doivent être choisis soigneusement. Nous définissons huit hyperparamètres (voir tableau 4.1) : le taux d'apprentissage, la norme maximale du déplacement appliquée à chaque sommet, le nombre de cellules dans les couches cachées du GCN, le taux de dropout du CNN, le taux de dropout du GCN, le poids de la fonction cosinus, le poids de la régularisation laplacienne et le poids de la régularisation de longueur d'arête. Le taux d'apprentissage ainsi que les taux de dropout sont des hyperparamètres communs en apprentissage profond. La norme maximale du déplacement appliqué à chaque sommet, présentée dans l'annexe III, détermine le déplacement maximal qu'un sommet peut effectuer à l'aide de notre algorithme de déformation automatique. Idéalement, cet hyperparamètre devrait être le plus élevé possible de manière à permettre des déplacements aussi grands que nécessaire pour superposer les sommets du modèle générique

déformé à ceux du modèle de fémur de référence. En pratique, plus la norme du déplacement est petite, plus il est facile d'optimiser le déplacement à appliquer à chaque sommet (Wen *et al.*, 2019). Le nombre de cellules dans les couches cachées du GCN est un hyperparamètre que nous avons ajouté afin de vérifier qu'une valeur autre que l'originale ne permettrait pas un meilleur apprentissage. Les poids appliqués à trois des quatre composantes de la fonction de coût permettent de pondérer leur importance dans l'apprentissage. La méthode Hyperband (Li, Jamieson, DeSalvo, Rostamizadeh & Talwalkar, 2016) est utilisée dans la littérature afin d'optimiser l'utilisation de ces ressources matérielles et du temps consacré à l'optimisation des hyperparamètres. La méthode Hyperband nécessite deux paramètres d'entrée : un facteur de réduction r de l'ensemble de valeurs d'hyperparamètres et un nombre total d'epochs n représentant le budget total de la recherche d'hyperparamètres, qui devrait être une puissance du facteur de réduction. L'algorithme découpe ensuite le budget total en $\log_r(n)$ étapes. La première étape lance n configurations pendant une epoch. Chaque étape subséquente se voit attribuée $(r^i) - (r^{i-1})$ où $i \in [1, \log_r(n)]$ epochs de calcul. À la fin d'une étape, les $1/r$ configurations d'hyperparamètres les moins performantes sont écartées. La figure 4.10 présente un exemple de l'utilisation de la méthode Hyperband lorsque $n = 81$ et $r = 3$. La première étape lance 81 configurations pendant une epoch. À la fin de cette étape, les $81/3 = 27$ pires configurations sont écartées et les configurations restantes sont lancées pendant $(r^1) - (r^{1-1}) = 2$ epochs additionnelles. À la fin, la meilleure combinaison est celle qui n'aura pas été écartée pendant les 81 epochs. Les configurations seront évaluées selon leur distance de Chamfer. Utiliser la valeur de la fonction de coût directement ne nous semble pas possible puisqu'il nous paraît évident que l'algorithme pourrait associer un fort poids aux deux paramètres de régularisation tout en minimisant le poids associé à la distance cosinus de manière à ce que le modèle n'ait qu'à apprendre à ne pas déformer le modèle. Cela ferait en sorte que les deux régularisations auraient une valeur de zéro et que cette configuration pourrait être sélectionnée malgré le fait qu'elle ne déforme pas du tout le modèle générique de fémur.

Cette méthode d'optimisation d'hyperparamètres permet de bien répartir les ressources de calcul de manière à obtenir un entraînement optimal. Il faut toutefois proposer à la méthode Hyperband




Figure 4.10 La méthode Hyperband permet de mettre en compétition différentes combinaisons d’hyperparamètres en éliminant rapidement les configurations les moins performantes

un espace de recherche pour chaque valeur d’hyperparamètre. Les intervalles de recherche pour l’ensemble des hyperparamètres sont présentés dans le tableau 4.1. Pour les poids appliqués à la fonction de coût, nous nous sommes inspirés des valeurs $\lambda_{\text{cosine}} = 1.6 * 10^{-4}$, $\lambda_{\text{laplace}} = 0.3$, $\lambda_{\text{edge}} = 0.1$ présentées dans la méthode Pixel2Mesh (Wang *et al.*, 2018) puisque les auteurs de Pixel2Mesh++ (Wen *et al.*, 2019) ne présentent pas les poids associés à chaque composante de la fonction de coût dans leur méthode. Considérant cette information manquante dans l’article de Wen *et al.* (2019), nous n’avons pas de certitude que ces intervalles d’hyperparamètres sont viables dans notre contexte. Nous avons validé que pour chaque limite de l’intervalle de la norme du déplacement maximal des sommets permettait de déformer le modèle générique sur

les modèles de la base de données d’entraînement en calculant la distance entre les sommets correspondants des modèles de référence et du modèle générique mis à l’échelle.

Tableau 4.1 Hyperparamètres de Pixel2Mesh++ avec les intervalles de recherche proposés à Hyperband

Paramètre	Intervalle
Taux d’apprentissage	$[1e - 3, 1e - 6]$
Norme du déplacement	$[4, 18]mm$
Nb. cellules cachées GCN	$[200, 230, \dots, 339]$
Dropout CNN	$[0.0, 0.1, \dots, 0.9]$
Dropout GCN	$[0.0, 0.1, \dots, 0.5]$
Poids Cosine	$[0, 0.01]$
Poids Laplace	$[0, 1]$
Poids Longueur d’arête	$[0, 1]$

Nous utiliserons aussi cette étape de validation d’hyper-paramètres afin de déterminer combien d’étapes de déformation devraient être appliquées par notre méthode. La méthode originale proposée par Wen *et al.* (2019) appliquent deux passes de déformations. Nous pourrions constater si d’utiliser un nombre différent de passes de déformation permet d’obtenir une reconstruction 3D plus robuste ou plus précise.

4.4 Entraînement du réseau de neurones

L’entraînement du réseau de neurones s’effectue sur la plateforme Compute Canada, au moyen d’un noeud de calcul équipé d’une carte graphique NVIDIA v100-SXM2 possédant 32Go de VRAM et 64Go de RAM. La plateforme Tensorflow 2.0 est utilisée comme plateforme de développement pour l’architecture du réseau de neurones et l’optimiseur ADAM (Kingma & Ba, 2014) est utilisé.

4.5 Validation de la méthode

4.5.1 Reconstruction avec les DRR face/profil

D'abord, l'évaluation de la méthode de reconstruction sera faite avec la position face/profil. Cette évaluation permettra de se comparer à la majorité des méthodes de la littérature et d'étudier l'utilisation de la méthode dans le contexte d'utilisation classique du système EOS. La précision de forme des reconstructions obtenues sera étudiée en comparant les modèles de référence obtenus grâce à la méthode de Chaibi (2010) aux modèles reconstruits à l'aide des métriques P2S moyenne et RMS en plus de la métrique SHD moyenne. La comparaison sera effectuée pour les régions proximale, diaphysaire et distale du fémur. Les erreurs sur ces régions seront calculées entre le modèle générique et les modèles de référence afin de quantifier l'amélioration apportée par l'algorithme de reconstruction. Les meilleures et les pires reconstructions, basées sur la variation d'erreur à partir de l'erreur initiale, seront aussi observées de manière à déterminer dans quels cas l'algorithme échoue. Nous évaluerons aussi notre méthode sur des radiographies EOS, tout en conservant la pose et l'échelle du modèle de référence, de manière à observer le comportement de notre méthode face à des radiographies où il y a une superposition dans la vue latérale de deux fémurs et où il y a des tissus mous et du bruit. La précision des paramètres cliniques HKS, TF et ACD, décrits à la section 1.1, sera aussi étudiée à l'aide de graphiques de Bland-Altman. Les paramètres cliniques de référence sont calculés pour chaque modèle de référence à l'aide de la plateforme de prototypage SterLIO et de régions définies sur le modèle générique utilisé par Chaibi (2010) et nous. Comme les régions du modèle générique sont définies en fonction de la topologie de ce dernier et que notre méthode conserve la topologie du modèle générique, nous pourrions réutiliser ces régions ainsi que les méthodes de calcul automatique des paramètres cliniques définies sur ce dernier par Chaibi (2010).

4.5.2 Reconstruction multi vues

La reconstruction utilisant d'une à cinq paires de DRR sera étudiée afin d'observer les gains en précision de forme de l'algorithme. Comme nous avons trois angles de rotation possible en X,

quatre en Y et six Z, nous avons donc $6 * 4 * 3 = 72$ triplets de rotations différents à évaluer. Tester l'ensemble des combinaisons d'une à cinq paires de DRR avec des poses différentes reviendrait à évaluer $\sum_{i=1}^5 C(72 - (i - 1), i) = 1.502 * 10^7$ combinaisons, ce qui n'est pas réaliste.

Un sous-ensemble de combinaisons de poses devra être choisi de manière à évaluer un ensemble réaliste de combinaisons. Pour ce faire, nous allons générer $N = 4500$ combinaisons de pose du patient pour les combinaisons comportant de 2 à 5 poses différentes et ces combinaisons seront utilisées pour générer des DRR pour chaque fémur de la base de données de test. Afin de vérifier que l'ajout de radiographies améliore réellement la précision de forme de l'algorithme de reconstruction 3D, la procédure de génération des combinaisons doit être conçue de manière à ce qu'une combinaison $C_{i,k}$, où i représente l'indice d'une combinaison et k le nombre de paires de DRR dans la combinaison, contienne l'ensemble des points de vue contenus dans la combinaison $C_{i,k-1}$. De la sorte, si par exemple $C_{0,2}$ contient les triplets de rotation $(0, 0, 0)$ et $(0, 20, 0)$, alors la combinaison $C_{0,3}$ contiendra ces deux triplets et un nouveau.

Pour ce faire, $N = 4500$ combinaisons de points de vue sont générées pour les combinaisons $C_{i,5}$. Ces combinaisons sont générées aléatoirement en suivant une distribution uniforme en respectant trois règles : les combinaisons doivent être uniques, elles ne doivent pas contenir deux fois le même point de vue, les points de vue utilisés ne peuvent pas être voisins. Deux points de vue voisins sont séparés par un seul incrément à un des angles de rotation. Avec ces 4500 combinaisons de cinq points de vue, un point de vue est retiré de chaque combinaison $C_{i,5}$ afin de créer une combinaison $C_{i,4}$. Les mêmes règles doivent être respectées pour tous les ensembles de combinaisons $C_{i,2..5}$. Finalement, lorsque $k = 1$, chacun des 72 points de vue possibles sont évalués. Cette procédure de génération de combinaisons ne permet pas d'évaluer toutes les combinaisons possibles, mais devrait permettre d'évaluer une grande variété de combinaisons.

Avec ces combinaisons de points de vue, il est ensuite possible d'évaluer l'amélioration de la précision de forme de l'algorithme lorsque plusieurs paires de DRR sont utilisées. La précision de forme pourra être observée à l'aide de la variation de la moyenne. Il sera aussi possible de déterminer si la précision de forme de la reconstruction 3D converge à partir d'un certain

nombre de DRR. Comme pour l'expérimentation avec les DRR en position face/profil, les erreurs seront calculées sur les trois régions du fémur selon les métriques P2S moyenne, RMS et SHD moyenne.

4.5.3 Impact des points de vue choisi

Comme indiqué dans la revue de la littérature, peu d'expérimentations sont faites sur l'impact de la position du patient dans la cabine, de la flexion du genou ou encore de la présence d'un varus/valgus dans les méthodes de reconstruction 3D. L'opportunité que nous permet notre méthode de génération de données de tester la méthode de reconstruction 3D sous un grand nombre de configurations nous permettra de déterminer expérimentalement l'impact du point de vue choisi lors d'une reconstruction 3D ou encore de savoir si la présence du varus/valgus influence la précision de forme obtenue.

Afin de trouver les combinaisons de points de vue les plus performantes, nous avons établi un processus en trois étapes : l'évaluation des combinaisons, la sélection de la combinaison la plus performante et la construction des combinaisons suivantes. Ce processus sera répété pour les combinaisons d'un à cinq points de vue.

Ce processus est d'abord appliqué à la reconstruction à chaque combinaison $C_{i,1}$, contenant qu'une seule paire de DRR orthogonales. Nous évaluerons d'abord les 72 points de vue pour chaque modèle de la base de données de test. La moyenne des erreurs P2S moyennes de chaque modèle reconstruit sera calculée en fonction du point de vue utilisé, de manière à obtenir 72 erreurs moyennes. La combinaison la plus performante, appelons-la $C_{v,1}$ sera sélectionnée comme base pour créer les prochaines combinaisons. Pour construire les prochaines combinaisons, chaque combinaison $C_{i,2}$ contiendra le point de vue de la combinaison $C_{v,1}$, permettant de créer 71 (72 points de vue moins celle contenue $C_{v,1}$) dans nouvelles combinaisons $C_{i,2}$. Ensuite, la combinaison la plus performante sera utilisée comme base pour construire les combinaisons $C_{i,3}$ et ainsi de suite jusqu'à cinq. Ce processus nous permettra d'identifier la combinaison de points de vue la plus performante lorsqu'une à cinq paires de DRR sont utilisées.

CHAPITRE 5

RÉSULTATS ET DISCUSSION

5.1 Entraînement du modèle

La recherche d'hyperparamètres effectuée avec Hyperband (Li *et al.*, 2016) a permis d'obtenir les valeurs hyperparamètres présentées dans le tableau 5.1. Pour rappel, la fonction de coût utilisée par Wen *et al.* (2019) comporte quatre composantes : la distance de Chamfer, la distance cosinus, la régularisation laplacienne et la régularisation de longueur d'arêtes. Par exemple, si la régularisation de longueur d'arête occupe un poids trop gros dans la fonction de coût, le modèle d'apprentissage profond n'apprendra à diminuer la taille des arêtes du modèle final, ce qui ne serait pas utile du tout. Nous avons d'abord évalué 81 configurations avec la méthode Hyperband présentée à la section 4.3. Dans ces configurations d'hyperparamètres, nous n'arrivions pas à faire converger la fonction de coût sur l'ensemble de données de validation à cause des poids associés aux trois composantes de la fonction de coût. Les reconstructions 3D obtenues n'étaient pas suffisamment précises pour être comparables aux autres méthodes présentées dans la littérature. Nous avons choisi d'ignorer les composantes de distance cosinus, régularisation laplacienne et de longueur d'arête de notre fonction de coût. Considérant la conclusion obtenue par Wang *et al.* (2018) comme quoi ces composantes diminuaient la précision de forme de la reconstruction 3D, nous avons lancé la méthode d'optimisation d'hyperparamètres Hyperband avec une nouvelle série de 81 configurations d'hyperparamètres où ces trois composantes de la fonction de coût sont omises. Comme nous pourrions le voir dans les sections suivantes, la précision obtenue par la meilleure configuration d'hyperparamètres en utilisant seulement la distance de Chamfer dans la fonction de coût est très élevée. Par contre, les modèles 3D que nous obtenons à l'aide de notre méthode ne seront pas aussi lisses que les modèles de référence. À notre avis, optimiser la fonction de coût avec les quatre composantes représente un défi de taille qui pourrait être exploré davantage à la suite de notre projet de recherche. Afin d'y arriver, nous croyons qu'une métrique devrait être mise en place de manière à quantifier la qualité visuelle des modèles 3D obtenus de manière à pouvoir automatiser la recherche d'hyperparamètres en tenant compte de cette métrique. Nous avons aussi constaté que nos courbes d'entraînement ne

s'amélioreraient pas lorsqu'une ou deux passes de déformations étaient faites à l'aide de notre méthode. Conséquemment, nous avons choisi de n'appliquer qu'une passe de déformation à l'aide de notre algorithme.

Tableau 5.1 Hyperparamètres optimaux obtenus pour l'entraînement

Hyperparamètre	Valeur
Taux d'apprentissage	$8.5 * 10^{-4}$
Norme du dépl. max.	12.89mm
Nb. cellules cachées GCN	320
Dropout CNN	0.4
Dropout GCN	0.3
Poids Cosine	N/D
Poids Laplace	N/D
Poids Longueur d'arête	N/D

L'algorithme a été entraîné pendant 75 epochs, pour une durée de 7h. Les courbes d'erreur de validation et d'entraînement ont bien convergé comme le montre la figure 5.1.

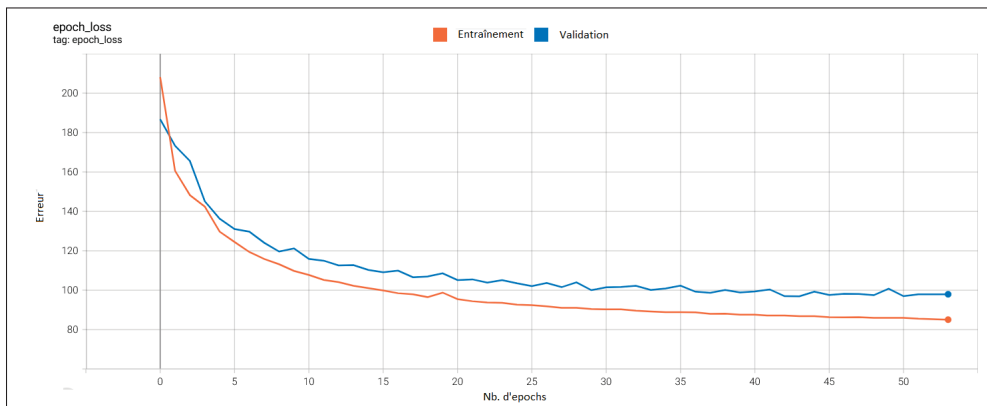


Figure 5.1 Courbes d'apprentissage de l'algorithme. La courbe orange représente la courbe d'erreur sur l'ensemble d'entraînement et la courbe bleue sur l'ensemble de validation

5.2 Reconstruction avec les DRR face/profil

5.2.1 Résultats qualitatifs

La figure 5.2 présente trois exemples de reconstructions obtenus à l'aide de notre méthode. Cette figure permet de qualitativement apprécier la déformation apportée au modèle initial. Comme nous l'avons mentionné à la section 5.1, le retrait des composantes de régularisation de la fonction de coût pourrait faire en sorte que les modèles que nous obtenons ne sont pas très lisses. Ces régularisations ont été retirées de notre méthode puisqu'elles faisaient en sorte que notre réseau de neurones convergeait vers une précision moins bonne que lorsqu'elles étaient présentes. À notre avis, la précision est à maximiser par rapport à la régularité de la surface.




Figure 5.2 Trois exemples de reconstructions obtenues à l'aide de notre méthode. Dans chaque figure, on y retrouve en ordre le modèle générique mis à l'échelle, le modèle de référence et le modèle reconstruit. La figure a) représente la meilleure reconstruction (0.29mm P2S moy.), la figure b) une reconstruction avec une erreur près de la moyenne (0.4mm P2S moy.) et la figure c) la pire reconstruction (0.56mm P2S moy.)

5.2.2 Erreurs avant/après la déformation

La figure 5.3 présente les erreurs de reconstruction selon les métriques P2S moyenne, P2S RMS et SHD moyenne pour les trois régions du fémur avant et après la déformation. Les diagrammes "avant" présentent les distributions d'erreurs entre le modèle générique mis à l'échelle et les modèles de références, tandis que les diagrammes "après" présentent l'erreur entre les modèles reconstruits et les modèles de référence. La moyenne de l'erreur y est aussi présentée à l'aide d'un X à l'intérieur des boîtes. Le tableau 5.2 présente les erreurs obtenues dans les diagrammes de boîtes à moustache. La boîte dans chaque diagramme représente le 25e, 50e et 75e percentiles de la distribution des erreurs. Les barres sortant de cette boîte mènent aux 1er et 99e percentiles. Les points à l'extérieur de ces barres représentent les cas qui sont à l'extérieur de l'intervalle du 1er au 99e percentile.




Figure 5.3 Diagramme de boîte à moustache des erreurs sur les différentes régions du fémur avant et après la déformation par Pixel2Mesh++ lorsque le fémur est en position face/profil

Tableau 5.2 Statistiques des erreurs post-déformation
lorsque la position face/profil est utilisée

Région	Erreurs initiales				Erreurs de reconstruction			
	Moy.	Std.	Min	Max	Moy.	Std.	Min	Max
P2S moy. (mm)								
Global	2.22	0.49	1.28	3.71	0.41	0.06	0.29	0.56
Proximale	2.42	0.71	1.38	4.53	0.49	0.11	0.34	0.89
Diaphysaire	1.89	0.47	1.01	3.32	0.30	0.05	0.22	0.54
Distale	2.38	0.78	0.91	4.68	0.46	0.10	0.29	0.80
P2S RMS (mm)								
Global	2.81	0.6	1.8	4.55	0.55	0.09	0.38	0.85
Proximale	3.04	0.86	1.71	5.54	0.65	0.16	0.44	1.31
Diaphysaire	2.3	0.55	1.33	4.13	0.38	0.07	0.28	0.67
Distale	2.97	0.92	1.14	5.43	0.60	0.13	0.37	1.06
SHD moy. (mm)								
Global	9.93	2.44	6.39	17.53	2.96	0.83	1.88	6.50
Proximale	8.96	2.7	4.9	17.53	2.82	0.86	1.67	6.50
Diaphysaire	5.66	1.42	3.19	8.84	1.70	0.40	1.08	2.95
Distale	8.29	2.5	3.43	14.89	2.37	0.64	1.44	4.20

La figure 5.3 et le tableau 5.2 permettent de constater l'amélioration marquée de la forme du modèle 3D après la déformation lorsque la vue en face/profil est utilisée. Les erreurs P2S moyenne, P2S RMS et Hausdorff moyenne diminuent respectivement de 2.22 ± 0.49 mm à 0.41 ± 0.06 mm, de 2.81 ± 0.6 mm à 0.55 ± 0.09 mm et de 9.93 ± 2.44 mm à 2.96 ± 0.83 mm après la déformation, soit d'environ 5 fois pour les erreurs P2S et de 3 fois pour l'erreur SHD. Présenter les métriques d'erreur sur l'ensemble du fémur n'est pas nécessairement pertinent, puisque la diaphyse occupe une grande région du modèle générique (913 sommets comparativement à 712 pour le fémur distal et 808 pour le fémur proximal). Cette région est plus facile à reconstruire et a moins d'importance clinique que le fémur proximal et le fémur distal. Les erreurs P2S moyennes pour le fémur proximal et distal sont de 0.49 ± 0.11 mm et 0.46 ± 0.1 mm pour le fémur distal après la déformation automatique. Ces résultats montrent à notre avis que notre méthode permet de déformer avec précision un modèle 3D à partir de radiographies simulées. Nous pouvons aussi constater à cette étape que, lorsque les DRR face/profil sont utilisées, la reconstruction 3D obtenue est toujours plus près du modèle de référence que le modèle générique initial mis à

l'échelle. Nous sommes satisfaits de constater que notre méthode de déformation 3D ne crée pas de reconstructions aberrantes à ce stade, ce qui aurait pu être le cas compte tenu du fait que la déformation n'est pas explicitement régularisée comme lorsqu'un modèle statistique de forme est utilisé.

5.2.3 Régions avec les erreurs les plus importantes

La figure 5.4 présente une carte d'erreur projetée sur le modèle initial. Cette carte d'erreur est obtenue en observant pour chaque sommet du modèle générique S_i quelle est l'erreur P2S maximale obtenue pour S_i dans l'ensemble des reconstructions 3D, M lorsque comparée à leur fémur de référence \hat{M} :

$$E(\bar{S}_i) = \max_j (P2S_{S_i}(M_j, \hat{M}_j)) \quad (5.1)$$




Figure 5.4 Carte d'erreur représentant l'erreur maximale par sommet dans l'ensemble des évaluations lorsqu'une seule paire de DRR est utilisée

Nous retrouvons quelques erreurs au niveau des condyles. Il n'est pas surprenant à notre avis que cette région soit plus difficile à reconstruire compte tenu du fait que les deux condyles se superposent en vue latérale et que leur forme postérieure est peu visible en vue frontale. Nous croyons qu'avec davantage d'exemples dans notre base de données ou encore en utilisant un CNN d'extraction de caractéristiques plus puissant, nous pourrions obtenir une meilleure précision dans cette région.

C'est dans la région proximale du fémur que nous retrouvons la plus haute erreur de reconstruction, avec une erreur SHD de 6.5mm comparativement à 2.95mm pour la diaphyse et de 4.2mm pour la région distale. La figure 5.5 présente le fémur proximal initial mis à l'échelle, de référence et reconstruit pour la reconstruction 3D ayant la plus grande erreur SHD. La distance maximale entre le grand trochanter générique et celui de référence, présentée à la figure 5.5a, est de 17.53mm, ce qui est supérieur à la norme maximale du déplacement de 12.89mm pour un sommet lors de la déformation, ce qui fait en sorte qu'il est impossible pour les sommets du modèle générique d'atteindre le haut du grand trochanter du modèle de référence. À la figure 5.5b les sommets du modèle reconstruits, en rouge, forment un plateau qui ne se rend pas au sommet du grand trochanter. Cette norme maximale de déplacement représente une limitation de notre méthode. Afin de remédier à ce problème, nous pourrions considérer initialiser le modèle 3D générique à l'aide de l'étape de modélisation rapide de la méthode de Chaibi (2010) plutôt que de faire une initialisation de pose et d'échelle globale, ce qui réduirait l'erreur initiale.

Un autre problème que nous observons au niveau du grand trochanter, à la figure 5.6, est que notre méthode semble avoir de la difficulté à recréer la courbure naturelle du haut de ce dernier. L'algorithme crée une pointe au niveau du grand trochanter alors que le modèle de référence a une forme plus arrondie. Nous croyons que l'utilisation de la distance cosinus et de la régularisation laplacienne aurait pu être avantageuse afin de régler ce problème. Ces deux composantes permettraient potentiellement de conserver les courbures naturelles du modèle générique lors de la déformation.

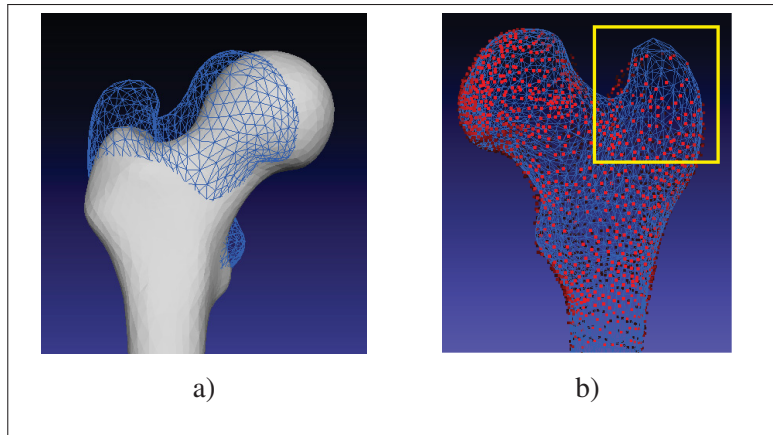


Figure 5.5 Fémur proximal avec l'erreur de reconstruction SHD maximale. a) Différence entre le maillage générique (en gris) mis à l'échelle et le modèle de référence (en bleu) dans la région proximale. b) Différence entre le modèle reconstruit (en rouge) et le modèle de référence (en bleu), vue de l'arrière du fémur




Figure 5.6 Comparaison de la courbure du modèle de référence (en jaune) et du modèle reconstruit (en gris). Nous pouvons constater que le modèle reconstruit n'arrive pas à recréer la courbure naturelle du grand trochanter

La figure 5.7a permet de voir qu'il n'y a aucun sommet du modèle de reconstruction qui s'approche de l'extrémité du petit trochanter. Pour cet exemple, nous pouvons voir à la figure 5.7b que le petit trochanter du modèle générique est très loin de celui du modèle de référence.

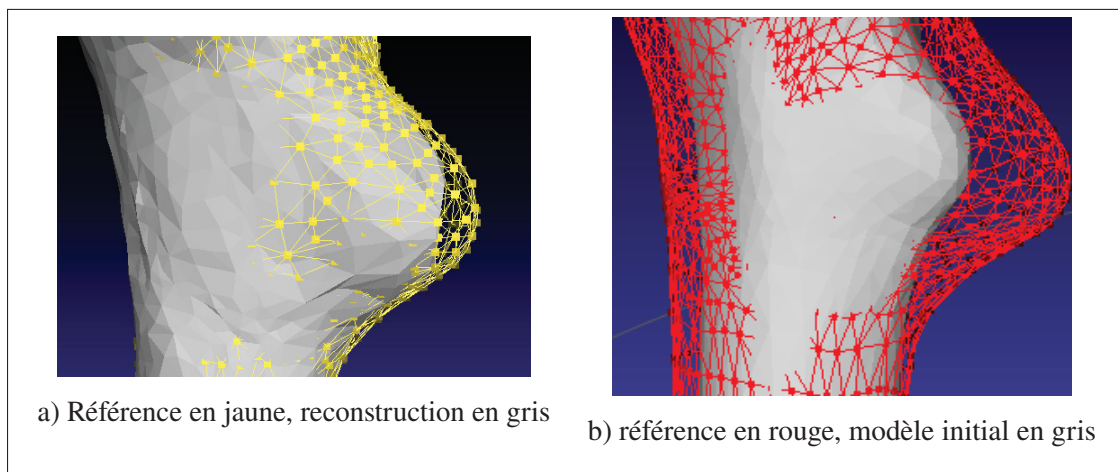


Figure 5.7 Les erreurs communes faites par notre algorithme sur le petit trochanter. À gauche, la reconstruction du petit trochanter. À droite, la comparaison entre le modèle générique initial et le modèle de référence de la reconstruction présentée dans les deux autres figures

Cette région est, à notre avis, plus difficile à reconstruire que le grand trochanter puisque le petit trochanter n'est que très peu visible en vue latérale et qu'il est difficile d'estimer sa position par rapport à la diaphyse à partir de la vue frontale. Comme nous pouvons le voir à la figure 5.8, le petit trochanter peut être orienté différemment d'un fémur à l'autre (voir les flèches rouge et bleue de la figure 5.8a) et cette orientation n'est pas particulièrement visible dans nos DRR. Dans la figure 5.8b, nous pouvons constater que le petit trochanter est pratiquement invisible dans les DRR latérales et que leur visibilité en vue frontale n'est pas très bonne non plus.

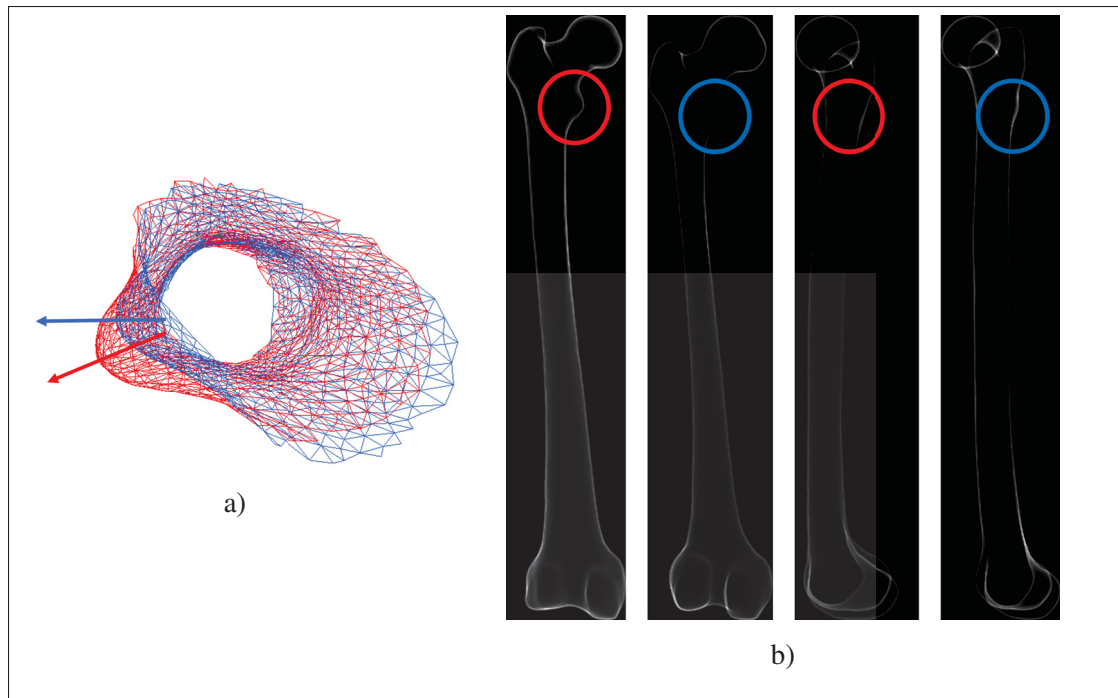


Figure 5.8 À gauche, une figure illustrant la direction changeante du petit trochanter d'un fémur à l'autre à l'aide des modèles de fémur de référence. À droite, les radiographies frontales et latérales associées aux surfaces bleue et rouge de la figure de gauche. Le petit trochanter est identifié dans ces DRR à l'aide de cercles de couleur indiquant à quelle surface la DRR appartient

5.2.4 Reconstruction à partir de radiographies EOS

La figure 5.9 permet de comparer les reconstructions 3D du fémur obtenues à l'aide de radiographies EOS ainsi que des DRR pour un même patient et donc pour un même fémur de référence. Nous pouvons constater, qualitativement, que la reconstruction 3D obtenue à partir des radiographies EOS n'est vraiment pas précise et qu'il y a des incohérences dans le modèle 3D. L'erreur P2S moyenne obtenue pour la reconstruction à partir des radiographies EOS, dans la figure 5.9a, est de 3.29mm avec une erreur maximale de 11.7mm. Lorsque les DRR sont utilisées, l'erreur P2S moyenne est de 0.38mm avec une erreur maximale de 2.64mm. Comme les radiographies EOS contiennent aussi des tissus mous, le deuxième fémur ainsi que le pelvis et qu'elles sont davantage bruitées que les DRR que nous avons utilisées pour entraîner notre modèle, nous ne sommes pas surpris de constater cet écart de précision. Dans la littérature, les méthodes de Li *et al.* (2020); Kasten *et al.* (2020); Aubert *et al.* (2022) indiquent toutes qu'un réseau de neurones entraîné sur des DRR ne généralise pas bien à des radiographies réelles surtout dues à la différence de distribution d'intensité entre les deux images, qui fait en sorte qu'il est difficile voir impossible pour le modèle d'apprentissage profond de retrouver les caractéristiques géométriques qu'il a appris à extraire sur les DRR dans les radiographies. Kasten *et al.* (2020); Aubert *et al.* (2022) proposent tout deux d'utiliser un modèle génératif de transfert de style afin de transformer la radiographie d'entrée de manière à ce qu'elle ait la même distribution d'intensité et qu'elle ne présente que la même information que ce qui est visible dans les DRR utilisées pour l'entraînement. Afin d'adapter notre méthode à des radiographies réelles, il faudrait donc, à notre avis, reprendre les travaux de ces deux auteurs et les adapter à notre méthode.

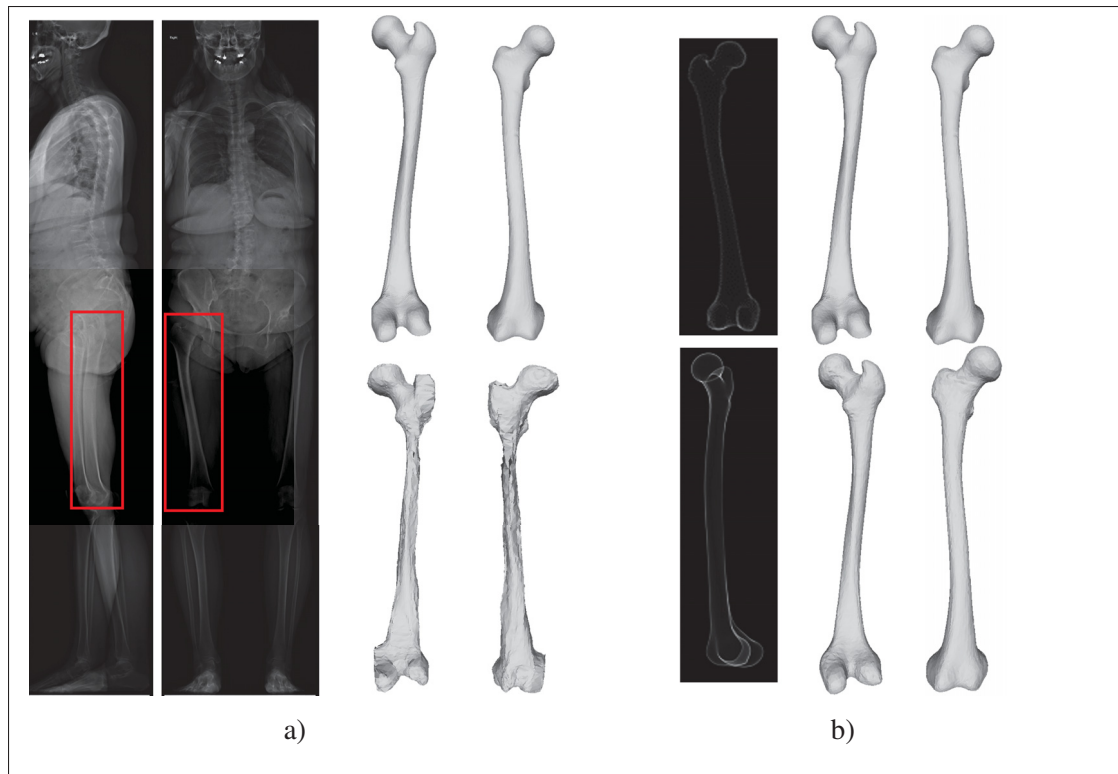


Figure 5.9 Comparaison de la qualité de la reconstruction 3D avec deux radiographies EOS vs. deux DRR. Dans 5.9a, on retrouve les radiographies EOS utilisées pour prédire la reconstruction 3D. Plus spécifiquement, les encadrés rouges sont fournis en entrée à notre modèle de déformation automatique. On y retrouve le modèle de référence en haut, vu de face et de derrière, ainsi que le modèle prédit en bas, vu de face et de derrière. Dans 5.9b, on retrouve les deux DRR utilisées pour obtenir la reconstruction 3D du fémur, le modèle de référence en haut ainsi que la prédiction obtenue à l'aide des deux DRR en bas avec les mêmes angles de vue que la figure 5.9a

5.2.5 Précision des paramètres cliniques

Les figures 5.10, 5.11 et 5.12 présentent les diagrammes de Bland-Altman obtenus à l'aide des DRR en position face/profil pour les paramètres cliniques suivants : la torsion fémorale, l'angle anatomique/mécanique et l'angle cervico-diaphysaire. Dans ces graphiques, chaque point représente un des fémurs de la base de données de test reconstruit. Sur l'axe des abscisses, on retrouve la moyenne entre la valeur de référence du paramètre clinique et celle obtenue à l'aide de la déformation automatique tandis que sur l'ordonnée on retrouve la différence entre notre méthode et la méthode de Chaibi (2010). La majorité des paramètres cliniques obtenus des modèles reconstruits se retrouvent dans un intervalle de ± 2 écarts-types basés sur la différence entre les mesures. Ces écarts-types sont de 11.92° , 1.37° et 2.83° pour la torsion fémorale, l'angle HKS et l'angle cervico-diaphysaire. Les moyennes des différences entre les méthodes, exprimées par la ligne bleue sur l'axe des ordonnées, sont aussi relativement près de zéro. Ces mesures montrent que malgré le fait que nos reconstructions 3D ne sont pas lisses, les points et axes nécessaires au calcul des paramètres cliniques sont plutôt bien reconstruits dans notre méthode.

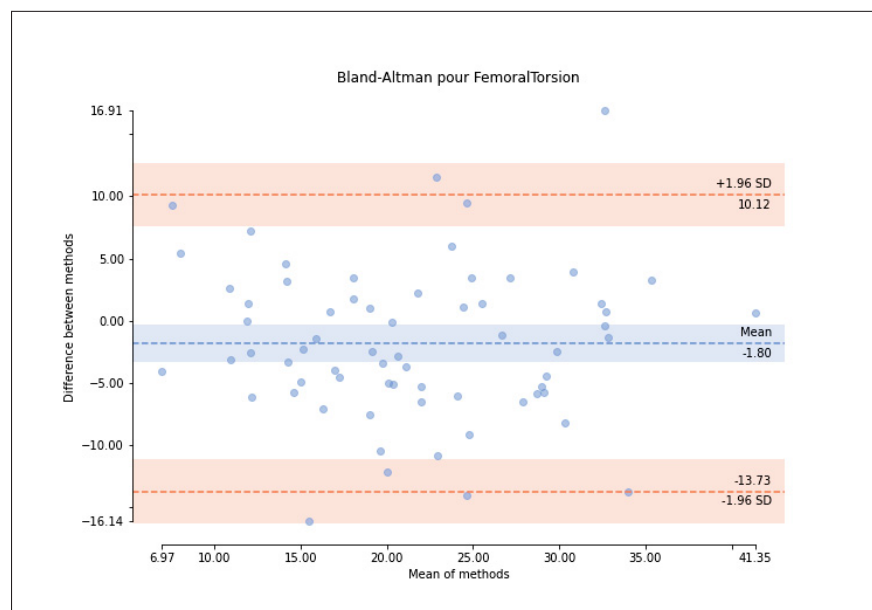


Figure 5.10 Bland-Altman de la torsion fémorale

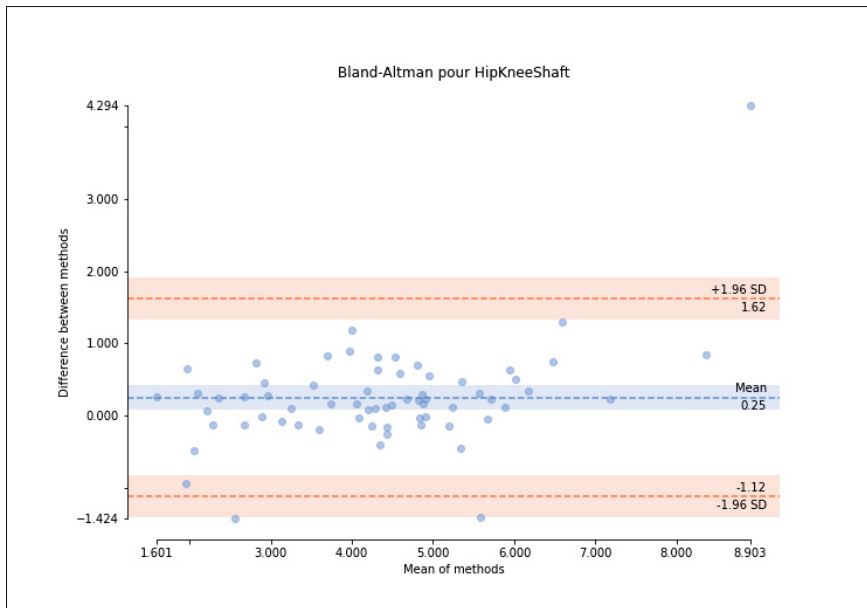


Figure 5.11 Bland-Altman de l'angle anatomique/mécanique

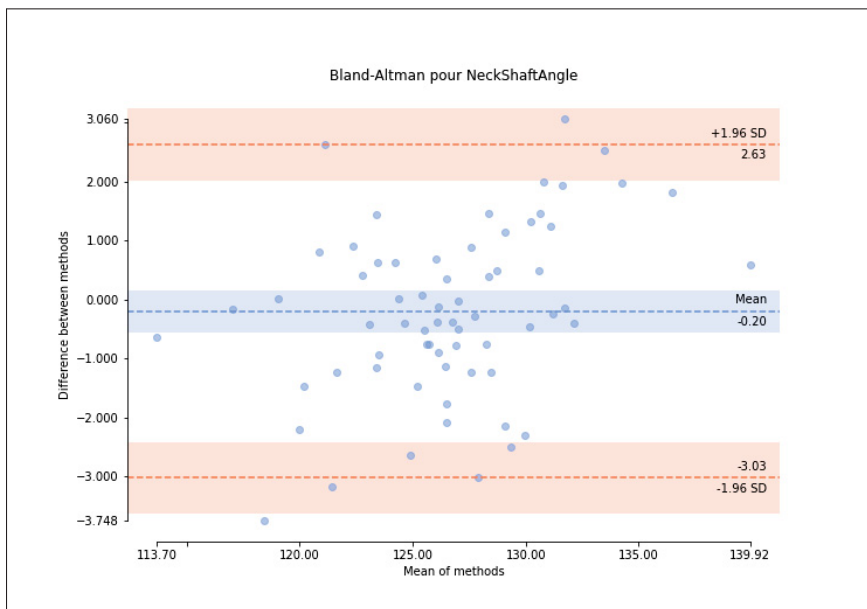


Figure 5.12 Bland-Altman de l'angle cervico-diaphysaire

Le tableau 5.3 présente les valeurs de différences des moyennes et des écarts-types utilisés pour construire nos diagrammes de Bland-Altman et la méthode de Chaibi (2010). Avant d'entamer cette comparaison, nous devons rappeler que les paramètres cliniques de référence de cette méthode ont été extraits de CT scans de référence par des experts, tandis que nos paramètres cliniques de référence sont obtenus à partir de la méthode de Chaibi (2010). Il faut donc dire que, malgré le fait que certaines de nos erreurs puissent être près de ce que Chaibi (2010) obtiennent, cette méthode obtiendrait des encore meilleurs résultats sur notre ensemble de données. Comme Chaibi (2010) ne présentent que les erreurs moyennes signées, ces valeurs peuvent difficilement être comparées directement puisque la moyenne pourrait s'approcher de zéro malgré des erreurs très élevées. Par contre, nous pouvons comparer les écarts-types obtenus. Nous pouvons voir que notre méthode estime plutôt bien l'angle anatomique/mécanique du fémur(HKS) et l'angle cervico-diaphysaire (NSA). Par contre, notre erreur a un écart-type beaucoup plus grand pour la torsion fémorale.

Tableau 5.3 Comparaison des erreurs (moy. signées et 2*écarts-types) pour les paramètres cliniques étudiés entre notre méthode et celle de Chaibi (2010)

Méthode	HKS (°)		NSA (°)		FT (°)	
	Moy.	2É.T.	Moy.	2É.T.	Moy.	2É.T.
Chaibi (2010)	-0.1	1.5	0.4	2.2	-0.2	3.2
Nous	-0.24	1.39	0.19	2.85	1.8	12.16

Comme nous l'avons indiqué à la section 1.1, quatre axes sont nécessaires au calcul de ces paramètres cliniques :

1. L'axe bicondylien : Axe passant par la section postérieure des deux condyles. Utilisé dans la torsion fémorale ;
2. L'axe du col fémoral : Axe passant par les barycentres de la région supérieure et inférieure du col fémoral. Utilisé dans l'angle cervico-diaphysaire et la torsion fémorale ;
3. L'axe diaphysaire : Axe passant par le centre de la diaphyse et le centre de la diaphyse proximale. Utilisé dans l'angle cervico-diaphysaire et l'angle anatomique/mécanique du fémur ;

4. L'axe mécanique du fémur : Axe passant par le centre de la tête fémorale et le centre de la trochée. Utilisé dans l'angle anatomique/mécanique du fémur.

La figure 5.4, présentée à la section 5.2.3, montre effectivement que la section postérieure de condyles et du bas du col fémoral sont moins bien reconstruites. Particulièrement, comme l'axe bicondylien n'est pas calculé à partir de barycentre comme les autres, il est plus sensible aux erreurs de reconstruction qui pourrait se présenter dans notre méthode. Comme ces deux régions sont essentielles au calcul de la torsion fémorale, le calcul de la torsion fémorale à l'aide de notre méthode n'est pas optimal.

5.3 Reconstruction multivues

La figure 5.13 présente l'évolution des statistiques d'erreurs en fonction du nombre de paires de DRR utilisées. Les erreurs sont présentées pour les métriques P2S moyenne, RMS et SHD pour les trois régions du fémur.




Figure 5.13 Évolution de l'erreur sur les différentes régions du fémur en fonction du nombre de paires de DRR de points de vue différents utilisés

Les erreurs P2S moyennes et ses écarts-types diminuent de manière plus importante lorsque le nombre de DRR utilisées passe d'une à deux que le reste, de 0.6mm à 0.4mm pour la moyenne et de 0.24mm à 0.11mm pour l'écart-type. Cette figure permet de constater que l'ajout de DRR améliore effectivement la précision de forme de la reconstruction 3D. Dans un cas où

plusieurs images seraient disponibles pour un seul patient et que les images auraient été acquises dans un court laps de temps où la morphologie du fémur du patient n'aurait pas changé, nous recommandons donc d'utiliser l'ensemble des images disponibles. Toutefois, nous remarquons dans cette figure que l'amélioration est plus significative lorsque l'on passe d'une à deux paires de DRR que pour les ajouts subséquents.

La figure 5.14 présente une reconstruction 3D où l'erreur P2S moyenne entre le modèle générique et le modèle de référence est plus petite que l'erreur entre le modèle reconstruit et le modèle de référence. Cette reconstruction est obtenue avec deux paires de DRR présentant la même information à une symétrie près (triplets de rotations de $(0, 20, 135)$ et $(0, 20, 225)$). L'erreur P2S moyenne globale est de 1.62mm. Par contre, c'est dans la région proximale que l'erreur est la plus grande avec 1.92mm. L'erreur SHD maximale est de 19.98mm, une grande augmentation de l'erreur comparativement à l'erreur initiale de 13.17mm.

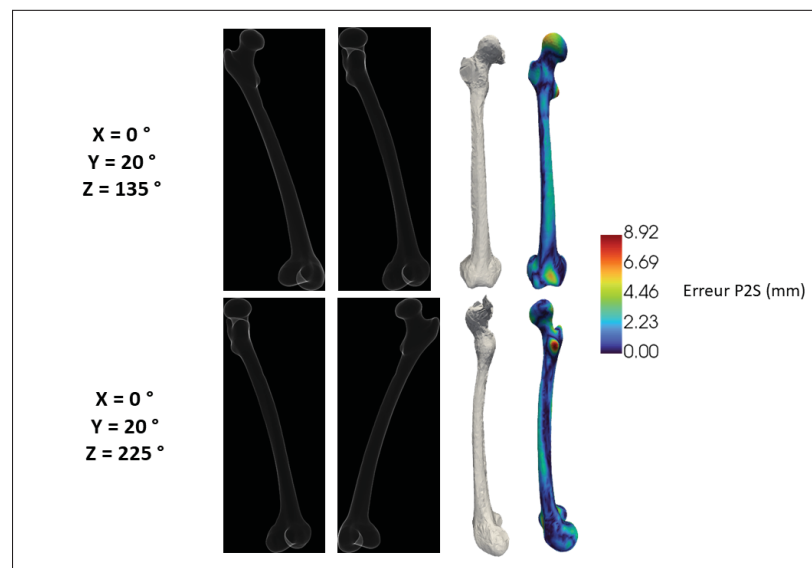


Figure 5.14 Reconstruction dégradée avec points de vue orthogonaux

Afin d'agrèger les caractéristiques issues de plusieurs radiographies, notre méthode calcule la moyenne, l'écart-type et le maximum de chaque caractéristique extraite par le CNN. Comme ce CNN d'extraction de caractéristiques n'est pas invariant à la symétrie, à l'étape de fusion

des caractéristiques nous nous retrouvons avec des statistiques qui ne sont pas nécessairement représentatives de l'information dans les différentes radiographies. Nous croyons qu'en utilisant un CNN avec une invariance à la symétrie, ou bien en ne permettant pas aux utilisateurs de notre méthode de fournir en entrée des images identiques à la symétrie près, nous pouvons éviter ce problème.

5.4 Impact des points de vue choisis

La figure 5.15 présente les erreurs P2S moyennes des reconstructions 3D obtenues sur les régions globale, proximale, diaphysaire et distale du fémur en fonction du point de vue utilisé lorsqu'une seule paire de DRR est utilisée. Chaque figure de gauche représente l'erreur lorsque le patient a un valgus de 15 degrés ($X = -15^\circ$), les figures du centre lorsque le patient n'a pas de varus ni de valgus et les figures de droites lorsque le patient a un valgus de 15 degrés ($X = 15^\circ$). Pour chaque figure, l'abscisse représente l'angle de flexion du genou (Y) et l'ordonnée l'angle de la position du patient dans la cabine par rapport à la position antéro-postérieure (Z). Les intersections des grilles dans les figures représentent des configurations qui ont été expérimentées, les autres valeurs de ces figures ont été estimées à l'aide d'une interpolation bilinéaire à partir des valeurs assignées aux intersections.

Comme nous pouvons l'observer, la position face/profil permet d'obtenir la reconstruction 3D la plus précise et robuste. Il s'agit de la position du patient dans laquelle le fémur est le mieux visible, puisque lorsqu'il y a flexion/extension ou un varus/valgus, le fémur se superpose à lui-même dans la radiographie. Le CNN est tout de même entraîné à s'adapter lorsqu'il y a superposition, car ces exemples existent dans sa base de données d'entraînement, ce qui fait qu'il est tout de même possible d'obtenir des erreurs submillimétriques pour l'ensemble des points de vue. La figure 5.15 permet aussi de constater qu'il n'y a pas réellement d'avantages à choisir un point de vue plutôt qu'un autre pour reconstruire le fémur distal comparativement au fémur proximal.

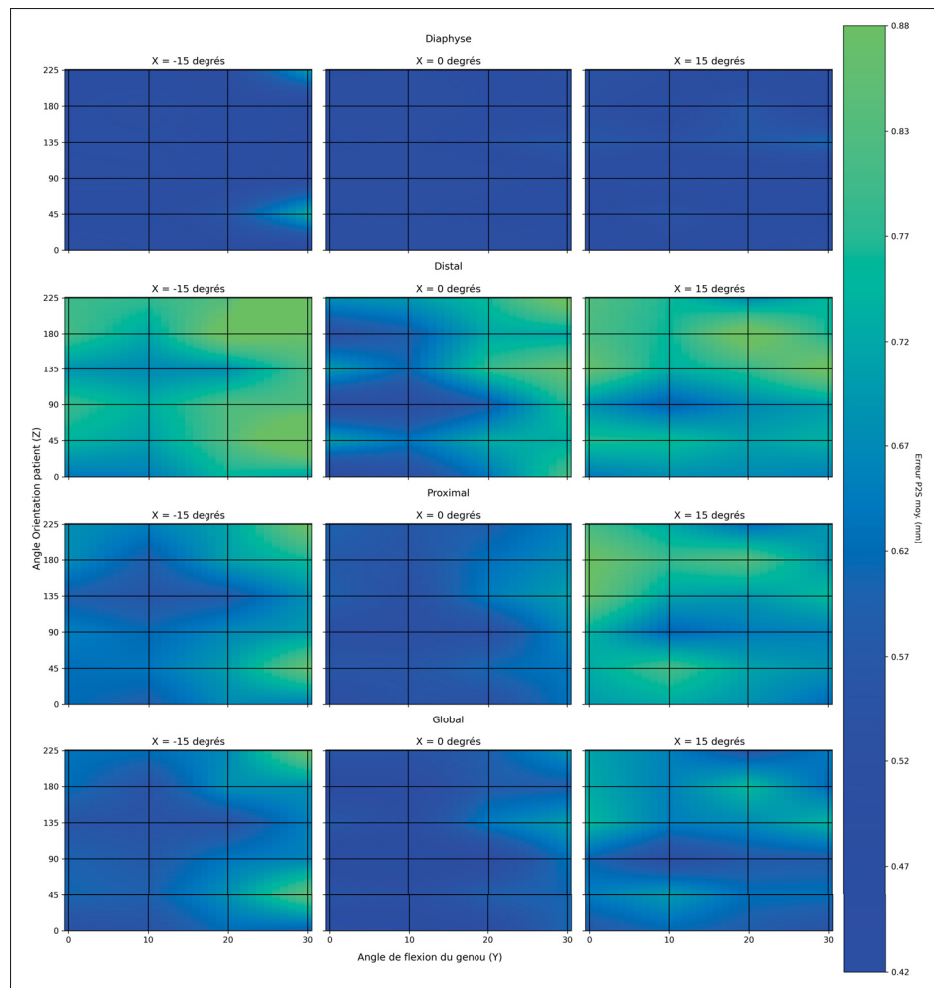


Figure 5.15 Cartes d'erreurs P2S moyennes par points de vue pour les régions globale, proximale, diaphysaire et distale du fémur lorsqu'une seule paire de DRR est utilisée

5.4.1 Impact des rotations individuelles par axe

Afin de valider l'impact des rotations individuelles, le tableau 5.4 présente les variations d'erreurs P2S moyennes lorsque les rotations en X, Y et Z sont appliquées individuellement à un fémur originalement en position face/profil.

Nous pouvons observer un point intéressant dans les rotations axiales du tableau 5.4 : les angles de rotations ayant une différence de 90° permettent d'obtenir des erreurs relativement similaires. Les erreurs moyennes à 0, 90 et 180 degrés sont de l'ordre de 0.41 à 0.47mm tandis

Tableau 5.4 Impact sur l'erreur P2S moyenne (mm) des rotations individuelles. Les meilleures erreurs sont en gras

Rot. X	Rot. Y	Rot. Z	Moy.	Std.	Min	Max
0	0	0	0.41	0.06	0.29	0.56
-15	0	0	0.53	0.23	0.37	1.48
15	0	0	0.57	0.26	0.37	1.44
0	0	0	0.41	0.06	0.29	0.56
0	10	0	0.45	0.14	0.34	1.17
0	20	0	0.49	0.13	0.37	1.07
0	30	0	0.60	0.19	0.44	1.45
0	0	0	0.41	0.06	0.29	0.56
0	0	45	0.55	0.07	0.42	0.79
0	0	90	0.43	0.05	0.34	0.61
0	0	135	0.51	0.19	0.40	1.98
0	0	180	0.47	0.15	0.33	1.58
0	0	225	0.56	0.08	0.42	1.88

que ces mêmes erreurs pour les rotations de 45, 135 et 225 degrés sont de l'ordre de 0.51 à 0.56mm. Comme l'information présente dans ces images devrait être relativement identique, nous nous serions attendus à ce que ces erreurs soient encore plus rapprochées puisque le réseau de neurones aurait dû extraire la même information de chaque image. Comme pour la section 5.4, nous pouvons ici aussi constater que la position face/profil est celle qui offre la meilleure performance dans l'ensemble des points de vue et des métriques observées, à l'exception de l'écart-type pour le triplet de rotation (0, 0, 90) qui est meilleure de 0.01mm.

5.4.2 Meilleures configurations de points de vue

Le tableau 5.5 présente le minimum, la moyenne, l'écart-type et le maximum obtenus avec les meilleures configurations de chaque combinaison de points de vue, obtenues à l'aide du processus défini dans la section 4.5.3.

Nous pouvons constater dans ce tableau que l'ajout de DRR où le fémur est présenté d'un point de vue complémentaire aux DRR précédemment utilisées permet d'obtenir une reconstruction plus précise. L'erreur P2S moyenne diminue d'environ 0.1mm lorsqu'une paire de DRR avec le

Tableau 5.5 Amélioration des erreurs P2S moyenne et SHD moyenne sur le fémur global lorsque les meilleures configurations d'acquisitions sont utilisées

Nb. d'img.	Acq.	P2S moy. (mm)				SHD moy. (mm)			
		Moy.	Std.	Min	Max	Moy.	Std.	Min	Max
2	(0,0,0)	0.41	0.06	0.29	0.56	2.96	0.83	1.88	6.50
4	(0,20,225)	0.31	0.03	0.25	0.38	2.30	0.79	1.36	6.13
6	(0,30,0)	0.29	0.03	0.22	0.35	2.09	0.72	1.34	6.05
8	(0,20,0)	0.28	0.02	0.24	0.36	2.09	0.73	1.44	6.04
10	(0,10,135)	0.26	0.02	0.21	0.33	2.04	0.73	1.38	6.01

point de vue (0, 20, 225) est ajoutée à la paire de DRR utilisant la position face/profil (0, 0, 0) (0.41mm vs 0.31mm), ce qui représente un gain intéressant en termes de précision. C'est au niveau des variations d'erreur SHD moyenne que l'analyse est la plus intéressante. La différence d'erreur moyenne entre l'utilisation d'un point de vue et de cinq points de vue est de l'ordre de presque un millimètre (2.96mm vs 2.04mm), ce qui représente une grande amélioration. Cette analyse montre que la robustesse du processus de reconstruction 3D de notre méthode s'améliore lorsque des DRR sont ajoutées. À la vue de nos résultats, nous croyons que l'utilisation d'images où le patient est en position face/profil dans la cabine EOS est suffisante pour obtenir une reconstruction 3D précise. Si d'autres radiographies sont déjà disponibles pour le patient, nous croyons qu'il peut être utile de les ajouter à notre processus de reconstruction, mais qu'il ne vaut pas toujours la peine d'aller chercher 0.1mm de précision additionnelle au coût d'une acquisition EOS additionnelle.

5.5 Discussion générale

Suivant les résultats présentés dans les sections précédentes, nous présentons ici les forces et des limitations de notre méthode de déformation automatique d'un modèle 3D de fémur générique à partir d'un nombre arbitraire de radiographies calibrées en plus de comparer notre méthode avec ce qui est disponible dans la littérature.

La méthode originale de Pixel2Mesh++ (Wen *et al.*, 2019) utilise une fonction de coût avec quatre composantes. Bien que, dans notre revue de la littérature, nous ayons constaté que la

distance cosine ainsi que les régularisations laplacienne et de longueur d'arête ne soient très utiles quantitativement, elles améliorent grandement la régularité de la surface de la reconstruction 3D. Nous n'avons pas utilisé ces trois composantes d'abord parce que nous n'avons pas réussi à faire converger la fonction de coût de notre méthode vers un niveau acceptable de précision, mais aussi parce que nous voulions prioriser la précision de forme quantitativement. La sous-section 5.2.1 nous a permis de constater que nos reconstructions 3D ne sont pas lisses et que notre méthode a de la difficulté à reconstruire le sommet du grand trochanter. Nous croyons qu'en retravaillant l'intégration de ces trois composantes à la fonction de coût, nous pourrions obtenir des reconstructions 3D plus lisses, ce qui serait un avantage si nos modèles 3D venaient à être utilisés pour la création de prothèses, par exemple.

Notre méthode de déformation automatique permet d'obtenir une reconstruction 3D très précise (sous 0.5mm d'erreur point à surface moyenne) tant que la distance à parcourir pour un sommet du modèle générique est inférieure à 12.89mm, ce qui nous a limités dans un seul exemple de notre base de données de test contenant 69 fémurs. La méthode est efficace peu importe le nombre de paires de DRR utilisées et permet d'estimer les paramètres cliniques NSA et HKS de manière adéquate. Le calcul de la torsion fémorale est moins bien réussi par notre méthode, sans doute dû à la faible précision de la définition de l'axe bicondylien.

Le tableau 5.6 présente une comparaison des erreurs de reconstruction P2S moyenne, P2S RMS et SHD moyenne par rapport à la littérature, lorsque nous utilisons la position face/profil. Il s'agit de la position recommandée dans la cabine EOS ainsi que de celle qui permet d'obtenir la meilleure précision de forme pour notre méthode.

Nos résultats sont plus précis que les autres méthodes de littérature qui sont évaluées dans un contexte similaire (semi-automatiques et évaluées sur des DRR ou des fémurs cadavériques). Ces méthodes ont en moyenne une erreur P2S moyenne de 1mm alors que nos erreurs sont sous la barre des 0.5mm. La méthode de Tchinde Fotsin *et al.* (2019) présente une erreur P2S RMS de 0.7mm, similaire à la nôtre de 0.6mm, mais ne reconstruit que le fémur distal. Il en va de même pour la méthode de Tsai *et al.* (2015), qui est automatique, avec une erreur P2S moyenne

Tableau 5.6 Comparaison des erreurs avec la littérature en fonction de la région du fémur reconstruite, lorsque les radiographies face/profil sont utilisées

Article	P2S moy. (mm)	P2S RMS (mm)	Modalité d'éval.	Auto
Femur complet				
Cresson <i>et al.</i> (2010)	1.68	N/D	Acq. EOS cadav.	Non
Chaibi (2010)	1	N/D	Acq. EOS cadav.	Non
Klima <i>et al.</i> (2016)	1.18	N/D	DRR/CT	Oui
Giridon <i>et al.</i> (2020)	1.0	1.6	Acq. EOS	Non
Notre méthode	0.41	0.55	DRR modèles 3D	Non
Femur proximal				
Zheng <i>et al.</i> (2009)	0.9	N/D	Radio. cadav.	Non
Zheng (2011)	1.5	N/D	DRR cadav.	Non
Boussaid <i>et al.</i> (2011)	N/D	1.97	Radio. cadav.	Non
Zheng (2013)	0.7	N/D	DRR cadav.	Non
Yu & Zheng (2015)	1.4	N/D	C-arm cadav.	Oui
Yu <i>et al.</i> (2017)	1.3	N/D	C-arm cadav.	Oui
Notre méthode	0.49	0.65	DRR modèles 3D	Non
Femur distal				
Fleute & Lavallée (1999)	N/D	0.99	Contours	Non
Laporte <i>et al.</i> (2003)	1	N/D	Radio. cadav.	Non
Zhu & Li (2011)	1.16	N/D	Fluoro.	Oui
Baka <i>et al.</i> (2011)	N/D	1.68	Radio.	Oui
Karade & Ravi (2015)	1.2	N/D	Contours	Non
Tsai <i>et al.</i> (2015)	0.67	N/D	Fluoro	Oui
Cerveri <i>et al.</i> (2017)	N/D	0.97	DRR/CT	Non
Tchinde Fotsin <i>et al.</i> (2019)	N/D	0.7	DRR modèles 3D	Oui
Wu & Mahfouz (2021)	N/D	1.19	Fluoro	Oui
Notre méthode	0.46	0.60	DRR modèles 3D	Non

de 0.67mm. Par contre, comme nous l'avons noté à la section 2.2, cette méthode n'est évaluée que sur deux fémurs alors que nous en avons 69.

Il est difficile d'effectuer une comparaison directe aux méthodes de reconstruction 3D automatiques ou à celles qui utilisent des radiographies de patients. Nous avons deux très grands avantages par rapport à ces méthodes : nous initialisons la pose et l'échelle à partir du modèle de référence et nous utilisons des DRR générées depuis des modèles 3D. Nous pouvons constater à la section 5.2.4 que la différence de modalité nous confère un gros avantage. Notre méthode

ne généralise absolument pas aux radiographies EOS et l'estimation de pose automatique générerait sans doute des erreurs qui ne pourraient être facilement corrigées par notre méthode de déformation.

Suite à l'évaluation de notre méthode lorsque plusieurs points de vue sont utilisés pour générer les paires de DRR, nous pouvons conclure que l'utilisation de toutes les radiographies disponibles est avantageuse lorsqu'elles sont utilisées avec notre méthode, sauf lorsque deux paires de DRR sont obtenues à partir de points de vue orthogonaux. Comme le gain de performance n'est pas énorme (0.1mm en passant d'une paire de DRR à deux avec les points de vue optimaux $(0, 0, 0)$ et $(0, 20, 225)$), nous ne considérons pas qu'il serait avantageux d'acquérir davantage de radiographies pour un patient dans l'unique but d'améliorer la précision de la reconstruction 3D.

CONCLUSION ET RECOMMANDATIONS

Nous avons mis en place une nouvelle méthode de déformation 3D automatique d'un fémur générique à l'aide d'une méthode d'apprentissage profond, initialement utilisée en imagerie optique. Cette méthode permet de déformer la surface d'un fémur à partir d'un ensemble de taille arbitraire de DRR générées depuis des modèles 3D de fémur. Il s'agit d'un pas vers l'automatisation de la reconstruction 3D du fémur à partir de radiographies EOS calibrées. Nous mettons de l'avant deux principales contributions à notre projet de recherche : la mise en place d'une méthode de déformation automatique du fémur en fonction d'un nombre arbitraire d'images calibrées et l'étude de l'impact de la pose du patient et du nombre d'images utilisées lors de la reconstruction 3D.

Afin de mettre en place notre méthode, une revue de la littérature a été effectuée. Dans cette revue, nous avons relevé deux familles de méthodes pouvant répondre à notre objectif de recherche : les méthodes de recalage 3D/2D non rigide et les méthodes d'apprentissage profond. Les méthodes de recalage, bien que plus souvent utilisées dans la littérature, s'appuient majoritairement sur l'utilisation de modèles statistiques de forme qui permettent de reconstruire un fémur en fonction des variations observées dans une base de données de modèles 3D de fémurs. Ces méthodes ont l'avantage d'être robustes et de produire des modèles plausibles plutôt précis, mais sont limitées par les exemples disponibles dans la base de données et ne sont pas bien adaptées à reconstruire des détails qui peuvent se retrouver sur le fémur. Notre méthode est aussi limitée d'une certaine façon par la base de données due à la manière dont est définie la norme maximale du vecteur de déplacement. De plus, les méthodes de recalage s'appuient sur des méthodes d'extraction de caractéristiques géométriques ou bien de métriques de similitude qui sont sensibles au bruit dans les images, ce qui affecte la précision de la reconstruction 3D finale. C'est pourquoi nous avons choisi de nous tourner vers une méthode d'apprentissage profond. La majorité des méthodes de reconstruction 3D en apprentissage profond utilisent des grilles de voxels qui demandent énormément de mémoire graphique. Nous avons choisi de nous tourner vers la

méthode Pixel2Mesh++ Wen *et al.* (2019), qui permet de déformer un maillage 3D en fonction d'un nombre arbitraire de radiographies calibrées.

Notre méthode a été évaluée sur un ensemble de 69 modèles 3D reconstruits à l'aide de la méthode de Chaibi (2010) et de DRR générées depuis différents points de vue de ces modèles. Suite à nos évaluations de précision de la forme finale de la reconstruction 3D ainsi que des paramètres cliniques extraits de ces modèles, nous pouvons affirmer que notre méthode permet d'obtenir une reconstruction 3D précise du fémur présenté dans les radiographies. En associant à chaque sommet du modèle 3D des caractéristiques géométriques extraites des radiographies par un CNN, notre méthode met en correspondance de manière implicite les caractéristiques d'images aux sommets du modèle générique utilisé. Ceci évite le processus d'extraction et de mise en correspondances des caractéristiques qui est complexe en recalage 3D/2D géométrique. Notre méthode permet ensuite d'estimer un champ de déformation appliqué à l'ensemble des sommets du modèle générique, ce qui permet un grand contrôle sur la forme finale. Notre méthode de déformation est très rapide (0.5s) et permet d'obtenir une reconstruction avec une erreur P2S moyenne de moins de 0.5mm. Lorsqu'elle est utilisée avec 2 à 10 paires de DRR calibrées, la précision de forme de la méthode s'améliore selon toutes nos métriques d'évaluation, ce qui montre que la méthode est bel et bien capable d'intégrer l'information provenant de différents points de vue.

6.1 Recommandations

Bien que notre méthode montre des résultats impressionnants en termes de précision, il reste encore du travail à faire afin de pouvoir l'utiliser à des fins cliniques.

Une première limite de notre méthode est la régularité de la surface des fémurs reconstruits. Bien qu'il serait possible d'appliquer un algorithme de lissage aux modèles obtenus à l'aide de notre méthode, ces algorithmes ne seraient pas nécessairement optimisés pour conserver la

précision de forme qui est essentielle dans notre application. La première recommandation que nous proposons en lien avec ce problème serait d'abord d'évaluer ces algorithmes de lissage pour vérifier leur impact sur la précision du modèle final. Par exemple, si le lissage produit une forme qui est en moyenne aussi précise que le modèle non-lisse, la simple application de cet algorithme pourrait régler notre problème. Dans le cas contraire, nous croyons qu'il serait avantageux de s'intéresser à nouveau aux trois composantes de la fonction de coût qui ont été exclus de notre méthode. La première étape, qui est complexe à notre avis, serait de mettre en place une métrique qui reflète bien la qualité ainsi que la précision de forme d'une reconstruction 3D. Comme l'indiquent Wang *et al.* (2018), la distance de Chamfer ne permet pas à elle seule de déterminer la qualité d'une reconstruction 3D. Sans une telle métrique, il est à notre avis difficile d'établir les hyperparamètres optimaux pour procéder à l'entraînement de notre méthode de déformation automatique.

Ensuite, l'initialisation de la pose et de l'échelle du fémur dans les images devrait être automatisée. Nous avons entraînée et évaluée notre méthode à partir de la pose et de l'échelle des modèles de référence dans le cadre de notre projet, ce qui nous confère un grand avantage de précision. Comme nous avons pu le constater dans notre revue de la littérature, l'initialisation automatique de la pose et de l'échelle n'est pas sans erreurs et il est fréquent que le recalage alterne entre l'optimisation de la pose et de la forme de manière à optimiser les deux en même temps suite à une première initialisation. Comme le déplacement maximal appliqué par notre méthode est limité, il est nécessaire que le fémur générique et le fémur de référence soit déjà le plus près possible avant d'entamer la déformation. Pour ce faire, nous croyons que la manière la plus avantageuse de procéder serait d'identifier automatiquement trois points saillants par fémur dans les radiographies EOS à l'aide d'un CNN et de procéder à une première déformation MLS du fémur générique en utilisant ces trois points comme points de contrôle. Cela permettrait non seulement d'identifier la position du fémur dans le référentiel EOS, mais aussi d'appliquer

une première déformation qui devrait permettre de rapprocher le fémur générique du fémur de référence.

Une troisième limitation importante de notre méthode repose sur l'utilisation de DRR pour entraîner et évaluer le modèle. Comme nous l'avons vu à la section 5.2.4, notre méthode ne permet pas de reconstruire le fémur à partir de radiographies EOS. Cette limitation est due entre autres au fait qu'il n'y a qu'un fémur dans nos images, qu'il n'y a pas le bruit que l'on retrouve habituellement dans les radiographies, qu'il n'y a aucun tissu mou et que la distribution d'intensité n'est pas la même entre les DRR et les radiographies EOS. Il serait possible d'ajouter un bruit dans les DRR similaire à celui présent dans les radiographies EOS en suivant les travaux de Gravel, Beaudoin & De Guise (2004), ce qui permettrait diminuer la différence entre les deux modalités. Dans la littérature, Kasten *et al.* (2020); Aubert *et al.* (2022) utilisent un réseau de neurones génératif afin d'appliquer un transfert de style qui permet de résoudre la majorité de ces problèmes. Ce réseau permet de transformer la modalité utilisée en clinique, la radiographie EOS dans notre cas, à la modalité utilisée pour entraîner le réseau de neurones. La méthode est aussi utilisée par Aubert *et al.* (2022) afin de segmenter les structures d'intérêt dans les images, ce qui permettrait de reconstruire un fémur à la fois.

Finalement, nous croyons que notre méthode devrait être ré-entraînée à partir de projections EOS générée depuis des CT scans pour lesquels les fémurs auraient été segmentés. Notre méthode utilise des reconstructions 3D obtenues à l'aide de la méthode de Chaibi (2010), mais ces reconstructions ont elles-même une erreur de 1mm (P2S RMS) avec les fémurs des patients. En utilisant des segmentations de CT, nous pourrions obtenir des reconstructions 3D encore plus réalistes et exploiter au maximum la déformation applicable par notre méthode.

ANNEXE I

RECALAGE GÉOMÉTRIQUE À L'AIDE D'UN MODÈLE STATISTIQUE DE FORME

Cette annexe explique avec plus de détails la manière dont le modèle statistique de forme est utilisé pour recalibrer un modèle générique à un objet dans des radiographies en fonction des contours extraits des images et projetés à partir du modèle générique.

L'ACP est une méthode linéaire de réduction de dimension qui permet, dans notre contexte, de déterminer quelles sont les principales variations que les modèles présents dans la base de données possèdent par rapport à la forme moyenne (Sarkalkan, Weinans & Zadpoor, 2014). Il est ensuite possible d'exprimer un modèle 3D en n'utilisant que les modes de variations e définis par les vecteurs propres de l'ensemble de données, un vecteur de poids w et le modèle moyen \bar{m} (Équation A I-1). La figure I-1 montre l'impact des coefficients e appliqués aux deux premiers modes de variation. Cette figure permet de constater l'intérêt envers l'utilisation des SSM en recalage 3D/2D : un petit nombre de paramètres à optimiser permet de créer des représentations réalistes du fémur. Les premiers modes de déformation représentent habituellement un haut pourcentage de la variance entre les exemples de la base de données, ce qui fait en sorte qu'il est possible de n'en sélectionner qu'un petit sous-ensemble afin de permettre la convergence rapide et efficace de la fonction de coût (Cootes *et al.*, 1995). Lindner (2017) expliquent en détail le processus de création du SSM.

$$M(w) = \bar{M} + w * e \quad (\text{A I-1})$$

Pour obtenir les caractéristiques 2D du modèle 3D, les paramètres de calibration des différentes radiographies seront utilisés afin de projeter des points clés ou le contour du modèle 3D sur chacune des radiographies. Baka *et al.* (2011); Boussaid *et al.* (2011) définissent le contour projeté du modèle 3D en conservant une liste des sommets pour lesquels deux faces rattachées ont des normales qui pointent dans des directions opposées de la source des rayons X. Karade & Ravi (2015) projettent l'ensemble des sommets du modèle 3D sur chaque radiographie puis utilisent

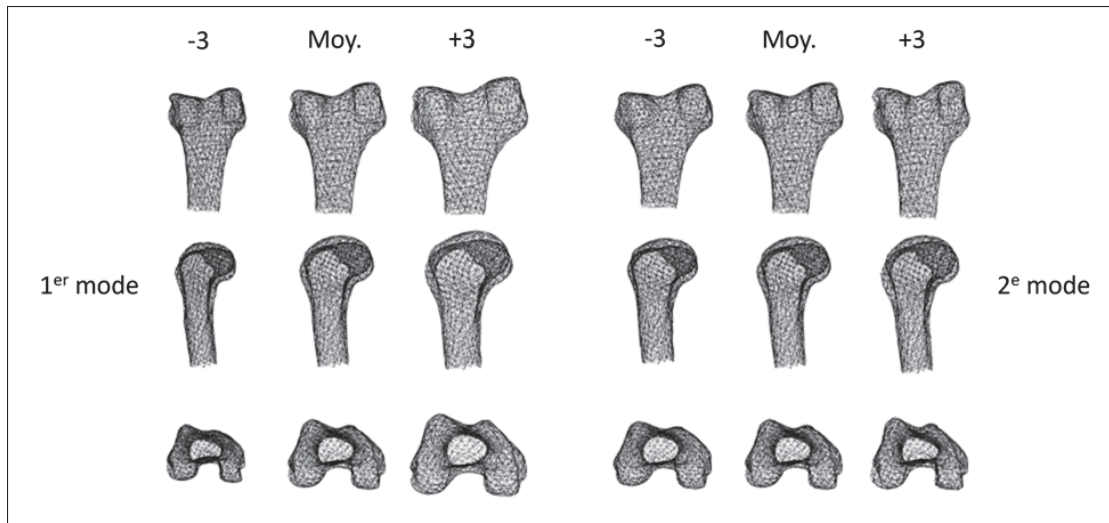


Figure-A I-1 Variations de la forme du fémur distal en fonction des coefficients appliqués aux 2 premiers modes de variation

Modifiée de Fleute & Lavallée (1999)

une triangulation de Delaunay (Delaunay, 1934) ne conservant que les arêtes de moins de 2mm pour définir le contour. Ces caractéristiques géométriques des radiographies et du modèle 3D sont mises en correspondance. L'optimisation de la fonction de coût A I-2 est faite en trouvant les paramètres w du SSM qui minimisent la distance entre les contours projetés \hat{C}_i et les contours extraits C_i correspondants.

$$\min_e \sum_i^{|\mathcal{C}|} |\hat{C}_i - C_i|^2 \text{ où } \hat{C} = Proj(\bar{M} + w * e) \quad (\text{A I-2})$$

ANNEXE II

REVUE APPROFONDIE DES MÉTHODES DE RECONSTRUCTION 3D PAR APPRENTISSAGE SANS MODÈLE INITIAL

Cette annexe présente d'autres méthodes de reconstruction 3D utilisant l'apprentissage profond sans déformer un modèle générique. Comme ces méthodes utilisent des images optiques et qu'elles n'ont pas été retenues comme étant pertinente à notre application, elles ont été placées en annexe.

Choy *et al.* (2016) proposent l'architecture 3D-R2N2, le premier réseau de neurones capable de reconstruire un objet en 3D à partir d'un nombre arbitraire d'images. Comme la méthode Pixel2Mesh++ (Wen *et al.*, 2019), cette méthode est entraînée et évaluée sur l'ensemble de données ShapeNet (Chang *et al.*, 2015). L'architecture est composée d'un CNN 2D, d'un réseau de neurones récurrent de type Long-Short Term Memory (LSTM) (Hochreiter & Schmidhuber, 1997) permettant d'agréger l'information des différentes vues et d'un CNN 3D prenant en entrée la sortie du LSTM afin de reconstruire le modèle 3D dans une grille de voxels de dimension 32^3 . Cette méthode comporte trois limitations : les réseaux de type LSTM ne sont pas efficaces pour traiter des données non ordonnées (Yang *et al.*, 2020), la résolution est très basse et la précision, évaluée à l'aide du coefficient IoU (Tanimoto, 1958), n'est que de 57%.

Afin de régler le problème de l'utilisation du LSTM, Yang *et al.* (2020) proposent AttSets, un module d'attention (Vaswani *et al.*, 2017), qui permet de combiner un nombre arbitraire d'images en calculant une moyenne pondérée des caractéristiques extraites du CNN 2D en fonction de leur importance. L'utilisation d'un mécanisme d'attention pour fusionner les caractéristiques extraites des différentes images est intéressante parce que les différents points de vue présentés à l'algorithme de reconstruction 3D ne possèdent pas les mêmes informations ni la même pertinence. Apprendre à pondérer les caractéristiques extraites de ces images pourrait mener à un ensemble de caractéristiques final qui permettrait une reconstruction 3D plus précise et plus robuste. Les résultats proposés par Yang *et al.* (2020) sont meilleurs que ceux de la méthode originale, avec un coefficient IoU (Tanimoto, 1958) de 66% lorsque deux vues sont utilisées.

Xie *et al.* (2020) proposent Pix2Vox++, une méthode de reconstruction 3D basée sur l'imagerie optique. L'architecture est composée d'un CNN 2D de type ResNet (He, Zhang, Ren & Sun, 2015), qui extrait des caractéristiques de chaque image. Un CNN 3D génère à partir de ces caractéristiques une reconstruction 3D grossière par image d'entrée. Leur contribution principale est le module "Multi-scale Context Aware Fusion" qui permet d'identifier les parties de chaque reconstruction grossière ayant la meilleure qualité afin de fusionner les reconstructions 3D en un modèle final. La méthode proposée par Xie *et al.* (2020) permet d'obtenir un score IoU de 66.1%.

ANNEXE III

DÉTAILS DU FONCTIONNEMENT DE PIXEL2MESH++

Cette annexe a pour objectif d'expliquer en détails le fonctionnement de la méthode Pixel2Mesh++. La figure III-1 présente l'architecture utilisée par cette méthode. Elle est composée de trois modules principaux : le CNN d'extraction de caractéristiques, le module de génération de la forme grossière et le module de déformation fine multivues.

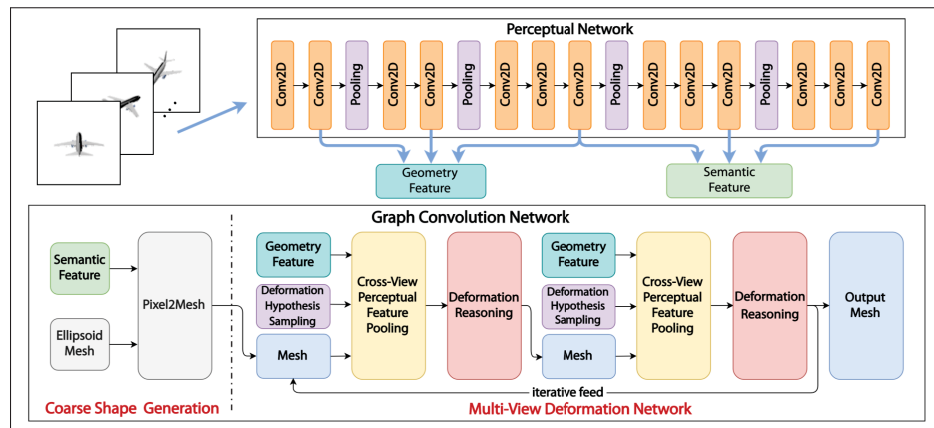


Figure-A III-1 Architecture de l'algorithme Pixel2Mesh++
Tirée de Wen *et al.* (2019)

1. Extraction des caractéristiques géométriques

Le module d'extraction de caractéristiques (*Perceptual Network* dans la figure III-1) est basé sur l'architecture VGG16 (Simonyan & Zisserman, 2015), qui contient 16 couches de convolution. Wen *et al.* (2019) séparent les caractéristiques extraites de ce VGG16 en deux : les caractéristiques géométriques forment la première moitié des caractéristiques extraites et les caractéristiques sémantiques la deuxième moitié. L'architecture VGG16 est relativement ancienne et différentes architectures de CNN sont maintenant plus performantes, mais les auteurs indiqués dans leur questionnaire de code source qu'ils ont choisi de conserver l'architecture VGG16 car elle est facile à entraîner¹.

¹ <https://github.com/walsvid/Pixel2MeshPlusPlus/issues/1#issuecomment-546655000>

2. Génération grossière du maillage 3D

Le module de génération grossière (*Coarse Shape Generation* dans la figure III-1) est basé sur l'architecture Pixel2Mesh (Wang *et al.*, 2018). Les images d'entrée sont d'abord passées dans le CNN de manière à obtenir des cartes d'activation après chaque couche de convolution. Ces cartes d'activation représentent les caractéristiques extraites après chaque couche. Afin de déterminer comment déformer le modèle 3D, chaque sommet du modèle 3D est projeté à l'aide des paramètres de calibration des différentes images dans l'espace 2D. Avec les coordonnées 2D de chaque sommet dans chaque image, il est possible de trouver les caractéristiques correspondantes dans les cartes d'activation (voir figure III-2). Seules les caractéristiques sémantiques sont utilisées dans cette étape.




Figure-A III-2 Projection des sommets du modèle dans Pixel2Mesh afin d'obtenir les caractéristiques associées
Tirée de Wang *et al.* (2018)

La figure III-3 présente l'ensemble du module de génération grossière. Avec les caractéristiques 2D associées à chaque sommet, un module de GCN est utilisé afin de déformer un modèle générique d'ellipsoïde. Après une première itération de déformation, un sur échantillonnage du maillage 3D est effectué afin de l'affiner. Ce module de génération grossière permet d'obtenir un modèle 3D qui sera ensuite déformé plus finement par le dernier module de Pixel2Mesh++, le module de déformation fine multivues.




Figure-A III-3 Architecture de l’algorithme Pixel2Mesh
Tirée de Wang *et al.* (2018)

3. Déformation fine multivues

La déformation fine multivues est différente de la déformation grossière. 42 hypothèses de déplacements sont échantillonnées uniformément sur une sphère de rayon λ = autour de chaque sommet (voir figure III-4). La valeur de λ est un hyperparamètre qui est fixé à 1^{-3} dans l’architecture originale. Cette valeur est difficile à interpréter puisque les modèles 3D utilisés dans la base de données ShapeNet (Chang *et al.*, 2015) n’ont pas d’échelle ou d’unité de mesure associées. Cet échantillonnage par sommet (Deformation Hypothesis Sampling) est illustré à la figure III-1. Un graphe est créé pour chaque sommet à partir des 42 hypothèses et du centre d’échantillonnage, où chaque noeud représente un point 3D et où les sommets les plus près sont liés par des arêtes, créant un graphe avec 43 noeuds et 162 arêtes par sommet du modèle 3D.

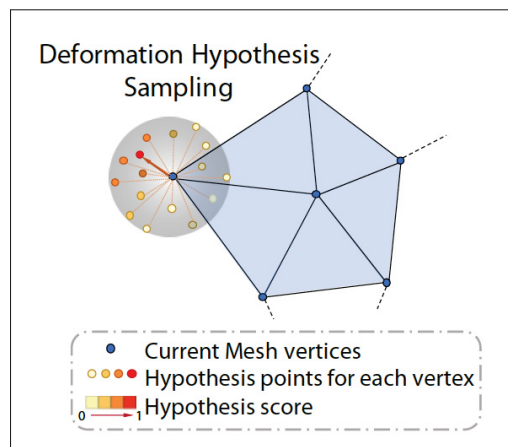


Figure-A III-4 Échantillonnage d’hypothèses pour chaque sommet du modèle 3D
Tirée de Wen *et al.* (2019)

Toutes ces hypothèses ainsi que leurs sommets correspondants sont ensuite projetés dans l'ensemble des images 2D de manière à en extraire les caractéristiques correspondantes (étape de "Cross-View Perceptual Feature Pooling"). Comme le nombre d'images données en entrée au réseau est variable et que les réseaux de GCN ne fonctionnent généralement pas avec des entrées de taille variable (Wen *et al.*, 2019), il est nécessaire de fusionner l'ensemble des caractéristiques liées à un point 3D en un vecteur de taille fixe. Pour chaque caractéristique géométrique extraite du CNN de chaque image, la moyenne, le maximum et l'écart-type sont calculés de manière à obtenir un vecteur de taille fixe peu importe le nombre d'images utilisé en entrée. À ce vecteur est ajoutée la position 3D du point associé au vecteur (voir figure III-5).

$$\left(\begin{pmatrix} x \\ y \\ z \end{pmatrix}, \begin{pmatrix} \alpha_1 \\ \beta_1 \\ \delta_1 \\ \dots \end{pmatrix}, \begin{pmatrix} \alpha_2 \\ \beta_2 \\ \delta_2 \\ \dots \end{pmatrix}, \begin{pmatrix} \alpha_3 \\ \beta_3 \\ \delta_3 \\ \dots \end{pmatrix}, \begin{pmatrix} \alpha_4 \\ \beta_4 \\ \delta_4 \\ \dots \end{pmatrix} \right) \Rightarrow \begin{pmatrix} \bar{\alpha} \\ \max(\alpha) \\ \sigma(\alpha) \\ \\ \bar{\beta} \\ \max(\beta) \\ \sigma(\beta) \\ \\ \bar{\delta} \\ \max(\delta) \\ \sigma(\delta) \\ \\ \dots \\ \\ x \\ y \\ z \end{pmatrix}$$

Figure-A III-5 Agrégation des caractéristiques d'un sommet issues de quatre images

La figure III-6 présente avec plus de détails l'étape de "Deformation Reasoning", tout en prenant compte des étapes précédemment décrites. Pour chacun des 2466 sommets du modèle 3D grossier, un graphe d'hypothèses de déformation est créé à l'aide du module "Deformation Hypothesis Sampling". Ensuite, pour chacun des noeuds de ces graphes, représentant un sommet du modèle 3D ou une hypothèse de déplacement, les caractéristiques géométriques sont extraites

des images par le VGG 16 et sont fusionnées grâce au module de "Cross-View Perceptual Feature Pooling". Chaque graphe associé à un sommet est ensuite utilisé en entrée d'un GCN qui calculera, pour chaque hypothèse de déplacement, un score où une valeur élevée indique que le déplacement du sommet devrait s'effectuer dans cette direction (voir figure III-4). Finalement, une moyenne pondérée de ces scores et des hypothèses correspondantes sont utilisées pour déplacer le sommet.




Figure-A III-6 Diagramme détaillé de l'étape de "Deformation Reasoning"
Tirée de Wen *et al.* (2019)

4. Fonction de coût

L'apprentissage de la déformation proposée par Pixel2Mesh++ est guidé par une fonction de coût, présentée à l'équation A III-1, utilisant le modèle générique initial $\bar{M}(\bar{S}, \bar{F}, \bar{E})$, le modèle générique déformé $M(S, F, E)$ et le modèle de référence $\hat{M}(\hat{S}, \hat{F}, \hat{E})$. La fonction de coût contient quatre composantes (Wang *et al.*, 2018) : la distance symétrique de Chamfer entre M et \hat{M} , la distance cosinus entre ces deux modèles, une régularisation laplacienne appliquée entre \bar{M} et M ainsi qu'une régularisation de longueur d'arêtes appliquée entre \bar{M} et M . Ces quatre composantes sont balancées à l'aide de coefficients définis expérimentalement λ_i .

$$\begin{aligned}
Loss(\hat{M}, \bar{M}, M) = & chamfer(\hat{S}, S) \\
& + \lambda_2 * cosine(\hat{N}, S, E) \\
& + \lambda_3 * laplace(\bar{S}, S) \\
& + \lambda_4 * edge(E)
\end{aligned} \tag{A III-1}$$

La distance symétrique de Chamfer (équation A III-2) permet de calculer, pour chaque sommet \hat{S} d'un modèle de référence \hat{M} , la distance au plus proche sommet S du modèle reconstruit M et inversement de S vers \hat{S} . Cette fonction de coût force le réseau de neurones à apprendre à superposer les sommets du modèle générique au modèle attendu à partir des caractéristiques d'images.

$$chamfer(\hat{S}, S) = \sum_i^{|S|} \|\min_j (S_i - \hat{S}_j)\|^2 + \sum_j^{|\hat{S}|} \|\min_i (S_i - \hat{S}_j)\|^2 \tag{A III-2}$$

La distance cosinus force le réseau de neurones à apprendre à minimiser le cosinus entre les arêtes du modèle reconstruit $E(S_i, S_j)$ et les normales des sommets du modèle de référence $\hat{N}_k S_k$, où \hat{S}_k est correspondant à S_i (voir équation A III-3). Afin de bien comprendre cette fonction de coût, il faut d'abord se ramener à la définition du cosinus entre deux vecteurs : $cos(\theta) = \frac{\langle v_1, v_2 \rangle}{|v_1| * |v_2|}$ où $\langle v_1, v_2 \rangle$ est le produit scalaire entre v_1, v_2 . La distance cosinus, présentée à l'équation A III-4, minimise uniquement le produit scalaire entre les arêtes du modèle et les arêtes, puisque ces deux ensembles de vecteurs sont normalisés dans la fonction de coût. Afin de calculer cette fonction de coût, il est nécessaire que les normales \hat{N}_i des sommets des modèles de référence soient connues et qu'un ensemble d'arêtes \hat{E} soit défini tel que $\hat{E}(\hat{S}_i) = \hat{S}_j$ où \hat{S}_j est un sommet voisin de \hat{S}_i . Les normales N des sommets S d'un maillage 3D sont calculées en fonction des normales des faces F du modèle 3D. La normale N_f d'une face F_i , composée de trois sommets S_1, S_2, S_3 est la normale du plan formé par les trois sommets. Afin de calculer la normale d'un sommet, on calcule la moyenne des normales de toutes les faces associées à ce sommet. Wang

et al. (2018) indiquent que cette fonction de coût ne peut être égale à zéro que lorsque l'ensemble des sommets se trouvent sur un même plan, ce qui n'est pas réaliste dans aucune application en reconstruction 3D. Par contre, selon leur expérimentation, la distance cosinus permet d'améliorer l'alignement entre les sommets du modèle reconstruit S et du modèle de référence \hat{S} .

$$corr(S_i) := j \text{ t.q. } S_i - \hat{S}_j < S_i - \hat{S}_k \forall \hat{S}_k \in \hat{S} \text{ où } k \neq j \quad (\text{A III-3})$$

$$cosine(\hat{N}, S, E) = \sum_i^{|S|} \left\langle \frac{\hat{N}_{corr(S_i)}}{|\hat{N}_{corr(S_i)}|}, \frac{S_i - E(S_i)}{|S_i - E(S_i)|} \right\rangle \quad (\text{A III-4})$$

La régularisation laplacienne cherche à minimiser la différence entre les coordonnées laplaciennes (voir figure III-7) du modèle générique reconstruit par rapport à celles du modèle générique initial. La coordonnée laplacienne δ_i d'un sommet S_i est définie comme la différence entre la coordonnée du sommet et la moyenne de ses voisins (voir équation A III-5), où $\mathcal{N}(S_i)$ représente l'ensemble du voisinage du sommet S_i . La régularisation laplacienne (voir équation A III-6) se calcule ensuite comme la différence des coordonnées laplacienne avant et après la déformation. Elle force le réseau de neurones à déplacer un sommet en tenant compte de son voisinage (Wang *et al.*, 2018).

$$\delta_i = S_i - \frac{\sum_{k \in \mathcal{N}(S_i)} k}{|\mathcal{N}(S_i)|} \quad (\text{A III-5})$$

$$laplace(\delta, \bar{\delta}) = \sum_i \|\delta_i - \bar{\delta}_i\|^2 \quad (\text{A III-6})$$

Finalement, la régularisation de longueur d'arête (voir équation A III-7) pénalise les arêtes longues en calculant la distance euclidienne entre les deux sommets d'une arête. Wang *et al.* (2018) indiquent que cette régularisation est utilisée afin d'éviter que l'optimisation ne converge vers un minimum local où un sommet isolé pourrait être très loin de son voisinage. Cette

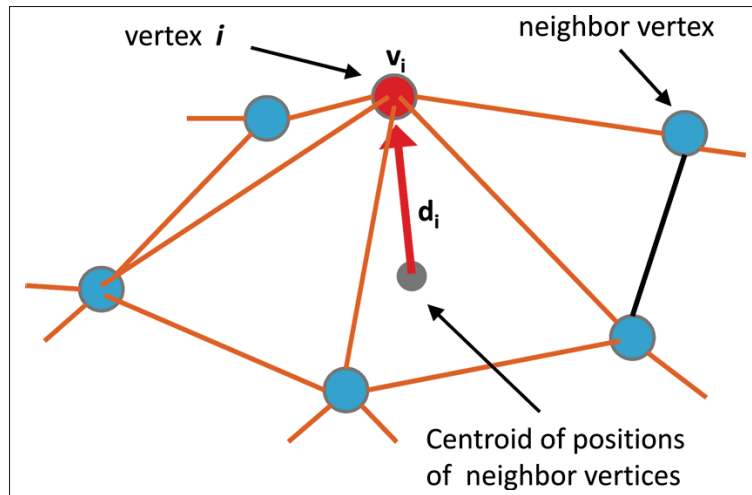


Figure-A III-7 Le vecteur d_i correspond à la coordonnée laplacienne de v_i . Ce vecteur lie le point situé au barycentre des voisins de v_i et v_i lui-même

Tirée de Karade & Ravi (2015)

régularisation est aussi utilisée de manière à conserver la distribution relativement uniforme des sommets sur le maillage 3D.

$$edge(S) = \sum_i^{|S|} \sum_j^{\mathcal{N}(S_i)} \|S_i - S_j\|^2 \quad (\text{A III-7})$$

5. Étude d'ablation

Les auteurs de la méthode Pixel2Mesh (Wen *et al.*, 2019) présentent une étude d'ablation où chaque composante de la fonction de coût, à l'exception de la distance de Chamfer, est retirée afin de montrer l'utilité de ces composantes. Une étude qualitative de l'impact de ces composantes ainsi qu'une étude quantitative de la précision de la forme sont présentées. Qualitativement, nous pouvons voir à la figure III-8 que ces trois composantes permettent, dans cette méthode, d'obtenir une surface beaucoup plus lisse et d'éviter l'intersection des faces du modèle 3D. Quantitativement, ces paramètres nuisent à la précision. Le retrait de distance cosine, de la régularisation laplacienne et de la régularisation de longueur d'arêtes améliore la précision des

reconstructions obtenues de $7 * 10^{-3}$, $5 * 10^{-3}$ et $3 * 10^{-2}$ unités (Wang *et al.*, 2018). Wang *et al.* (2018) conservent tout de même ces trois composantes en indiquant que qualitativement, elles permettent d'obtenir une reconstruction 3D de meilleure qualité et que la distance de Chamfer n'est pas nécessairement une métrique adaptée à mesurer la qualité d'une reconstruction 3D. À la vue de cette étude d'ablation, nous sommes d'accord avec cette dernière affirmation. Par contre, il est difficile de savoir si cette qualité visuelle de la reconstruction 3D est pertinente dans notre contexte et si cette qualité est davantage importante que la précision de forme. L'objectif de nos modélisations 3D n'étant pas d'être observées pour leur qualité, mais plutôt d'être utilisées dans un contexte clinique où des mesures seront prises sur ces modèles.

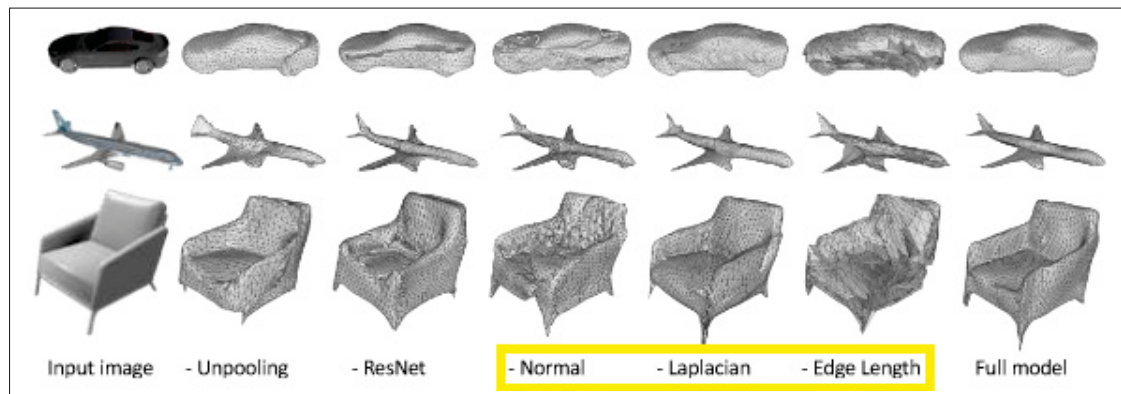


Figure-A III-8 Étude d'ablation qualitative de la méthode Pixel2Mesh. Les trois composantes d'intérêt à notre avis sont le retrait de la distance cosinus (Normal), la régularisation laplacienne (Laplacian) et la régularisation de longueur d'arête (Edge Length)
Tirée de Wang *et al.* (2018)

BIBLIOGRAPHIE

- Aspert, N., Santa-Cruz, D. & Ebrahimi, T. (2002). MESH : measuring errors between surfaces using the Hausdorff distance. *Proceedings. IEEE International Conference on Multimedia and Expo*, pp. 705–708. doi : 10.1109/ICME.2002.1035879.
- Aubert, B., Cresson, T., De Guise, J. & Vazquez, C. (2022). X-ray to DRR images translation for efficient multiple objects similarity measures in deformable model 3D/2D registration. *IEEE Transactions on Medical Imaging*, 1–1. doi : 10.1109/TMI.2022.3218568.
- Baka, N., Kaptein, B., de Bruijne, M., van Walsum, T., Giphart, J., Niessen, W. & Lelieveldt, B. (2011). 2D–3D shape reconstruction of the distal femur from stereo X-ray imaging using statistical shape models. *Medical Image Analysis*, 15(6), 840–850. doi : 10.1016/j.media.2011.04.001.
- Baka, N., de Bruijne, M., van Walsum, T., Kaptein, B. L., Giphart, J. E., Schaap, M., Niessen, W. J. & Lelieveldt, B. P. F. (2012). Statistical Shape Model-Based Femur Kinematics From Biplane Fluoroscopy. *IEEE Transactions on Medical Imaging*, 31(8), 1573–1583. doi : 10.1109/TMI.2012.2195783.
- Besl, P. & McKay, N. D. (1992). A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 14(2), 239–256. doi : 10.1109/34.121791.
- Boussaid, H., Kadoury, S., Kokkinos, I., Lazennec, J.-Y., Zheng, G. & Paragios, N. (2011). 3D Model-based Reconstruction of the Proximal Femur from Low-dose Biplanar X-Ray Images. *Proceedings of the British Machine Vision Conference 2011*, pp. 35.1–35.10. doi : 10.5244/C.25.35.
- Brown, L. G. (1992). A survey of image registration techniques. *ACM Computing Surveys*, 24(4), 325–376. doi : 10.1145/146370.146374.
- Canny, J. (1986). A Computational Approach to Edge Detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(6), 679–698. doi : 10.1109/T-PAMI.1986.4767851.
- Cerveri, P., Sacco, C., Olgiati, G., Manzotti, A. & Baroni, G. (2017). 2D/3D reconstruction of the distal femur using statistical shape models addressing personalized surgical instruments in knee arthroplasty : A feasibility analysis. *The International Journal of Medical Robotics and Computer Assisted Surgery*, 13(4), e1823. doi : 10.1002/rcs.1823.

- Chaibi, Y. (2010). *ADAPTATION DES METHODES DE RECONSTRUCTION 3D RAPIDES PAR STÉRÉORADIOGRAPHIE : MODÉLISATION DU MEMBRE INFÉRIEUR ET CALCUL DES INDICES CLINIQUES EN PRÉSENCE DE DÉFORMATION STRUCTURALE*. (PhD Thesis).
- Chang, A. X., Funkhouser, T., Guibas, L., Hanrahan, P., Huang, Q., Li, Z., Savarese, S., Savva, M., Song, S., Su, H., Xiao, J., Yi, L. & Yu, F. (2015). ShapeNet : An Information-Rich 3D Model Repository. *arXiv :1512.03012 [cs]*. Repéré à <http://arxiv.org/abs/1512.03012>. arXiv : 1512.03012.
- Choy, C. B., Xu, D., Gwak, J., Chen, K. & Savarese, S. (2016). 3D-R2N2 : A Unified Approach for Single and Multi-view 3D Object Reconstruction. *arXiv :1604.00449 [cs]*. Repéré à <http://arxiv.org/abs/1604.00449>. arXiv : 1604.00449.
- Cohen-Or, D. (2009). Space Deformations, Surface Deformations and the Opportunities In-Between. *Journal of Computer Science and Technology*, 24(1), 2–5. doi : 10.1007/s11390-009-9200-0.
- Cootes, T., Taylor, C., Cooper, D. & Graham, J. (1995). Active Shape Models-Their Training and Application. *Computer Vision and Image Understanding*, 61(1), 38–59. doi : 10.1006/c-viu.1995.1004.
- Cresson, T., Branchaud, D., Chav, R., Godbout, B. & de Guise, J. A. (2010). 3D shape reconstruction of bone from two x-ray images using 2D/3D non-rigid registration based on moving least-squares deformation. pp. 76230F. doi : 10.1117/12.844098.
- Delaunay, B. (1934). Sur la sphère vide. *Bulletin de l'Académie des Sciences de l'URSS. VII. Série*, 1934(6), 793–800. Publisher : Academy of Sciences of the Union of Soviet Socialist Republics - USSR (Akademiya Nauk SSSR).
- Dubousset, J., Charpak, G., Dorion, I., Skalli, W., Lavaste, F., Deguise, J., Kalifa, G. & Ferey, S. (2005). Une nouvelle imagerie Ostéo-Articulaire basse dose en position debout : le système EOS. *Bulletin de l'Académie Nationale de Médecine*, 189(2), 287–300. doi : 10.1016/S0001-4079(19)33584-8.
- Ehlke, M., Ramm, H., Lamecker, H., Hege, H.-C. & Zachow, S. (2013). Fast Generation of Virtual X-ray Images for Reconstruction of 3D Anatomy. *IEEE Transactions on Visualization and Computer Graphics*, 19(12), 2673–2682. doi : 10.1109/TVCG.2013.159.
- Fahim, G., Amin, K. & Zarif, S. (2021). Single-View 3D reconstruction : A Survey of deep learning methods. *Computers & Graphics*, 94, 164–190. doi : 10.1016/j.cag.2020.12.004.

- Filippi, S., Motyl, B. & Bandera, C. (2008). Analysis of existing methods for 3D modelling of femurs starting from two orthogonal images and development of a script for a commercial software package. *Computer Methods and Programs in Biomedicine*, 89(1), 76–82. doi : 10.1016/j.cmpb.2007.10.011.
- Fleute, M. & Lavallée, S. (1999). Nonrigid 3-D/2-D Registration of Images Using Statistical Models. Dans Goos, G., Hartmanis, J., van Leeuwen, J., Taylor, C. & Colchester, A. (Éds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI’99* (vol. 1679, pp. 138–147). Berlin, Heidelberg : Springer Berlin Heidelberg. doi : 10.1007/10704282_15.
- Fu, K., Peng, J., He, Q. & Zhang, H. (2021). Single image 3D object reconstruction based on deep learning : A review. *Multimedia Tools and Applications*, 80(1), 463–498. doi : 10.1007/s11042-020-09722-8.
- Gajny, L., Girinon, F., Bayoud, W., Lahkar, B., Bonnet-Lebrun, A., Rouch, P., Lazennec, J.-Y. & Skalli, W. (2022). Fast quasi-automated 3D reconstruction of lower limbs from low dose biplanar radiographs using statistical shape models and contour matching. *Medical Engineering & Physics*, 101, 103769. doi : 10.1016/j.medengphy.2022.103769.
- Girinon, F., Gajny, L., Ebrahimi, S., Dagneaux, L., Rouch, P. & Skalli, W. (2020). Quasi-automated reconstruction of the femur from bi-planar X-rays. *Computer Methods in Biomechanics and Biomedical Engineering : Imaging & Visualization*, 8(5), 529–537. doi : 10.1080/21681163.2020.1725915.
- Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep Learning*. MIT Press. Repéré à <http://www.deeplearningbook.org>.
- Goswami, B. & Kr., S. (2015). 3D Modeling of X-Ray Images : A Review. *International Journal of Computer Applications*, 132(7), 40–46. doi : 10.5120/ijca2015907566.
- Gravel, P., Beaudoin, G. & De Guise, J. (2004). A method for modeling noise in medical images. *IEEE Transactions on Medical Imaging*, 23(10), 1221–1232. doi : 10.1109/TMI.2004.832656.
- Groisser, B. [arXiv :1904.06711 [eess]]. (2019). Geometry of the EOS(R) Radiographic Scanner. arXiv. Repéré le 2023-08-13 à <http://arxiv.org/abs/1904.06711>.
- Guenoun, B., Zadegan, F., Aim, F., Hannouche, D. & Nizard, R. (2012). Reliability of a new method for lower-extremity measurements based on stereoradiographic three-dimensional reconstruction. *Orthopaedics & Traumatology : Surgery & Research*, 98(5), 506–513. doi : 10.1016/j.otsr.2012.03.014.

- Han, X.-F., Laga, H. & Bennamoun, M. (2019). Image-based 3D Object Reconstruction : State-of-the-Art and Trends in the Deep Learning Era. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1–1. doi : 10.1109/TPAMI.2019.2954885. arXiv : 1906.06543.
- Hasegawa, K., Okamoto, M., Hatsushikano, S., Caseiro, G. & Watanabe, K. (2018). Difference in whole spinal alignment between supine and standing positions in patients with adult spinal deformity using a new comparison method with slot-scanning three-dimensional X-ray imager and computed tomography through digital reconstructed radiography. *BMC Musculoskeletal Disorders*, 19(1), 437. doi : 10.1186/s12891-018-2355-5.
- He, K., Zhang, X., Ren, S. & Sun, J. (2015). Deep Residual Learning for Image Recognition. *arXiv :1512.03385 [cs]*. Repéré à <http://arxiv.org/abs/1512.03385>. arXiv : 1512.03385.
- Hochreiter, S. & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. doi : 10.1162/neco.1997.9.8.1735.
- Hosseinian, S. & Arefi, H. (2015). 3D RECONSTRUCTION FROM MULTI-VIEW MEDICAL X-RAY IMAGES – REVIEW AND EVALUATION OF EXISTING METHODS. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-1-W5, 319–326. doi : 10.5194/isprsarchives-XL-1-W5-319-2015.
- Huang, J., Tian, F., Zhang, Z., Shi, W., Lin, J., Chen, L. & Yang, H. (2020). Reliability and concurrent validity of angle measurements in lower limb : EOS 3D goniometer versus 2D manual goniometer. *Journal of Orthopaedic Translation*, 24, 96–102. doi : 10.1016/j.jot.2020.05.002.
- Humbert, L. (2008). Contribution à l’automatisation du traitement des radiographies du système ostéoarticulaire pour la modélisation géométrique et l’analyse clinique. 205.
- Isola, P., Zhu, J.-Y., Zhou, T. & Efros, A. A. [arXiv :1611.07004 [cs]]. (2018). Image-to-Image Translation with Conditional Adversarial Networks. arXiv. Repéré le 2022-12-29 à <http://arxiv.org/abs/1611.07004>.
- Jannin, P., Fitzpatrick, J., Hawkes, D., Pennec, X., Shahidl, R. & Vannier, M. (2002). Validation of medical image processing in image-guided therapy. *IEEE Transactions on Medical Imaging*, 21(12), 1445–1449. doi : 10.1109/TMI.2002.806568.
- Jianhua Yao & Taylor. (2003). Assessing accuracy factors in deformable 2D/3D medical image registration using a statistical pelvis model. *Proceedings Ninth IEEE International Conference on Computer Vision*, pp. 1329–1334 vol.2. doi : 10.1109/ICCV.2003.1238644.

- Jolliffe, I. T. (2002). *Principal component analysis* (éd. 2nd ed). New York : Springer.
- Kanhonou, M. (2017). *Méthode d'évaluation fonctionnelle de la gonarthrose par étude de la pseudo-cinématique d'accroupissement*. (Thèse de doctorat, École de Technologie Supérieure, Montréal). Repéré à https://espace.etsmtl.ca/id/eprint/1949/1/KANHONOU_Mich%C3%A8le.pdf.
- Kar, A., Häne, C. & Malik, J. (2017). Learning a Multi-View Stereo Machine. *arXiv :1708.05375 [cs]*. Repéré à <http://arxiv.org/abs/1708.05375>. arXiv : 1708.05375.
- Karade, V. & Ravi, B. (2015). 3D femur model reconstruction from biplane X-ray images : a novel method based on Laplacian surface deformation. *International Journal of Computer Assisted Radiology and Surgery*, 10(4), 473–485. doi : 10.1007/s11548-014-1097-6.
- Kass, M., Witkin, A. & Terzopoulos, D. (1988). Snakes : Active contour models. *International Journal of Computer Vision*, 1(4), 321–331. doi : 10.1007/BF00133570.
- Kasten, Y., Doktofsky, D. & Kovler, I. (2020). End-To-End Convolutional Neural Network for 3D Reconstruction of Knee Bones From Bi-Planar X-Ray Images. *arXiv :2004.00871 [cs, eess]*. Repéré à <http://arxiv.org/abs/2004.00871>. arXiv : 2004.00871.
- Kim, J., Li, S., Pradhan, D., Hammoud, R., Chen, Q., Yin, F.-F., Zhao, Y., Kim, J. H. & Movsas, B. (2007). Comparison of Similarity Measures for Rigid-body CT/Dual X-ray Image Registrations. *Technology in Cancer Research & Treatment*, 6(4), 337–345. doi : 10.1177/153303460700600411.
- Kingma, D. P. & Ba, J. (2014). Adam : A Method for Stochastic Optimization. doi : 10.48550/ARXIV.1412.6980. Publisher : arXiv Version Number : 9.
- Kipf, T. N. & Welling, M. (2017). Semi-Supervised Classification with Graph Convolutional Networks. *arXiv :1609.02907 [cs, stat]*. Repéré à <http://arxiv.org/abs/1609.02907>. arXiv : 1609.02907.
- Klima, O., Kleparnik, P., Spanel, M. & Zemcik, P. (2016). Intensity-based femoral atlas 2D/3D registration using Levenberg-Marquardt optimisation. pp. 97880F. doi : 10.1117/12.2216529.
- Lamecker, H., Wenckeback, T. & Hege, H.-C. (2006). Atlas-based 3D-Shape Reconstruction from X-Ray Images. *18th International Conference on Pattern Recognition (ICPR'06)*, pp. 371–374. doi : 10.1109/ICPR.2006.279.

- Laporte, S., Skalli, W., De Guise, J., Lavaste, F. & Mitton, D. (2003). A Biplanar Reconstruction Method Based on 2D and 3D Contours : Application to the Distal Femur. *Computer Methods in Biomechanics and Biomedical Engineering*, 6(1), 1–6. doi : 10.1080/1025584031000065956.
- Laporte, S., Mitulescu, A., Mitton, D., Dubousseet, J., De Guise, J. A. & Skalli, W. (2000). 3D Personalized Geometric Modeling of the Pelvis using Stereo X-rays.pdf.
- Le Bras, A., Laporte, S., Mitton, D., de Guise, J. A. & Skalli, W. (2003). Three-dimensional (3D) detailed reconstruction of human vertebrae from low-dose digital stereoradiography. *European Journal of Orthopaedic Surgery & Traumatology*, 13(2), 57–62. doi : 10.1007/s00590-003-0074-5.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. & Jackel, L. D. (1989). Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1(4), 541–551. doi : 10.1162/neco.1989.1.4.541.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A. & Talwalkar, A. (2016). Hyperband : A Novel Bandit-Based Approach to Hyperparameter Optimization. doi : 10.48550/ARXIV.1603.06560. Publisher : arXiv Version Number : 4.
- Li, P., Pei, Y., Guo, Y., Ma, G., Xu, T. & Zha, H. (2020). Non-Rigid 2D-3D Registration Using Convolutional Autoencoders. *2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI)*, pp. 700–704. doi : 10.1109/ISBI45749.2020.9098602.
- Lindner, C. (2017). Automated Image Interpretation Using Statistical Shape Models. Dans *Statistical Shape and Deformation Analysis* (pp. 3–32). Elsevier. doi : 10.1016/B978-0-12-810493-4.00002-X.
- Maintz, J. B. A. & Viergever, M. A. (1998). A survey of medical image registration. *Medical Image Analysis*, 2(1), 36. doi : [https://doi.org/10.1016/S1361-8415\(01\)80026-8](https://doi.org/10.1016/S1361-8415(01)80026-8).
- Manson, E., Ampoh, V. A., Fiagbedzi, E., Amuasi, J., Flether, J. J. & Schandorf, C. (2019). Image Noise in Radiography and Tomography : Causes, Effects and Reduction Techniques.
- Markelj, P., Tomaževič, D., Likar, B. & Pernuš, F. (2012). A review of 3D/2D registration methods for image-guided interventions. *Medical Image Analysis*, 16(3), 642–661. doi : 10.1016/j.media.2010.03.005.
- Matthews, I. & Baker, S. (2004). Active Appearance Models Revisited. *International Journal of Computer Vision*, 60(2), 135–164. doi : 10.1023/B:VISI.0000029666.37597.d3.

- McLaughlin, R., Hipwell, J., Hawkes, D., Noble, J., Byrne, J. & Cox, T. (2005). A comparison of a similarity-based and a feature-based 2-D-3-D registration method for neurointerventional use. *IEEE Transactions on Medical Imaging*, 24(8), 1058–1066. doi : 10.1109/TMI.2005.852067.
- Melhem, E., Assi, A., El Rachkidi, R. & Ghanem, I. (2016). EOS[®] biplanar X-ray imaging : concept, developments, benefits, and limitations. *Journal of Children's Orthopaedics*, 10(1), 1–14. doi : 10.1007/s11832-016-0713-0.
- Mettler, F. A., Huda, W., Yoshizumi, T. T. & Mahesh, M. (2008). Effective Doses in Radiology and Diagnostic Nuclear Medicine : A Catalog. *Radiology*, 248(1), 254–263. doi : 10.1148/radiol.2481071451.
- Milletari, F., Navab, N. & Ahmadi, S.-A. [arXiv :1606.04797 [cs]]. (2016). V-Net : Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. arXiv. Repéré le 2023-01-23 à <http://arxiv.org/abs/1606.04797>.
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill. Repéré à <https://books.google.ca/books?id=EoYBngEACAAJ>.
- Mitton, D., Landry, C., Véron, S., Skalli, W., Lavaste, F. & De Guise, J. A. (2000). 3D reconstruction method from biplanar radiography using non-stereocorresponding points and elastic deformable meshes. *Medical and Biological Engineering and Computing*, 38(2), 133–139. doi : 10.1007/BF02344767.
- Mitton, D., Deschênes, S., Laporte, S., Godbout, B., Bertrand, S., de Guise, J. A. & Skalli, W. (2006). 3D reconstruction of the pelvis from bi-planar radiography. *Computer Methods in Biomechanics and Biomedical Engineering*, 9(1), 1–5. doi : 10.1080/10255840500521786.
- Mitulescu, A., Semaan, I., De Guise, J. A., Leborgne, P., Adamsbaum, C. & Skalli, W. (2001). Validation of the non-stereo corresponding points stereoradiographic 3D reconstruction technique. *Medical and Biological Engineering and Computing*, 39(2), 152–158. doi : 10.1007/BF02344797.
- Molinaro, A. M., Simon, R. & Pfeiffer, R. M. (2005). Prediction error estimation : a comparison of resampling methods. *Bioinformatics*, 21(15), 3301–3307. doi : 10.1093/bioinformatics/bti499.
- Olory Agomma, R., Cresson, T., De Guise, J. & Vazquez, C. (2022). Automatic lower limb bone segmentation in radiographs with different orientations and fields of view based on a contextual network. *International Journal of Computer Assisted Radiology and Surgery*, 18(4), 641–651. doi : 10.1007/s11548-022-02798-7.

- Pajarinen, J., Lindahl, J., Savolainen, V., Michelsson, O. & Hirvensalo, E. (2004). Femoral shaft medialisation and neck-shaft angle in unstable pertrochanteric femoral fractures. *International Orthopaedics*. doi : 10.1007/s00264-004-0590-x.
- Pei, Y., Zhang, Y., Qin, H., Ma, G., Guo, Y., Xu, T. & Zha, H. (2017). Non-rigid Craniofacial 2D-3D Registration Using CNN-Based Regression. Dans Cardoso, M. J., Arbel, T., Carneiro, G., Syeda-Mahmood, T., Tavares, J. M. R., Moradi, M., Bradley, A., Greenspan, H., Papa, J. P., Madabhushi, A., Nascimento, J. C., Cardoso, J. S., Belagiannis, V. & Lu, Z. (Éds.), *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support* (vol. 10553, pp. 117–125). Cham : Springer International Publishing. doi : 10.1007/978-3-319-67558-9_14.
- Pomero, V., Mitton, D., Laporte, S., de Guise, J. A. & Skalli, W. (2004). Fast accurate stereoradiographic 3D-reconstruction of the spine using a combined geometric and statistic model. *Clinical Biomechanics*, 19(3), 240–247. doi : 10.1016/j.clinbiomech.2003.11.014.
- Reyneke, C. J. F., Luthi, M., Burdin, V., Douglas, T. S., Vetter, T. & Mutsvangwa, T. E. M. (2019). Review of 2-D/3-D Reconstruction Using Statistical Shape and Intensity Models and X-Ray Image Synthesis : Toward a Unified Framework. *IEEE Reviews in Biomedical Engineering*, 12, 269–286. doi : 10.1109/RBME.2018.2876450.
- Rueckert, D., Sonoda, L., Hayes, C., Hill, D., Leach, M. & Hawkes, D. (1999). Nonrigid registration using free-form deformations : application to breast MR images. *IEEE Transactions on Medical Imaging*, 18(8), 712–721. doi : 10.1109/42.796284.
- Rueckert, D., Frangi, A. & Schnabel, J. (2003). Automatic construction of 3-D statistical deformation models of the brain using nonrigid registration. *IEEE Transactions on Medical Imaging*, 22(8), 1014–1025. doi : 10.1109/TMI.2003.815865.
- Russakoff, D. B., Rohlfing, T., Ho, A., Kim, D. H., Shahidi, R., Adler, J. R. & Maurer, C. R. (2003). Evaluation of Intensity-Based 2D-3D Spine Image Registration Using Clinical Gold-Standard Data. Dans Goos, G., Hartmanis, J., van Leeuwen, J., Gee, J. C., Maintz, J. B. A. & Vannier, M. W. (Éds.), *Biomedical Image Registration* (vol. 2717, pp. 151–160). Berlin, Heidelberg : Springer Berlin Heidelberg. doi : 10.1007/978-3-540-39701-4_16.
- Sadowsky, O. (2007). Deformable 2D-3D Registration of the Pelvis with a Limited Field of View Using Shape Statistics. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2007*, 10, 519–26. doi : 10.1007/978-3-540-75759-7_63.
- Sarkalkan, N., Weinans, H. & Zadpoor, A. A. (2014). Statistical shape and appearance models of bones. *Bone*, 60, 129–140. doi : 10.1016/j.bone.2013.12.006.
- Sederberg, T. W. (1986). Free-Form Deformation of Solid Geometric Models. 20(4), 10.

- Serrurier, A., Quijano, S., Nizard, R. & Skalli, W. (2012). Robust femur condyle disambiguation on biplanar X-rays. *Medical Engineering & Physics*, 34(10), 1433–1440. doi : 10.1016/j.medengphy.2012.01.008.
- Shannon, C. E. (1948). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(3), 379–423. doi : 10.1002/j.1538-7305.1948.tb01338.x.
- Simonyan, K. & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv :1409.1556 [cs]*. Repéré à <http://arxiv.org/abs/1409.1556>. arXiv : 1409.1556.
- Sorkine, O., Cohen-Or, D., Lipman, Y., Alexa, M., Rössl, C. & Seidel, H.-P. (2004). Laplacian surface editing. *Proceedings of the 2004 Eurographics/ACM SIGGRAPH symposium on Geometry processing - SGP '04*, pp. 175. doi : 10.1145/1057432.1057456.
- Sotiras, A., Davatzikos, C. & Paragios, N. (2013). Deformable Medical Image Registration : A Survey. *IEEE Transactions on Medical Imaging*, 32(7), 1153–1190. doi : 10.1109/TMI.2013.2265603.
- Suzuki, S. & be, K. (1985). Topological structural analysis of digitized binary images by border following. *Computer Vision, Graphics, and Image Processing*, 30(1), 32–46. doi : 10.1016/0734-189X(85)90016-7.
- Tanimoto, T. T. (1958). *An elementary mathematical theory of classification and prediction*. New York, : International Business Machines Corporation.
- Tchinde Fotsin, T. J., Vazquez, C., Cresson, T. & De Guise, J. (2019). Shape, Pose and Density Statistical Model for 3D Reconstruction of Articulated Structures from X-Ray Images. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 2748–2751. doi : 10.1109/EMBC.2019.8857699.
- Trochu, F. (1993). A contouring program based on dual kriging interpolation. *Engineering with Computers*, 9(3), 160–177. doi : 10.1007/BF01206346.
- Tsai, T.-Y., Li, J.-S., Wang, S., Li, P., Kwon, Y.-M. & Li, G. (2015). Principal component analysis in construction of 3D human knee joint models using a statistical shape model method. *Computer Methods in Biomechanics and Biomedical Engineering*, 18(7), 721–729. doi : 10.1080/10255842.2013.843676.
- Van Houtte, J., Gao, X., Sijbers, J. & Zheng, G. (2021). 2D/3D Registration with a Statistical Deformation Model Prior Using Deep Learning. *2021 IEEE EMBS International Conference on Biomedical and Health Informatics (BHI)*, pp. 1–4. doi : 10.1109/BHI50953.2021.9508540.

- Van Houtte, J., Audenaert, E., Zheng, G. & Sijbers, J. (2022). Deep learning-based 2D/3D registration of an atlas to biplanar X-ray images. *International Journal of Computer Assisted Radiology and Surgery*, 17(7), 1333–1342. doi : 10.1007/s11548-022-02586-3.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. & Polosukhin, I. (2017). Attention Is All You Need. *arXiv :1706.03762 [cs]*. Repéré à <http://arxiv.org/abs/1706.03762>. arXiv : 1706.03762.
- Vidal, F. P. & Villard, P.-F. (2016). Development and validation of real-time simulation of X-ray imaging with respiratory motion. *Computerized Medical Imaging and Graphics*, 49, 1–15. doi : 10.1016/j.compmedimag.2015.12.002.
- Villena-Martinez, V., Oprea, S., Saval-Calvo, M., Azorin-Lopez, J., Fuster-Guillo, A. & Fisher, R. B. (2020). When Deep Learning Meets Data Alignment : A Review on Deep Registration Networks (DRNs). *Applied Sciences*, 10(21), 7524. doi : 10.3390/app10217524.
- Vincent, L. (1998). Minimal Path Algorithms for the Robust Detection of Linear Features in Gray Images. *Proceedings of the Fourth International Symposium on Mathematical Morphology and Its Applications to Image and Signal Processing*, (ISMM '98), 331–338.
- Wang, N., Zhang, Y., Li, Z., Fu, Y., Liu, W. & Jiang, Y.-G. (2018). Pixel2Mesh : Generating 3D Mesh Models from Single RGB Images. *arXiv :1804.01654 [cs]*. Repéré à <http://arxiv.org/abs/1804.01654>. arXiv : 1804.01654.
- Wen, C., Zhang, Y., Li, Z. & Fu, Y. (2019). Pixel2Mesh++ : Multi-View 3D Mesh Generation via Deformation. *arXiv :1908.01491 [cs]*. Repéré à <http://arxiv.org/abs/1908.01491>. arXiv : 1908.01491.
- Wu, J. & Mahfouz, M. R. (2021). Reconstruction of knee anatomy from single-plane fluoroscopic x-ray based on a nonlinear statistical shape model. *Journal of Medical Imaging*, 8(01). doi : 10.1117/1.JMI.8.1.016001.
- Wybier, M. & Bossard, P. (2013). Musculoskeletal imaging in progress : The EOS imaging system. *Joint Bone Spine*, 80(3), 238–243. doi : 10.1016/j.jbspin.2012.09.018.
- Xiao, Y.-P., Lai, Y.-K., Zhang, F.-L., Li, C. & Gao, L. (2020). A survey on deep geometry learning : From a representation perspective. *Computational Visual Media*, 6(2), 113–133. doi : 10.1007/s41095-020-0174-8.
- Xie, H., Yao, H., Zhang, S., Zhou, S. & Sun, W. (2020). Pix2Vox++ : Multi-scale Context-aware 3D Object Reconstruction from Single and Multiple Images. *International Journal of Computer Vision*, 128(12), 2919–2935. doi : 10.1007/s11263-020-01347-6.

- Yang, B., Wang, S., Markham, A. & Trigoni, N. (2020). Robust Attentional Aggregation of Deep Feature Sets for Multi-view 3D Reconstruction. *International Journal of Computer Vision*, 128(1), 53–73. doi : 10.1007/s11263-019-01217-w.
- Yao, J. (2001). *A Statistical Bone Density Atlas and Deformable Medical Image Registration*. (Thèse de doctorat, John Hopkins University).
- Yeghiazaryan, V. & Voiculescu, I. (2018). Family of boundary overlap metrics for the evaluation of medical image segmentation. *Journal of Medical Imaging*, 5(01), 1. doi : 10.1117/1.JMI.5.1.015006.
- Yu, W. & Zheng, G. (2015). 2D-3D regularized deformable b-spline registration : Application to the proximal femur. *2015 IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, pp. 829–832. doi : 10.1109/ISBI.2015.7163999.
- Yu, W., Chu, C., Tannast, M. & Zheng, G. (2016). Fully automatic reconstruction of personalized 3D volumes of the proximal femur from 2D X-ray images. *International Journal of Computer Assisted Radiology and Surgery*, 11(9), 1673–1685. doi : 10.1007/s11548-016-1400-9.
- Yu, W., Tannast, M. & Zheng, G. (2017). Non-rigid free-form 2D–3D registration using a B-spline-based statistical deformation model. *Pattern Recognition*, 63, 689–699. doi : 10.1016/j.patcog.2016.09.036.
- Zheng, G. (2011). Personalized X-Ray Reconstruction of the Proximal Femur via Intensity-Based Non-rigid 2D-3D Registration. Dans Fichtinger, G., Martel, A. & Peters, T. (Éds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2011* (vol. 6892, pp. 598–606). Berlin, Heidelberg : Springer Berlin Heidelberg. doi : 10.1007/978-3-642-23629-7_73.
- Zheng, G. (2013). 3D volumetric intensity reconstruction from 2D x-ray images using partial least squares regression. *2013 IEEE 10th International Symposium on Biomedical Imaging*, pp. 1268–1271. doi : 10.1109/ISBI.2013.6556762.
- Zheng, G., Gollmer, S., Schumann, S., Dong, X., Feilkas, T. & González Ballester, M. A. (2009). A 2D/3D correspondence building method for reconstruction of a patient-specific 3D bone surface model using point distribution models and calibrated X-ray images. *Medical Image Analysis*, 13(6), 883–899. doi : 10.1016/j.media.2008.12.003.
- Zhu, J.-Y., Park, T., Isola, P. & Efros, A. A. (2020). Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. *arXiv :1703.10593 [cs]*. Repéré à <http://arxiv.org/abs/1703.10593>. arXiv : 1703.10593.

Zhu, Y. & Gortler, S. J. (2007). 3D Deformation Using Moving Least Squares. 5.

Zhu, Z. & Li, G. (2011). Construction of 3D human distal femoral surface models using a 3D statistical deformable model. *Journal of Biomechanics*, 44(13), 2362–2368. doi : 10.1016/j.jbiomech.2011.07.006.

Škerl, D., Likar, B. & Pernuš, F. (2006). Evaluation of similarity measures for 3D/2D image registration. pp. 61442F. doi : 10.1117/12.652088.