



Titre: Modélisation physique des tissus mous du tronc scoliotique pour la
Title: simulation de l'apparence post-chirurgicale

Auteur: Kondo Claude Assi
Author:

Date: 2014

Type: Mémoire ou thèse / Dissertation or Thesis

Référence: Assi, K. C. (2014). Modélisation physique des tissus mous du tronc scoliotique
Citation: pour la simulation de l'apparence post-chirurgicale [Thèse de doctorat, École
Polytechnique de Montréal]. PolyPublie. <https://publications.polymtl.ca/1405/>

 **Document en libre accès dans PolyPublie**
Open Access document in PolyPublie

URL de PolyPublie: <https://publications.polymtl.ca/1405/>
PolyPublie URL:

**Directeurs de
recherche:** Farida Cheriet, & Hubert Labelle
Advisors:

Programme: Génie informatique
Program:

UNIVERSITÉ DE MONTRÉAL

MODÉLISATION PHYSIQUE DES TISSUS MOUS DU TRONC SCOLIOTIQUE POUR
LA SIMULATION DE L'APPARENCE POST-CHIRURGICALE

KONDO CLAUDE ASSI
DÉPARTEMENT DE GÉNIE INFORMATIQUE ET GÉNIE LOGICIEL
ÉCOLE POLYTECHNIQUE DE MONTRÉAL

THÈSE PRÉSENTÉE EN VUE DE L'OBTENTION
DU DIPLÔME DE PHILOSOPHIÆ DOCTOR
(GÉNIE INFORMATIQUE)
AVRIL 2014

UNIVERSITÉ DE MONTRÉAL

ÉCOLE POLYTECHNIQUE DE MONTRÉAL

Cette thèse intitulée:

MODÉLISATION PHYSIQUE DES TISSUS MOUS DU TRONC SCOLIOTIQUE POUR
LA SIMULATION DE L'APPARENCE POST-CHIRURGICALE

présentée par: ASSI Kondo Claude

en vue de l'obtention du diplôme de: Philosophiæ Doctor

a été dûment acceptée par le jury d'examen constitué de:

M. GUIBAUT François, Ph.D., président

Mme CHERIET Farida, Ph.D., membre et directrice de recherche

M. LABELLE Hubert, M.D., membre et codirecteur de recherche

Mme PÉRIÉ-CURNIER Delphine, Doctorat, membre

M. KRZYZAK Adam, Ph.D., membre

DÉDICACE

*À ma mère,
À mon père,
À mon épouse Lynda.*

REMERCIEMENTS

Je tiens tout d’abord à remercier ma directrice de recherche, la Docteure Farida Cheriet, professeure titulaire au département de génie informatique et génie logiciel de l’École Polytechnique de Montréal, pour avoir accepté de superviser ce travail et pour l’opportunité qu’elle m’a offerte d’allier le biomédical et le génie informatique.

Je tiens également à remercier mon co-directeur de recherche, le Docteur Hubert Labelle, chirurgien-orthopédiste au Centre Hospitalier Universitaire de Sainte-Justine de Montréal, pour son regard clinique.

Je remercie les membres du Jury pour l’intérêt qu’ils ont porté à mon travail, pour avoir accepté de le lire et de l’évaluer.

Je voudrais remercier Philippe Débanné et Sébastien Grenier, associés de recherche, qui m’ont aidé tout au long de ce projet.

Je voudrais également remercier mes collègues, étudiants du Laboratoire Liv4D de l’École Polytechnique, pour l’environnement amical entretenu qui a rendu possible la réalisation de cette recherche.

Je remercie vivement l’ensemble des organismes suivants, pour leur soutien financier. Ce sont: la Fondation CHU Sainte-Justine et la Fondation des étoiles, les Instituts de recherche en santé du Canada (IRSC). Ce projet de recherche a été financé en partie par le Conseil de recherches en sciences naturelles et en génie du Canada (CRSNG). L’équipement a été financé par la Fondation Canadienne pour l’Innovation.

J’aimerais remercier énormément mes parents, ma mère et mon père, et ma famille pour leur soutien, leur encouragement et leur amour. Je tiens à remercier mon épouse Lynda, pour sa patience et son soutien.

RÉSUMÉ

La scoliose idiopathique de l'adolescence (SIA) est une déformation tridimensionnelle complexe de la colonne vertébrale et de la cage thoracique. Dans le cas de déformation sévère, le recours à la chirurgie correctrice de la colonne vertébrale est requis comme moyen de traitement. Environ un patient sur mille atteint de SIA aura à subir une chirurgie correctrice de la colonne vertébrale. Cependant, dans la plupart des cas, une correction optimale de la colonne vertébrale n'entraîne pas nécessairement une correction optimale de l'apparence externe. Une asymétrie du tronc peut persister à l'issue de la chirurgie et cela est difficile à prédire par les chirurgiens. Cela est problématique, car l'apparence externe est un facteur important de satisfaction pour les patients. Il serait intéressant de disposer d'outils d'assistance à la planification de chirurgie pour la scoliose prenant en compte les attentes du patient concernant l'esthétique de l'apparence du tronc.

La simulation médicale sur ordinateur est devenue un outil important d'assistance à la prise de décision clinique. Elle est utilisée pour permettre de prédire et analyser les effets de traitements médicaux, ainsi que la prédiction de changements anatomiques dus à l'évolution d'une pathologie. Dans le contexte de la chirurgie pour la scoliose, des simulateurs de chirurgie correctrice de la colonne vertébrale existent. Des modèles biomécaniques pour la simulation de l'instrumentation de la colonne vertébrale en chirurgie de la scoliose ont été développés par différents chercheurs. Toutefois, ceux-ci ne prédisent pas la forme externe du tronc après chirurgie. De cet état des choses, découle la problématique et les objectifs de cette thèse : modéliser le tronc scoliotique en vue de la simulation de la forme postopératoire du tronc, et améliorer la précision des prédictions afin de proposer une stratégie opératoire optimale.

La question de recherche abordée dans cette thèse concerne le développement de méthodes pour la simulation et la prédiction de la forme postopératoire du tronc en chirurgie pour la scoliose. Quatre objectifs spécifiques de recherche ont été définis. La première partie du travail (traitant du premier objectif) a consisté à développer un modèle physique de déformation pour le tronc scoliotique. Contrairement au modèle existant, un nouveau modèle physique de déformation incrémentale est proposé pour tenir compte des grandes déformations du tronc. L'inspection qualitative des surfaces de tronc simulées et réelles montre une bonne approximation de la correction de la gibbosité. L'évaluation quantitative de la simulation est basée sur l'indice de rotation de la surface du dos (indice BSR). Il se définit comme l'angle formé par la double tangente du côté postérieur de chaque section horizontale de la surface du tronc et l'axe passant par les épines iliaques antéro-supérieures (ASIS) projeté sur le plan frontal. Les valeurs d'indices BSR, mesurées à différents niveaux vertébraux, montrent une erreur

moyenne de $1.20^\circ(\pm 0.73)$ à $3.20^\circ (\pm 0.83)$ dans la région thoracique, indiquant un accord entre les troncs prédits et les données réelles. La deuxième partie (regroupant les trois autres objectifs spécifiques) a consisté à améliorer la précision des prédictions. Nous proposons deux méthodes de détermination de formes à priori de tronc postopératoire (soit basé sur une prédiction statistique, soit basé sur une prédiction de type proche voisin). Ces outils exploitent l'intuition de choisir la restriction du champ de déplacement à la frontière du domaine du tronc (la surface externe) comme une première approximation de la déformation du tronc.

La réalisation des objectifs de cette recherche est à l'origine de contributions originales à l'état de l'art aussi bien en simulation physique de tissus mous qu'en apprentissage machine pour l'analyse de formes. Ce projet propose une nouvelle méthode de modélisation des déformations de tissus mous du tronc scoliotique pour la simulation de l'apparence postopératoire. Cette méthode présente, ainsi, l'avantage de constituer un outil pour les systèmes de planification par ordinateur de traitement chirurgical de la scoliose. En perspective, des études complémentaires sont suggérées pour surmonter certaines limitations des méthodes proposées. En particulier, l'incorporation d'un modèle du tronc obtenu par une fusion multimodale d'images (IRM/RX/TOPO) de patients scoliotiques, pour une meilleure personnalisation géométrique, devrait conduire à une amélioration de la précision de la simulation.

ABSTRACT

Adolescent Idiopathic scoliosis (AIS) is a complex three-dimensional deformation of the spine and rib cage. In case of severe spine deformity, a spine surgery is required as a treatment. Approximately one in a thousand patients suffering from AIS will have a spine surgery. However, in most cases, an optimal correction of the spine does not necessarily results in an optimal correction of the external appearance. A trunk asymmetry may persist after surgery and it is difficult to predict by surgeons. This is problematic because the external appearance is one of the most important factor for the patient satisfaction. It would be interesting to have available computer based scoliosis surgery planning assistance tools that takes into account the expectation of the patient regarding the aesthetics of the trunk appearance.

Computer based medical simulation is becoming an important tool to support clinical decision making. It is used to predict and analyze the effects of treatments, as well as the predictions of changes due to pathology evolution. In the context of scoliosis surgery, spine correction surgery simulators exist. Biomechanical models for the simulation of the spine instrumentation in scoliosis surgery have been developed by different researchers. However, they do not simulate the postoperative appearance of the trunk. From this observation arise the problem and objectives of this thesis: modeling the scoliotic trunk in order to simulate the postoperative trunk shape, and improve predictions accuracy in order to propose an optimal surgery strategy.

The research question of this thesis concerns the development of methods for the simulation and the prediction of the trunk postoperative shape in scoliosis surgery. Four research objectives have been defined. The first part of this work (dealing with the first objective) consisted in developing a physically based deformation model of the scoliotic trunk. Unlike the existing model, a novel incremental approach is proposed to take into account large deformations of the trunk. The qualitative visual inspection of the simulated and actual trunk surfaces show a good approximation of the correction of the rib hump. The quantitative evaluation of the simulation is based on the back surface rotation index (BSR index). It is defined as the angle formed by the dual tangent to the posterior side of each section of the trunk surface and the axis passing through the patient's anterior superior iliac spines (ASIS), projected onto the axial plane. The BSR indices, measured at different vertebral levels, shows an average error in the range of $1.20^\circ (\pm 0.73)$ to $3.20^\circ (\pm 0.83)$ in the thoracic region, indicating a good agreement between the predicted and actual trunk surfaces. The second part (dealing with the remaining three objectives) addressed the prediction accuracy improvement. In this regard, two tools have been developed: one for predicting 3D trunk

shapes based on a statistical approach, and the other being a prediction tool based on nearest neighbor methods. These tools make use of the intuition of choosing the restriction of the displacement field on the trunk domain boundary (the external surface) as a first approximation of the trunk deformation.

The achievement of the research objectives has resulted in original contributions to the state of the art in physical simulation of soft tissues as well as in machine learning for shape analysis. This project proposes a novel method for modeling scoliotic trunk soft tissue deformation for the simulation of the postoperative appearance. This method has, thus, the advantage of being a potential tool for computer based scoliosis surgery planning systems. As perspectives, further research studies may be suggested in order to overcome the limitations of the proposed methods. In particular, the incorporation of a trunk model obtained from a multimodal image fusion (MRI / RX / TOPO) for a better personalization of the anatomical structures may lead to the improvement of the simulation accuracy.

TABLE DES MATIÈRES

DÉDICACE	iii
REMERCIEMENTS	iv
RÉSUMÉ	v
ABSTRACT	vii
TABLE DES MATIÈRES	ix
LISTE DES TABLEAUX	xiii
LISTE DES FIGURES	xiv
LISTE DES SIGLES ET ABRÉVIATIONS	xvii
CHAPITRE 1 INTRODUCTION	1
1.1 Mise en contexte	1
1.2 Organisation de la thèse	2
CHAPITRE 2 REVUE DE LITTÉRATURE	4
2.1 Anatomie du tronc humain	4
2.1.1 Structures osseuses	4
2.1.2 Structures molles	5
2.2 La scoliose	5
2.2.1 Déformations scoliotiques	5
2.2.2 Traitement de la scoliose: la chirurgie	6
2.3 Simulation médicale pour la planification de chirurgie	7
2.4 Modélisation des tissus mous	9
2.5 Analyse de formes et anatomie numérique	10
2.5.1 Approches statistiques de prédiction de formes	11
2.5.2 Méthodes proches-voisins pour la régression	12
2.5.3 Apprentissage de métriques	12
2.6 Synthèse de la revue de littérature	13

CHAPITRE 3	MÉTHODOLOGIE GÉNÉRALE	15
3.1	Formulation du problème	15
3.2	Question de recherche	16
3.3	Objectifs de recherche	16
3.3.1	Modéliser les déformations de tissus mous	16
3.3.2	Prédire les courbes anatomiques du tronc	16
3.3.3	Proposer une distance dans l'espace des formes de troncs	17
3.3.4	Prédire les déformations par une approche proche voisin	17
3.4	Approche générale	18
3.4.1	Modélisation de la déformation de tissus mous par une méthode incrémentale	18
3.4.2	Prédiction de courbes anatomiques du tronc	18
3.4.3	Apprentissage de métrique de distance	19
3.4.4	Prédiction de forme utilisant la regression par proche voisin	19
3.5	Diagramme récapitulatif de la méthodologie et des contributions	19
CHAPITRE 4	ARTICLE 1: A PHYSICALLY BASED TRUNK SOFT TISSUE MODELING FOR SCOLIOSIS SURGERY PLANNING SYSTEMS	21
4.1	Abstract	21
4.2	Introduction	21
4.3	Methodology	23
4.3.1	The scoliotic patients sample	23
4.3.2	Data acquisition and construction of patient-specific trunk geometric model	23
4.3.3	Numerical simulation of postoperative trunk shapes	25
4.3.4	Modeling the trunk soft tissue deformation	25
4.3.5	Evaluation of the simulation	30
4.4	Results	31
4.5	Discussion	32
4.6	Conclusion	35
CHAPITRE 5	ARTICLE 2: STATISTICAL MODEL BASED 3D SHAPE PREDICTION OF POSTOPERATIVE TRUNKS FOR NON-INVASIVE SCOLIOSIS SURGERY PLANNING	39
5.1	Abstract	39
5.2	Introduction	39
5.3	Materials and Methods	43

5.3.1	Data acquisition of the trunk surface	43
5.3.2	Feature curves representation of the trunk	43
5.3.3	Statistical framework	46
5.3.4	Least Squares Support Vector Regression	48
5.4	Results	49
5.4.1	Validation	50
5.4.2	Results	50
5.5	Discussion	51
5.6	Conclusion	52
CHAPITRE 6 ARTICLE 3: MODIFIED LARGE MARGIN NEAREST NEIGHBOR		
	METRIC LEARNING FOR REGRESSION	54
6.1	Abstract	54
6.2	Introduction	54
6.3	Modified large margin nearest neighbor metric learning	55
6.3.1	Intuition of our modified LMNN	55
6.3.2	Proximity order preservation indicator	57
6.3.3	Loss function	58
6.4	Results	59
6.5	Conclusion	61
CHAPITRE 7 MÉTHODOLOGIE ET RÉSULTATS COMPLÉMENTAIRES: RÉGRES-		
SION PROCHE VOISIN POUR LA PRÉDICTION DE TRONC POSTOPÉRA-		
TOIRE		
7.1	Prédiction de forme utilisant la régression par proche voisin	64
7.1.1	Prédiction de forme 3D de tronc postopératoire	65
7.2	Expériences	67
7.3	Résultats	68
7.4	Discussion	70
CHAPITRE 8 DISCUSSION GÉNÉRALE		
8.1	Stabilité de simulation d'apparence	73
8.2	Précision de prédiction	74
8.2.1	Courbes anatomiques du tronc	74
8.2.2	Apprentissage de métriques	74
8.2.3	Régression par proche voisins	75
8.3	Limitations générales	75

CHAPITRE 9 CONCLUSION	77
RÉFÉRENCES	80

LISTE DES TABLEAUX

Tableau 7.1	Tableau des statistiques de performance en précision de prédiction de notre algorithme. La mesure de performance considérée est la différence dans l'indice de rotation de la surface du dos pour différentes sections horizontales du tronc. Les estimations sont faites sur un ensemble de données de 5 patients. SD : Écart type, CI : Interval de confiance. Les values des statistiques suivantes sont rapportées : MEAN, SD, MAX, MIN, MEDIAN.	72
-------------	--	----

LISTE DES FIGURES

Figure 3.1	Diagramme récapitulatif de la méthodologie générale.	20
Figure 4.1	Surgical instrumentation of a scoliotic spine for the correction of spinal deformities. A. Preoperative radiograph. B. Postoperative radiograph.	21
Figure 4.2	Trunk topography measurement and reconstruction. (A) Experimental set-up at Sainte-Justine Hospital of four Creaform optical digitizers. (B) Example of a Capturor II LF 3D optical digitizer, consisting of a CCD camera coupled with a structured light projector. (C) Set of four fringe images, each offset by $\frac{1}{4}$ phase, projected by a digitizer onto the back of a mannequin; the fifth image provided the surface texture. (D) Resulting phase image from the four fringe images; surface reconstruction uses the interferometry principle combined with active triangulation. (E) The process of registering and merging the partial surfaces from the different digitizers produces the complete trunk surface.	24
Figure 4.3	Graphical user interface of the system for 3D reconstruction of the bone structures. This view shows the identification of anatomical landmarks on the vertebrae and ribs in the coronal and sagittal radiographs (left and middle), and a simplified 3D reconstruction (right) [1].	25
Figure 4.4	Flow chart of the postoperative trunk shape simulation.	25
Figure 4.5	Graphical user interface of the software tool used to compute the BSR indices from cross-sections at various vertebral levels	31
Figure 4.6	Example of simulation results. (A) Preoperative patient trunk, (B) simulated trunk shape, (C) real postoperative trunk.	31
Figure 4.7	BSR indices (in degrees), measured at different vertebral levels from T4 to T12, for six patients. Blue: actual postoperative trunk, green: simulated trunk, yellow: preoperative trunk. Note that the horizontal scales are not the same on all the graphs.	33
Figure 4.8	Left: Double major curve scoliotic patient (preoperative geometry). Right: BSR indices measured on the actual postoperative trunk, the simulated trunk and the preoperative trunk surface. Blue: actual postoperative trunk, green: simulated trunk, yellow: preoperative trunk.	34

Figure 5.1	Trunk topography measurement and reconstruction. (A) Experimental set-up of four optical digitizers. (B) Example of a Capturor 3D optical digitizer, consisting of a CCD camera coupled with a structured light projector. (C) Set of four fringe images, each offset by $\frac{1}{4}$ phase, projected by a digitizer onto the back of a mannequin. A fifth image provided the surface texture. (D) Resulting phase image from the four fringe images; surface reconstruction uses the interferometry principle combined with active triangulation. (E) The process of registering and merging the partial surfaces from the different digitizers produces the complete trunk surface	44
Figure 5.2	Feature curves (back valley) of the trunk surface. Left: preoperative surface. Right: postoperative surface. The curve top and bottom endpoints A and B correspond to the spinous process of $C7$ and the spinous process of $L5$, respectively. C indicates the curve.	44
Figure 5.3	Anatomical landmarks for the normalization of the dataset. Four landmarks (A_1) PV , (A_2) MPSIS , (A_3) LASIS, and (A_4) RASIS are considered to define a unified coordinate systems. The origin is set at A_2 . The z -axis is perpendicular to the ($A_2A_3A_4$) plane. The y -axis is parallel to ASIS and oriented to the left side of the patient. The x -axis is oriented to the front of the patient.	45
Figure 5.4	Samples of scaled data of the preoperative curve (blue) and postoperative curve (red). The data have been scaled to unit length of the distance between the curve endpoints.	49
Figure 5.5	Comparison of the effect of dimensionality reduction methods on the trunk 3D shape prediction using LS-SVR regression. Summary of prediction errors for different dimensionality reduction methods: Box plots of mean prediction errors. The performances are compared in normalized root mean squared error (NRMS) terms. From left to right, Principal Component Analysis, Kernel Principal Component Analysis, Partial Least Squares, Locality Preserving Projection, and Neighborhood Preserving Embedding.	50
Figure 5.6	Three-dimensional visualization of the curve shape for an example patient. Overlay of the predicted curves on the actual postoperative trunk surface. preoperative (black), actual postoperative (green) and predicted postoperative with PLS-LSSVR (blue).	51

Figure 6.1	Illustration of the intuition behind the modified LMNN metric learning for regression. The point $\mathbf{x}_j$ is referred to as the target neighbor. The point $\mathbf{x}_l$ is referred to as an impostor since it violates the proximity order preservation (in this case). The training consists in finding a learned metric $\delta_{\mathcal{X}}$ such that: (1) the target neighbor is pushed closer to the input query point within a smaller radius after training, (2) impostor is pushed outside the smaller radius domain by a finite margin.	56
Figure 6.2	Left: Overlaid back valley curves (preoperative (blue) and postoperative (red)) on a patient surface mesh. Right: Displacement vector field along the back valley curve from preoperative to postoperative state. .	60
Figure 6.3	Quarter polar plots of the mean pointwise prediction errors distribution along the back valley curve of $N = 141$ scoliotic patients. (a) Red: Learned Mahalanobis metric, (b) Green: Arbitrary Mahalanobis metric, (c) Black: Euclidean metric.	61
Figure 7.1	Représentation du tronc en posture debout. Σ_1 : surface externe. Σ_0 : structures osseuses.	65
Figure 7.2	Diagramme de déformations de formes du tronc. Σ_0 et Σ_1 sont vues comme des structures couplées.	66
Figure 7.3	Régression des champs de déformation de formes du tronc.	66
Figure 7.4	Formes 3D de troncs de trois patients scoliotiques : rangée de haut : données préopératoires, rangée de bas : données postopératoires. La colonne de droite représente les courbes BSR des troncs préopératoire et postopératoire : (i) 1 (bleu) pour le patient de la colonne de gauche, (ii) 2 (rouge) pour le patient de la colonne du milieu, et (iii) 3 (noir) pour le patient de la colonne de droite.	69
Figure 7.5	Comparaison de formes de troncs prédites et réelles : (a) colonne de gauche : surface préopératoire, (b) colonne de milieu : surface réelle postopératoire, (c) colonne de droite : surface postopératoire prédite. .	70
Figure 7.6	Mesure d'erreur de prédiction par la distance point-à-surface entre le tronc postopératoire réelle et le tronc prédit.	70
Figure 7.7	Indice de rotation de la surface du dos mesuré sur le tronc postopératoire réel et sur la surface prédite, pour un patient.	71

LISTE DES SIGLES ET ABRÉVIATIONS

1D	Unidimensionnel
2D	Bidimensionnel
AIS	Adolescent idiopathic scoliosis
ASIS	Anterior superior iliac spine
BMI	Body mass index
BSR	Back surface rotation
C1 ... C7	Première ... septième vertèbre cervicale
LOO	Leave one out
PCA	Principal component analysis
KPCA	Kernel principal component analysis
IRM	Imagerie par résonance magnétique
ISA	Iliac spines axis
L1 ... L5	Première ... cinquième vertèbre lombaire
LAT	Radiographie latérale
LS-SVM	Least squares support vector machine
MPSIS	Midpoint of the posterior superior iliac spines
MRI	Magnetic resonance imaging
PA	Radiographie postéro-antérieure
RMSE	Root mean square error
SIA	Scoliose idiopathique de l'adolescent
SVM	Support vector machine, Machine à vecteurs de support
SVR	Support vector regression, régression par machine à vecteur de support
T1 ... T12	Première ... douzième vertèbre thoracique

CHAPITRE 1

INTRODUCTION

1.1 Mise en contexte

Les tissus mous du corps sont, par essence, déformables. Sous l'effet de pression externe, de changement de posture ou de changement de la configuration d'organes durs environnants, leur forme (apparence) se modifie. La compréhension des mécanismes gouvernant ces changements de formes a été l'objet d'investigation selon plusieurs perspectives: en biomécanique et en graphisme numérique. Combinée avec les techniques d'imagerie médicale modernes permettant la construction 3D de structures anatomiques personnalisées, la modélisation du comportement physique de structures anatomiques du corps a un impact certain dans le domaine médical en particulier parce qu'elle rend possible le développement de systèmes numériques de simulation pour la planification de traitements assistée par ordinateur. On peut citer entre autres les simulateurs de chirurgie maxillofaciale [2] où la prédiction de l'apparence postopératoire du visage est une composante essentielle de la planification de la chirurgie et où l'amélioration de l'esthétique du patient est l'un des objectifs principaux de la chirurgie. La planification de chirurgie assistée par ordinateur présente de nombreux avantages en comparaison à d'autres approches. En effet, lorsqu'un modèle virtuel personnalisé du patient est disponible, plusieurs stratégies de traitements médicaux peuvent être expérimentées pour examiner leurs impacts. Dans la présente thèse, la problématique de la modélisation des tissus mous du tronc humain sera abordée dans le contexte du développement d'un simulateur médical de l'apparence externe du tronc d'un patient scoliotique suite à une chirurgie correctrice de la colonne vertébrale, et qui servira dans les systèmes de planification de traitements chirurgicaux de la scoliose.

La scoliose idiopathique adolescente est une maladie affectant le système musculo-squelettique du tronc, qui entraîne une déformation tridimensionnelle du rachis et de la cage thoracique. Ces déformations peuvent être source de problèmes fonctionnels (respiratoires et cardiaques) si elles sont non traitées. Elles peuvent aussi être la cause de problèmes psychologiques secondaires liés à la modification esthétique du tronc. Elle affecte environ 1 à 3% de la population générale, principalement les adolescentes. Les traitements des déformations scoliotiques sont variés. Dans le cas de courbure sévère de la colonne, une chirurgie est requise comme traitement afin de redresser la colonne vertébrale. Un patient sur mille aura recours à une chirurgie correctrice. La chirurgie procède par l'installation de tiges mé-

talliques attachées à la colonne vertébrale par des vis et crochets. La correction esthétique des déformations externes au niveau du tronc constitue l'un des facteurs les plus importants de succès d'une chirurgie pour le patient. L'hôpital Sainte-Justine de Montréal a réalisé plus de 4000 interventions chirurgicales pendant ces trente dernières années. Disposer d'outils fiables d'aide à la planification chirurgicale est une préoccupation des professionnels de la santé. Les fondements scientifiques pour le développement de tels outils pour le cas de la scoliose méritent d'être établis.

À ce jour, les outils d'assistance de planification de chirurgie de la scoliose sont essentiellement focalisés sur la simulation de la correction de la colonne vertébrale [3, 4], et en particulier l'analyse biomécanique de l'impact de différentes stratégies d'instrumentation métallique sur la réduction de la courbure de la colonne. Toutefois, la question de l'apparence externe postopératoire du tronc n'y est pas abordée. Très peu de travaux de recherche ont été menés concernant la simulation de l'apparence externe postopératoire du tronc, qui constitue pourtant l'une des préoccupations majeures du patient. C'est pour combler ce vide que ce travail de recherche a été entrepris: développer des outils numériques qui complètent les simulateurs d'instrumentation de la colonne déjà existants en fournissant une prédiction de l'apparence externe postopératoire du tronc. Un tel outil présente un intérêt tant pour le chirurgien que pour le patient et permettrait de tenir compte et d'incorporer les attentes du patient quant à son apparence externe dans le processus de planification de traitement chirurgical.

1.2 Organisation de la thèse

La suite de cette thèse comporte sept chapitres et est organisée comme suit. Le chapitre 2 présente une revue de la littérature en relation avec le thème étudié. Dans le chapitre 3, nous décrivons la problématique, les objectifs de la thèse et l'approche générale de la recherche effectuée. Les contributions de cette étude sont rapportées sous forme d'articles scientifiques dans les chapitres subséquents. Le chapitre 4 rapporte un article soumis au journal *Computerized Medical Imaging and Graphics* et décrit une nouvelle méthode de simulation du tronc postopératoire basée sur une approche incrémentale. Dans le chapitre 5, l'article publié dans le journal *Computers in Biology and Medicine* traite de la prédiction statistique de courbes anatomiques de la surface du tronc postopératoire. Dans le chapitre 6, l'article publié dans le journal *IEEE Signal Processing Letters* traite de métriques pour les formes de troncs scoliotiques et plus précisément de l'apprentissage de métrique pour la recherche de troncs proches voisins au sens des formes. Le chapitre 7 expose une méthodologie et des résultats complémentaires concernant la détermination de forme a priori pour la simulation de l'apparence

postopératoire. Une discussion générale de l'ensemble du travail effectué dans cette recherche est proposée au chapitre 8. Enfin la synthèse des contributions de ce travail de recherche et des améliorations futures suggérées sont présentées dans la conclusion.

CHAPITRE 2

REVUE DE LITTÉRATURE

Dans le présent chapitre, nous proposons une revue des connaissances en relation avec le sujet de cette thèse. Nous commençons par un bref rappel d'anatomie du tronc humain (section 2.1) qui facilitera la compréhension de la suite du texte. Après une introduction à la scoliose idiopathique adolescente (section 2.2), la section 2.3 est consacrée à la simulation médicale pour la planification de traitement de la scoliose. La modélisation de tissus mous pour des fins de développement d'un simulateur est abordée dans la section 2.4. La section 2.5 décrit les méthodes d'analyse de formes, et en particulier les techniques d'apprentissage de métriques. Enfin, la section 2.6 présente une synthèse de la littérature.

2.1 Anatomie du tronc humain

Le corps humain est divisé en trois parties: la tête, le tronc et les membres. Le tronc est la partie la plus volumineuse du corps. Il constitue la partie médiane du corps, située entre la tête et les membres inférieurs et supérieurs, et contient plusieurs organes vitaux. Il comprend deux parties: le thorax et l'abdomen. L'intérieur du tronc peut être vu comme une grande cavité fermée, dont la frontière extérieure est constituée par la peau et la frontière interne constituée par la paroi thoracique prolongée par la paroi abdominale. À l'intérieur de cette cavité gisent des organes tels que les poumons, le coeur, le foie, l'estomac et les intestins. Ceux-ci assurent les fonctions respiratoires, vasculaires, et digestives. Les organes internes peuvent être classés en structures molles et structures dures; les derniers sont essentiellement les structures osseuses du tronc. *Tissu mou* est un terme générique pour désigner presque toutes les structures anatomiques qui peuvent être perçues comme *molles* en comparaison aux os, qui eux sont des tissus durs.

2.1.1 Structures osseuses

La charpente osseuse sert à la fois de support du tronc et de protection, comme c'est le cas pour la cage thoracique. Elle est constituée principalement de la colonne vertébrale, la cage thoracique et le bassin. La colonne est un assemblage flexible de vertèbres. Elle s'étend de la base du crâne au bassin. La cage thoracique constitue la structure osseuse du thorax composée de 12 paires de côtes et du sternum, situé dans sa partie centrale antérieure. Les côtes, en forme d'arcs, sont disposées de part et d'autre de la colonne et du sternum.

L'homoplate est un os plat situé dans la partie arrière supérieure du thorax. Les clavicules sont deux os allongés, situées dans la partie supérieure du thorax antérieur, joignant la pointe supérieure du sternum à l'épaule.

2.1.2 Structures molles

La peau. Les tissus à proximité de la surface externe consistent en les différentes couches anatomiquement et microbiologiquement distinctes suivantes: (1) la peau (épiderme formé du *stratum corneum* (couche cornée) et *viable epidermis*), (2) les tissus subcutanés (hypoderme), (3) le fascia, et (4) les muscles.

Topographie de surface du tronc. La forme du tronc est un attribut qui est visuellement perceptible et peut être qualitativement évaluée sur le plan esthétique par rapport à deux plans caractéristiques: le plan frontal et le plan sagittal. La partie arrière d'une coupe selon le plan frontal/coronal, opposé à la direction du regard, est le dos ou partie dorsale du tronc. La topographie du dos est qualitativement caractérisée par l'observation de reliefs rappelant la configuration des os sous-jassant (homoplates), le relief des muscles postérieurs et la vallée du dos. La moitié frontale comporte dans la partie supérieure le torse et la partie inférieure est l'abdomen. La glande mammaire est annexée à la paroi antérieure du thorax. On peut noter quelques différences anatomiques externes entre l'homme et la femme: le tissu mammaire, bien que existant aussi chez l'homme et l'enfant, est toutefois beaucoup plus réduit en comparaison au cas de la femme. La disposition générale des organes est telle que, dans le cas normal et en moyenne, l'apparence externe du tronc présente une certaine symétrie droite/gauche par rapport au plan sagittal. Cette symétrie constitue un élément qualitatif d'esthétique du tronc humain. La symétrie, avec le respect de norme de proportions est souvent rattachée à un critère d'esthétique du tronc. Une pathologie, comme la scoliose, peut entraîner la rupture de cette symétrie.

2.2 La scoliose

Dans cette section, nous présentons quelques caractéristiques générales de la scoliose et les différents types de traitements. Notre attention sera portée particulièrement à la chirurgie puisqu'il s'agit du traitement en relation avec cette thèse.

2.2.1 Déformations scoliotiques

La scoliose est une déformation tridimensionnelle de la colonne vertébrale et de la cage thoracique, se traduisant entre autres par une asymétrie du tronc aux niveaux de la hauteur

des épaules [5], une apparition de proéminence de l'homoplate [5], une asymétrie de hauteur et de taille des seins (pour les filles) [6], une asymétrie des distances entre le bras et le corps en position debout [5], et une asymétrie du bassin [5]. La cause de la scoliose est (le plus souvent 70 à 80% des cas) inconnue: on parle alors de scoliose idiopathique. De nombreuses équipes de recherche oeuvrent à en découvrir la cause [7] pouvant être attribuée soit à une origine génétique, hormonale, neuro-musculaire, ou biomécanique. Celle-ci survient le plus souvent à l'adolescence. On parle alors de scoliose idiopathique de l'adolescence [8]. Son incidence est évaluée à environ 4% dans la population adolescente [8].

Une évaluation radiologique est communément utilisée pour la confirmation de diagnostic de la scoliose. Un des indices clés dans ce contexte est l'angle de Cobb. Il caractérise la courbure de la colonne vertébrale. L'angle de Cobb est défini comme l'angle formé par la tangente au plateau supérieur de la vertèbre supérieure la plus déviée et la tangente au plateau inférieur de la vertèbre limite inférieure la plus déviée [9]. Il est mesuré sur la radiographie frontale (ou la radiographie latérale) du patient.

2.2.2 Traitement de la scoliose: la chirurgie

Le traitement de la scoliose dépend pour l'essentiel du degré de sévérité de la courbure de la colonne vertébrale, de la maturité physiologique du patient, et du risque de progression. Ainsi, pour les faibles ou moyennes courbures, c'est à dire, un angle de Cobb inférieur à 40° , un traitement par corset est généralement prescrit [10]. Pour les courbures plus sévères (angle de Cobb supérieur à 45° ou 50°) et progressives, un traitement par chirurgie est souvent recommandé. La chirurgie correctrice de la colonne consiste en l'installation d'une instrumentation formée de tiges métalliques ancrées sur les vertèbres au moyen de vis et de crochets dans le but de redresser le rachis. Du point de vue du chirurgien, l'issue d'une opération est principalement évaluée au regard de la réduction de la courbure après traitement, à court et à long terme. Les importantes avancées réalisées en techniques chirurgicales et en conception d'instrumentation durant cette dernière décennie ont permis d'obtenir des réductions de l'angle de Cobb après chirurgie (réduction de la courbure initiale dans le plan frontal) atteignant en moyenne 60 à 70% [11]. Aussi, des études cliniques [12, 13] ont documenté une rectification tridimensionnelle (3D) adéquate de la colonne. Néanmoins, cette amélioration de la courbure de la colonne n'implique pas nécessairement une amélioration optimale de l'apparence externe du tronc des patients. La réduction des asymétries et de la gibbosité suite à la chirurgie est plus modeste 20 à 40% [14, 15] en comparaison à l'angle de Cobb [13, 16]. Une explication possible de cette différence est le fait que l'instrumentation métallique de la chirurgie agit directement sur la colonne vertébrale tandis que la cage thoracique, responsable de l'apparition de la gibbosité, n'est que secondairement influencée par

l'instrumentation [13].

Une méta-analyse de la littérature a documenté que la correction de l'apparence externe est le facteur majeur de la satisfaction des patients ayant subis une chirurgie [17]. L'attente principale est alors une correction des asymétries et de la gibbosité. Suivant l'issue de la correction sur l'apparence externe, le chirurgien peut décider, en plus de l'instrumentation postérieure standard et de la fusion de la colonne, de réaliser un relâchement antérieur de la colonne par une ou plusieurs dissectomies et/ou des procédures de thoracoplastie, en vue d'obtenir un gain supplémentaire en correction de la forme du tronc. La thoracoplastie consiste en la résection de différentes longueurs de quelques côtes. Avec ces procédures additionnelles, une correction du tronc (apparence externe) de l'ordre de 70% peut être atteinte [18], mais des risques de problèmes respiratoires peuvent en découler. Présentement les indications pour de telles procédures demeurent mal définies [19] et la décision de réaliser ces procédures additionnelles est prise empiriquement par le chirurgien basé sur son expérience.

2.3 Simulation médicale pour la planification de chirurgie

Le développement d'outils de simulation pour la planification de traitements médicaux est une pratique établie dans la communauté scientifique. La méthode des éléments finis est communément utilisée en ingénierie mécanique pour des calculs de haute précision en structures. Elle a été utilisée pour la modélisation et la simulation biomécanique du système musculo-squelettique du tronc et de différents effets de traitements sur la structure osseuse. Le développement d'outils de simulation pour la conception d'instrumentation et la planification de traitement de la scoliose a été l'objet de différentes recherches à travers le monde.

Des modèles biomécaniques de la structure du rachis ont été proposés, en particulier par Aubin et al.[20, 4] et permettent de simuler de manière satisfaisante les déformations et les corrections chirurgicales de la colonne ainsi que la planification de l'instrumentation chirurgicale [3, 4] avec des résultats prévisibles et fiables. Les études importantes réalisées à ce jour portent pour l'essentiel sur l'effet sur la colonne [3, 4], la modélisation des tissus mous vis-à-vis de l'effet du corset sur la structure osseuse [21], la modélisation et simulation de la costoplastie [22].

Dans [22], un modèle biomécanique a été développé pour l'évaluation de la correction à long terme résultant du raccourcissement ou du (r)allongement de côtes dans le cas de la scoliose idiopathique adolescente. La costoplastie fût simulée en utilisant un modèle éléments finis du tronc, personnalisé à la géométrie d'un patient. Le modèle prenait en compte la relaxation des contraintes des ligaments à la suite de la chirurgie, la croissance longitudinale des corps vertébraux et côtes et leur modulation due aux contraintes mécaniques. Les résultats

indiquent le potentiel de la correction à long terme de la courbure de la colonne résultant du raccourcissement de la côte sur la concavité. L'effet sur l'apparence externe du tronc du patient n'a pas été considéré dans cette étude.

Dans [21], un outil pour la simulation et la conception de traitement de la scoliose par corset, utilisant un modèle d'éléments finis d'un corset et de son interface avec le torse, fût développé. Ce modèle fût adapté pour représenter une fille adolescente scoliotique traitée avec le corset de Boston. Le modèle inclut les structures osséo-ligamentaires, les tissus mous thoraciques et abdominaux, coussinet et coque, et l'interface corset-torse. Cette étude a pu démontrer sa capacité à représenter de manière plus réaliste le transfert de charge du corset vers la colonne au travers des différents tissus intermédiaires. Toutefois la prédiction de l'apparence externe du tronc n'a pas été abordée. Les travaux récents de Clin et al. [23, 24, 25, 26, 27] ont également porté sur divers types de corsets. Une série d'études de l'influence biomécanique et des effets correctifs de corsets sur la colonne (ou structure osseuse) ont ainsi été réalisées.

Dans [28], un modèle biomécanique du tronc humain a été élaboré pour modéliser et simuler les tests d'inflexion latérale du tronc. Ces tests sont le plus souvent utilisés dans l'évaluation préopératoire des patients scoliotiques afin de caractériser les courbures rachidiennes, évaluer leur flexibilité et leur potentiel de correction. Ce modèle biomécanique incluait les composantes osséo-ligamentaires de la colonne vertébrale, de la cage thoracique et du bassin ainsi que 160 faisceaux musculaires représentés par des éléments câbles bilinéaires. Il fut possible aux auteurs de représenter la modification de l'angle de Cobb thoracique (à moins de 2 degrés), les projections des rotations vertébrales dans le plan frontal (à plus de 85%), de même que les positions des centroides des corps vertébraux (adéquation supérieure à 77%).

Les études ci-dessus mentionnées n'ont porté, pour l'essentiel, que sur les effets de correction sur la structure osseuse et n'abordent pas la prédiction de l'apparence de la surface externe postopératoire du tronc du patient. Les tissus mous ont été considérés dans l'optique des effets sur la structure osseuse et non sur l'apparence externe postopératoire (ou post-traitement). Il existe à ce jour très peu de travaux de modélisation de tissus mous du tronc pour la prédiction de l'apparence externe du tronc suite à une chirurgie de la scoliose. À notre connaissance, seul le laboratoire Liv4D de l'École Polytechnique de Montréal conjointement avec le centre de recherche de l'Hôpital Sainte-Justine de Montréal aborde cette problématique [29]. Dans la suite, nous présentons les modèles usuels de tissus mous.

2.4 Modélisation des tissus mous

Les modèles d'objets déformables basés sur la physique sont utilisés depuis le début des années 80 dans l'industrie du jeu vidéo et aussi dans les applications biomédicales particulièrement pour la simulation et la planification de stratégies chirurgicales [30]. Pour ces dernières applications tant le réalisme visuel que la précision physique sont souvent recherchés. Les deux approches les plus populaires pour la modélisation physique des tissus mous du corps humain sont les modèles d'élasticité de la mécanique de milieu continu (généralement résolus par les méthode des éléments finis (FEM) [31, 32]) et les modèles dits de système masse-ressort (MSS) [33, 34, 35].

Les méthodes d'éléments finis sont communément utilisés en ingénierie mécanique pour des calculs de haute précision en structures. Elles sont toutefois exigeantes en ressources de calculs; ce qui constitue une limitation pour des applications interactives. Des variantes de modèles inspirés de méthodes FEM pour l'élasticité des tissus du corps humain ont été introduits pour résoudre les préoccupations de rapidité de calculs [36, 37, 38]. Toutefois, la plupart sont applicables à des déformations linéaires valables pour les petits déplacements et exigent un pré-calcul de la matrice du système qui écarte la possibilité d'y traiter les cas de domaines subissant des changements topologiques. Piccibono *et al.* [39] ont apporté des améliorations pour considérer les grandes déformations pour des simulations en temps réel. Toutefois, le coût de calcul étant croissant avec la taille des matrices mises en jeu, les critères d'interactivité sont limités aux calculs sur des domaines avec un faible nombre d'éléments. Ces approches ont été principalement appliquées à la simulation de chirurgie plastique et maxillo-faciale [31, 40, 2] ainsi que pour la chirurgie reconstructive du sein [41].

Le modèle MSS, comme le nom l'indique, consiste en un système de masses interagissant via des ressorts. Ces modèles ont été appliqués entre autres par Terzopoulos et Waters [33] en animation faciale où l'épiderme, le derme, le tissu sub-cutané sont représentés par des couches de réseau de ressorts. Dans leur simulation de chirurgie plastique faciale, Koch *et al.* [31] ont utilisé un modèle de la face consistant en une surface continue reliée au crâne par des ressorts. La surface est traitée dans un cadre d'élasticité résolu par éléments finis. Bien que le modèle masse-ressort ne soit qu'une approximation du comportement biomécanique, il présente néanmoins des avantages en temps de calcul et en simplicité de mise en oeuvre en comparaison avec l'approche par éléments finis de l'élasticité classique qui est plus précise mais a l'inconvénient d'être coûteuse en ressources de calculs. Cependant, la spécification des paramètres du système pour un MSS (constantes de ressorts, la topologie du maillage) constitue l'une des limitations principales de cette approche. Un modèle de tenseur de masse en étude statique ou quasi-statique des tissus mous fut proposé pour la planification de

chirurgie maxillo-faciale [2]. Ce modèle réunit certaines qualités de simplicité d'un modèle masse-ressort et les qualités de précision des modèles biomécaniques par éléments finis.

La question de l'estimation de paramètres de modèle physique déformable est un problème important. L'identification de paramètres par résolution de problèmes inverses en utilisant des données de mesures de déformations du corps étudié soumis à différentes contraintes contrôlées a fait l'objet d'études de différents chercheurs [42, 43, 44, 45, 46]. Généralement dans le contexte d'études biomécaniques, les valeurs utilisées pour les simulations sont des coefficients d'élasticité mesurés sur des spécimens cadavériques étant donné que des mesures *in vivo* sont difficiles à réaliser. Mais ces données ne sont pas appropriées dans le cas de simulations personnalisées.

2.5 Analyse de formes et anatomie numérique

L'analyse de formes joue un rôle très important dans la compréhension de la variabilité anatomique à partir d'images médicales et trouve des applications en reconnaissance de formes, en analyse d'images médicales, en segmentation d'images. Les bases de la science des formes ont été énoncées il y a près d'un siècle par D'Arcy Thompson, naturaliste et mathématicien écossais en 1917 dans son ouvrage '*Growth and Forms*' [47] et l'idée principale est d'utiliser des transformations géométriques sur les formes comme outils mathématiques pour leur comparaison. La statistique des formes est nécessaire aux applications allant du diagnostic de pathologies, à la planification de traitements, et la quantification des effets induits par des pathologies. La modélisation de la variabilité de formes anatomiques et leurs comparaisons quantitatives afin de tirer profit du maximum d'information fournie par les techniques modernes 2D, 3D ou 4D d'imagerie médicale constitue l'un des objectifs de l'anatomie numérique ('*computational anatomy*') [48].

Un problème central en analyse de formes est l'évaluation de combien une forme est différente d'une autre autrement dit la mesure de similarité (ou de dissimilarité). L'étude quantitative de formes commence généralement par la formulation d'un espace de formes. La définition d'une métrique sur cet espace fournit une mesure de similarité de forme entre deux objets quelconques. Lorsque l'espace de formes a une structure de variété riemannienne, la distance est donnée par les géodésiques minimales entre deux formes. Parmi les mesures de similarité les plus courantes, on peut citer par exemple la métrique de Hausdorff (Huttenlocher et al., 1993)[49]. Bien qu'intéressante pour plusieurs applications [50, 51], cette métrique possède l'inconvénient d'être très sensible aux valeurs aberrantes sur les formes comparées.

Les premières formulations d'espace de formes et l'utilisation de métriques pour définir les statistiques de formes furent développées dans les travaux pionniers de Kendall [52] et

Bookstein [53]. Une approche importante est de représenter une forme par un ensemble de points-repère caractéristiques (*landmarks*) sur sa frontière et de décrire les variations de forme en utilisant la matrice de covariance pour les coordonnées cartésiennes des points caractéristiques. Toutefois, pour certains types de formes, l'information directionnelle (telle que par exemple le champ des normales aux surfaces) [54, 55] est plus convenable pour la représentation de forme par rapport aux points cartésiens. Ce fut Rao (C.R.Rao, 1945) [56] qui le premier établit que la matrice d'information de Fischer satisfait les propriétés d'une métrique sur une variété riemannienne. La métrique de Fisher-Rao est une métrique sur des densités de probabilité développée dans un cadre de géométrie de l'information (Peter-Rangarajan, 2006a, Peter-Rangarajan, 2006a) [57, 58]. Elle est utilisée selon une approche où les formes sont représentées par des fonctions de densité de probabilité et où toute l'analyse subséquente est transposée dans la variété riemannienne des densités. Ceolin et Hancock ([59, 54]) ont utilisé la métrique de Fisher-Rao pour le calcul de similarité de visage humain.

Le développement de l'anatomie numérique, basée sur les idées initiales de D'Arcy, a connu une révolution depuis les années 1998 [48] avec le développement des technologies 3D et depuis, divers modèles de formes ont été proposés. Vaillant et Glaunès [60, 61, 62] ont introduit dans les années 2004-2005 un cadre théorique de l'espace des courants pour les formes qui permet de traiter de manière efficace les problèmes de mise en correspondance (avec ou sans points-repère) de formes et de mesurer des distances entre formes. La mesure de similarité associée à ces espaces est robuste et géométriquement intuitive. Les récents travaux de Durrleman *et al.* [63] constituent des applications des courants comme nouvelle approche d'étude statistique de variabilité de formes anatomiques.

2.5.1 Approches statistiques de prédiction de formes

Les techniques d'apprentissage machine pour la prédiction, en particulier les machines à vecteurs de support (SVM), ont été de plus en plus utilisées (et avec succès) pour des problèmes en biologie et médecine [64, 65]. Dans le cas spécifique de la scoliose, une question abordée par différents groupes, au cours de ces dernières années, concerne la détermination de la relation entre la topographie de surface et la configuration de la colonne vertébrale. Bergeron *et al.* [66] ont étudié la corrélation entre la topographie de la surface et la courbe de la colonne, en utilisant la régression par machine à vecteurs de support. Jaremko *et al.* [67] ont utilisé les approches par réseaux de neurones pour étudier et estimer par prédiction l'angle de Cobb à partir de mesures d'indices d'asymétrie de la surface externe du tronc. Ramirez *et al.* [68] ont utilisé une machine à vecteurs support pour évaluer la sévérité des déformations de la colonne vertébrale à partir de données de la surface externe du tronc. Les travaux récents de Séoud *et al.* [69] ont porté sur la prédiction de la courbure de la colonne basée

sur une analyse de la topographie de surface, en utilisant la technique de machine à vecteurs support. Bien que ces travaux trouvent des applications dans le suivi et le diagnostic de patients scoliotiques, ils sont essentiellement limités aux troncs en préopératoire. Ces études n'abordent pas la question de la corrélation entre les formes préopératoire et postopératoire pour un patient donné.

2.5.2 Méthodes proches-voisins pour la régression

La régression par proche voisin est l'une des méthodes d'apprentissage machine les plus simples consistant à attribuer à un nouveau point (requête) l'étiquette du point le plus proche dans une base de données [70, 71, 72, 73, 74]. Le principe général de la méthode de régression par proche voisin peut être décrit comme suit. Soit $\mathcal{X}$ et $\mathcal{Y}$ deux espaces métriques. Soit $D_n = \{z_i = (\mathbf{x}_i, y_i) : \mathbf{x}_i \in \mathcal{X}, y_i \in \mathcal{Y}, i = 1, \dots, n\}$ un ensemble de données. Étant donné un nouveau point $\mathbf{x} \in \mathcal{X}$, l'estimation de la réponse $\tilde{y} \in \mathcal{Y}$ par la régression par proche voisin est donné par

$$\tilde{y} = y_{k:\mathbf{x}_k = NN_{d_{\mathcal{X}}}(\mathbf{x})}, \quad (2.1)$$

où $NN_{d_{\mathcal{X}}}(\mathbf{x})$ désigne le plus proche voisin $\mathbf{x}$ dans $D_n^{\mathcal{X}} = \{\mathbf{x}_i : (\mathbf{x}_i, y_i) \in D_n, i = 1, \dots, n\}$ par rapport à la distance $d_{\mathcal{X}}$ définie sur $\mathcal{X}$.

L'un des ingrédients importants dans les techniques par proche voisin est la détermination de la fonction distance dans l'espace d'intérêt, et cela dépend du domaine d'application.

2.5.3 Apprentissage de métriques

Une application $d : \mathcal{X} \times \mathcal{X} \rightarrow R_0^+$ sur un espace vectoriel $\mathcal{X}$ est appelée une métrique si pour tout vecteur $\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_k \in \mathcal{X}$, elle satisfait les propriétés:

1. $d(\mathbf{x}_i, \mathbf{x}_j) + d(\mathbf{x}_j, \mathbf{x}_k) \geq d(\mathbf{x}_i, \mathbf{x}_k)$ inégalité triangulaire
2. $d(\mathbf{x}_i, \mathbf{x}_j) \geq 0$ non-négativité
3. $d(\mathbf{x}_i, \mathbf{x}_j) = d(\mathbf{x}_j, \mathbf{x}_i)$ symétrie
4. $d(\mathbf{x}_i, \mathbf{x}_j) = 0 \iff \mathbf{x}_i = \mathbf{x}_j$ distinguabilité.

Une application satisfaisant les trois premières propriétés mais pas la dernière est appelée pseudométrique. Une façon courante d'obtenir une famille de métriques sur $\mathcal{X}$ est de considérer la distance euclidienne après la transformation linéaire $\mathbf{x}' = \mathbf{L}\mathbf{x}$. Ces métriques calculent les carrés de distances comme:

$$d_{\mathbf{L}}(\mathbf{x}_i, \mathbf{x}_j) = \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|_2^2, \quad (2.2)$$

ou la transformation linéaire dans Eq.(2.2) est paramétrée par la matrice $\mathbf{L}$. Par ailleurs, il est souvent approprié (ou commun) d'exprimer le carré de distance dans Eq.(2.2) en utilisant la matrice carrée

$$\mathbf{M} = \mathbf{L}^T \mathbf{L}.$$

Les carrées de distances deviennent alors

$$d_{\mathbf{M}}(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i - \mathbf{x}_j)^T \mathbf{M} (\mathbf{x}_i - \mathbf{x}_j).$$

Les pseudo-métriques de cette forme sont appelées métriques de Mahalanobis.

Le problème de l'apprentissage de métriques concerne l'apprentissage machine d'une fonction distance relativement à une tâche particulière. Il a été montré que l'apprentissage de métrique est très utile lorsque combiné avec des méthodes de proches voisins et d'autres techniques dépendant de distances ou (mesures) de similarité. Différentes métriques à apprendre ont été considérées par différents auteurs dans la littérature. Mais la distance de Mahalanobis demeure de loin la plus utilisée en pratique, et la plus étudiée.

La méthode dite Large Margin Nearest Neighbors (LMNN) introduite par Weinberger et al. [75, 76, 77] est l'une des plus largement utilisées comme méthode d'apprentissage de métrique de Mahalanobis et a connu diverses extensions, dont la χ^2 -LMNN (où la distance d'histogramme χ^2 est utilisée au lieu de la distance de Mahalanobis). D'autres méthodes d'apprentissage de métriques ont également été proposées auparavant telles que la méthode Adaptive metric nearest neighbor (ADAMENN) [78] et la méthode Discriminant adaptive nearest neighbor (DANN) [79]. Ces méthodes présentent toutefois le désavantage de recourir à plus d'un paramètre à fixer. Toutes ces méthodes d'apprentissage ont été conçues uniquement pour des problèmes de classification par proche voisin, et n'abordent nullement le problème de la prédiction par régression par proche voisin.

2.6 Synthèse de la revue de littérature

Pour résumer, la revue de littérature met en évidence qu'il existe différentes techniques et modèles du tronc pour la simulation de traitement de chirurgie. Toutefois, la région d'intérêt pour ces différents modèles est la structure osseuse, et pour l'essentiel, seule la simulation de la correction de la structure osseuse est considérée. Il est à noter que, toutefois, l'apparence externe est aussi un aspect important de l'issue d'une chirurgie de la scoliose. Cependant, très peu de travaux ont porté sur la simulation de l'apparence du tronc dans le contexte de la chirurgie de la scoliose. La simulation de l'apparence externe du tronc passe par une modélisation des tissus mous. La littérature révèle que les modèles FEM et MSS ont été

utilisés pour une problématique connexe: la simulation de l'apparence postopératoire du visage en chirurgie maxillo-faciale. Contrairement aux méthodes non physiques, les modèles FEM offrent l'avantage du réalisme de la simulation, mais d'autre part possèdent une grande complexité de calcul. L'enjeu principal actuellement est de définir un modèle adéquat de tissus mous pour le tronc (et sa déformation en vue de la simulation d'apparence) ayant à la fois l'avantage de la simplicité de la modélisation mais aussi l'avantage du réalisme de la simulation. Il s'agira par la suite de propager les corrections sur la structure osseuse vers la surface externe via les tissus mous du tronc occupant la région séparant les os et la peau. D'autre part, la simulation d'un tronc personnalisé nécessite les valeurs de paramètres physiques spécifiques au patient considéré. La plupart des simulations physiques pour la simulation médicale se basent sur les paramètres d'élasticité mesurés ex-vivo puisque les mesures in-vivo sont difficiles à obtenir. Cependant, dans notre cas, il serait avantageux de disposer d'informations complémentaires permettant de contourner cette difficulté en tenant compte de base de données de patients scoliotiques.

CHAPITRE 3

MÉTHODOLOGIE GÉNÉRALE

L'utilisation d'outils d'assistance par ordinateur pour la planification de traitements médicaux est un domaine de recherche actif dont les retombées seront certainement bénéfiques à la pratique courante en médecine, en particulier pour la planification de chirurgies en préopératoire. Il ressort de la revue de la littérature présentée au chapitre précédent que pendant ces dix à vingt dernières années, de nombreux travaux ont porté sur la modélisation de la colonne vertébrale et la simulation de sa correction dans le cadre de chirurgie pour la scoliose. Cependant, bien que l'apparence esthétique du tronc du patient scoliotique soit l'une de ses préoccupations majeures à l'issue d'une chirurgie, toutes les études ci-dessus mentionnées n'abordent pas la simulation de l'apparence externe postopératoire du tronc. Dans un processus typique de planification de chirurgie (prenant en considération l'apparence externe), le clinicien disposerait idéalement d'un outil logiciel lui permettant de simuler le changement de forme de la surface externe du tronc induit par la fixation de l'instrumentation sur la colonne vertébrale. La question de la modélisation du tronc humain, en particulier la déformation de ses tissus mous, entrant dans le développement d'un tel outil d'assistance à la planification chirurgicale, découle de ce contexte.

3.1 Formulation du problème

Afin de formuler clairement l'objectif global de recherche, nous introduisons d'abord le contexte technique du problème abordé. Considérons le tronc humain comme un domaine fermé formé de deux sous-domaines, les tissus mous (milieu déformable) connecté à la structure osseuse. Le passage de la forme du tronc dans l'état préopératoire à sa forme dans l'état postopératoire peut être vu de la façon suivante. L'installation de l'instrumentation métallique sur la colonne vertébrale produit un certain changement de la configuration de la structure osseuse de l'état préopératoire à l'état postopératoire. Ce changement de configuration se répercute sur les tissus mous environnants, et se propage de proche en proche jusqu'à la surface externe. Il en résulte une variation de la forme de la surface externe. On s'intéressera à la forme du tronc dans la posture debout. Cette thèse aborde la question générale suivante: *Étant donné la géométrie externe du tronc en posture debout et la configuration osseuse d'un patient scoliotique en préopératoire, et une configuration osseuse postopératoire cible, simuler la géométrie externe du tronc en postopératoire.*

3.2 Question de recherche

La question principale pour cette recherche concerne le développement de méthodes pour la prédiction de la forme postopératoire du tronc de patients scoliotiques en chirurgie correctrice de la colonne vertébrale qui permettraient la mise en oeuvre d'outils de planification de chirurgie. Celle-ci découle de la mise en contexte technique décrite dans la Section 3.1.

Question: *Comment modéliser le tronc humain, en particulier ses tissus mous, de sorte à pouvoir simuler l'apparence externe postopératoire du tronc de patients scoliotiques, suite à une chirurgie correctrice de la colonne vertébrale?* ■

L'unique simulation du tronc postopératoire connue au moment où cette thèse a démarré, et à laquelle nous avons contribué (Dionne, Assi *et al.*, 2012), présente certaines limitations quant à la prise en compte de grandes déformations. Une nouvelle méthode (Chapitre 4)(Assi *et al.*, 2013) viendra répondre à cette limitation.

3.3 Objectifs de recherche

L'objectif principal de recherche découle de la question de recherche précédente: Développer des outils pour la simulation de l'apparence externe postopératoire de troncs de patients scoliotiques suite à une chirurgie pour la scoliose. Cet objectif principal sera atteint en réalisant les objectifs spécifiques suivants.

3.3.1 Modéliser les déformations de tissus mous

Objectif 1: *Modéliser les grandes déformations du tronc humain de l'état préopératoire à l'état postopératoire afin de simuler l'apparence postopératoire.* ■

Jusqu'à ces dernières années, la modélisation du tronc scoliotique pour la simulation de chirurgie a été essentiellement confiné aux aspects de l'instrumentation et de la correction de la colonne vertébrale. Pour simuler l'apparence externe du tronc postopératoire, une nouvelle approche pour les grandes déformations sera développée (Chapitre 4)(Assi *et al.*, 2013).

3.3.2 Prédire les courbes anatomiques du tronc

Une surface peut être représentée et reconstruite à partir d'une collection finie de courbes. Ramener la représentation de la surface à un ensemble de courbes en réduit la complexité. On peut remarquer en observant l'anatomie du tronc humain que certaines courbes anatomiques se dessinent naturellement sur la surface externe du tronc. Celles-ci sont souvent directement discernables sans appareillage spécial. L'ensemble de ces courbes capture grossièrement la

forme du tronc et peut servir à en contrôler la prédiction. Cette observation nous amène à penser qu’une connaissance a priori de certaines courbes anatomiques du tronc (comme la vallée du dos) permettrait la prédiction de l’apparence externe postopératoire du tronc scoliotique. Ce qui nous amène à formuler notre deuxième objectif de recherche comme suit.

Objectif 2: *Développer un modèle statistique des courbes anatomiques du tronc humain scoliotique afin de prédire leur forme dans l’état postopératoire.* ■

Les courbes anatomiques du tronc scoliotique, et en particulier la courbe associée à la vallée du dos, peuvent être statistiquement prédites à partir d’une base de données de formes de troncs de patients ayant subi une chirurgie correctrice de la colonne vertébrale (Chapitre 5)(Assi *et al.*, 2014). Le développement de la première approche statistique prédictive des courbes anatomiques de troncs postopératoires (Chapitre 5)(Assi *et al.*, 2014) devrait permettre la prédiction statistique de la surface toute entière.

3.3.3 Proposer une distance dans l’espace des formes de troncs

La prédiction de l’apparence postopératoire de troncs peut être aussi vue selon une perspective d’analyse de forme. Afin d’exploiter l’information implicite contenue dans une base de données, il y a un intérêt à introduire une métrique dans l’espace de formes de troncs scoliotiques qui capture l’intuition selon laquelle deux troncs considérés proches voisins subissent également des déformations similaires. La formulation rigoureuse du concept de *proche voisin scoliotique* est l’objet de notre troisième objectif de recherche.

Objectif 3: *Proposer une distance dans l’espace des formes de troncs scoliotiques afin d’appliquer des méthodes par proche voisin pour la prédiction de champs de déformations.* ■

L’efficacité des méthodes par proches voisins dépend, en grande partie, du choix de la métrique définissant le voisinage dans l’espace d’intérêt. Il est souvent difficile de construire une distance pour des espaces complexes. Une manière de contourner cette difficulté consiste à recourir à l’apprentissage machine. Une nouvelle approche d’apprentissage machine de métriques sera proposée pour l’espace de troncs scoliotiques (Chapitre 6)(Assi *et al.*, 2014). Le concept de proche voisin scoliotique sera utile, entre autres, pour la prédiction de forme utilisant la régression par proche voisin sur l’espace des déformations du tronc (Chapitre 7).

3.3.4 Prédire les déformations par une approche proche voisin

Objectif 4: *Prédire par régression proche voisin les formes de troncs postopératoires.* ■

La prédiction de forme postopératoire par l'approche physique dépend de la configuration osseuse interne cible choisie. Celle-ci est sensée être fournie par un simulateur de l'instrumentation de la colonne vertébrale. Ceci peut constituer une limitation si la configuration osseuse cible n'est pas disponible. Il est proposé une nouvelle approche fournissant une approximation de la configuration osseuse cible pour la prédiction de forme postopératoire (Chapitre 7).

3.4 Approche générale

Des méthodes pour la simulation (et la prédiction) de forme de troncs postopératoires de patients scoliotiques ont été développées. L'objectif principal de recherche a été atteint par la réalisation des objectifs spécifiques. Les détails des nouvelles méthodes proposées sont exposés aux chapitres 4, 5, 6 et 7. Nous en résumons ici les grandes lignes.

3.4.1 Modélisation de la déformation de tissus mous par une méthode incrémentale

Le premier objectif a abordé la modélisation de la déformation du tronc dans un contexte de larges déformations. Un modèle physique est défini pour simuler le changement de forme du tronc de l'état préopératoire à l'état postopératoire. La méthode proposée consiste en une approche incrémentale constituée d'une séquence de petites déformations entre l'état préopératoire et l'état postopératoire (Chapitre 4)(Assi *et al.*, 2013). Cette nouvelle méthode a été évaluée sur des données médicales de patients scoliotiques. Les surfaces obtenues par la simulation sont qualitativement comparées aux surfaces réelles par inspection visuelle. L'évaluation quantitative de la précision de la simulation est effectuée en considérant la différence d'angle BSR mesurée sur les sections horizontales du tronc postopératoire réel et du tronc postopératoire simulé.

3.4.2 Prédiction de courbes anatomiques du tronc

Le deuxième objectif a abordé l'utilisation de l'information implicitement contenue dans la base de données de formes de troncs scoliotiques (préopératoire et postopératoire). A cet effet, certaines courbes anatomiques de la surface du dos du tronc postopératoire sont prédites en utilisant une méthode statistique. Une machine à vecteurs de support est utilisée en combinaison avec des méthodes de réduction de dimensionalité (Chapitre 5)(Assi *et al.*, 2014). Différentes méthodes de réduction de dimensionalité sont explorées en combinaison avec la machine à vecteurs de support (Chapitre 5)(Assi *et al.*, 2014) afin d'en étudier l'impact sur la précision de la prédiction. Cette étude statistique est conduite sur un ensemble de données de

141 patients scoliotiques (préopératoires et postopératoires). La précision de la prédiction est calculée en considérant l'erreur ponctuelle sur les courbes prédites. L'évaluation quantitative de la performance de la méthode est effectuée par la procédure de validation croisée *leave-one-out*.

3.4.3 Apprentissage de métrique de distance

Le troisième objectif aborde l'élaboration et l'étude d'un concept de *proche voisin scoliotique* approprié pour la prédiction de forme de troncs postopératoire par proche voisin. Nous proposons une métrique obtenue par apprentissage (Chapitre 5)(Assi *et al.*, 2014) pour l'espace de formes de troncs. Une fois la distance définie, elle est évaluée dans un contexte d'expérience numérique de détermination de proche voisin scoliotique (Chapitre 5)(Assi *et al.*, 2014) afin d'en vérifier la fiabilité en utilisant la procédure de validation croisée *leave-one-out*.

3.4.4 Prédiction de forme utilisant la régression par proche voisin

Le quatrième objectif a abordé une application naturelle du concept de proche voisin dans l'espace de formes de troncs scoliotiques, en l'occurrence la prédiction de déformations du tronc utilisant la régression par proche voisin. Pour un nouveau patient donné, le champ de déformation est d'abord prédit par proche voisin. Ce champ de déformation associé aux troncs scoliotiques est ensuite appliqué au tronc préopératoire du nouveau patient pour prédire la forme du tronc postopératoire (Chapitre 7). Cette approche se base sur le fait que la restriction du champ de déformation élastique des tissus mous à la surface externe du tronc peut servir pour produire un estimé de la forme postopératoire (Chapitre 7).

3.5 Diagramme récapitulatif de la méthodologie et des contributions

La figure Fig.3.1 résume la méthodologie générale de cette thèse sous forme d'un diagramme où les articles soumis, acceptés et/ou publiés en rapport avec ce travail sont également indiqués.




Figure 3.1 Diagramme récapitulatif de la méthodologie générale.

CHAPITRE 4

ARTICLE 1: A PHYSICALLY BASED TRUNK SOFT TISSUE MODELING FOR SCOLIOSIS SURGERY PLANNING SYSTEMS

K. C. Assi^{1,2}, S. Grenier^{1,2}, S. Parent², H. Labelle², and F. Cheriet^{1,2}

(1) *École Polytechnique de Montréal, P.O. Box 6097, Succursale Centre-ville,
Montréal, Québec, Canada H3C 3A7*

(2) *Sainte-Justine Hospital Research Center, 3175 Côte-Sainte-Catherine,
Montréal, Québec, Canada H3T 1C5*

4.1 Abstract

One of the major concerns of scoliotic patients undergoing spinal correction surgery is the trunk's external appearance after the surgery. This paper presents a novel incremental approach for simulating postoperative trunk shape in scoliosis surgery. Preoperative and postoperative trunk shapes data were obtained using three-dimensional medical imaging techniques for seven patients with adolescent idiopathic scoliosis. Results of qualitative and quantitative evaluations, based on the comparison of the simulated and actual postoperative trunk surfaces, showed an adequate accuracy of the method. Our approach provides a candidate simulation tool to be used in a clinical environment for the surgery planning process.

4.2 Introduction

Adolescent idiopathic scoliosis (AIS) is a complex three-dimensional deformation of the trunk. In severe cases, a spine surgery treatment is required. Most of the surgical procedures use specialized instrumentation attached to the spine to correct the deformities (Fig. 4.1). One




Figure 4.1 Surgical instrumentation of a scoliotic spine for the correction of spinal deformities. A. Preoperative radiograph. B. Postoperative radiograph.

of the concerns of the patient (and, in fact, a major factor of satisfaction) is the trunk's appearance after the surgery. In addition to the surgeon's priorities in the surgery planning process, a tool for simulating the trunk's postoperative appearance is of importance to take into account the patient's concerns in the treatment planning.

Aubin *et al.* [4] have developed a spinal surgery simulation system in the context of the optimal planning of surgical procedures to correct scoliotic deformities. The overall goal of this biomechanical engineering research project is to develop a user-oriented simulator for virtual prototyping of spinal deformities surgeries: a fully operational, safe and reliable patient-specific tool that will permit advanced planning of surgery with predictable outcomes, and rationalized design of surgical instrumentation [3, 4]. It addresses the problems faced by orthopedic surgeons treating spinal deformities when making surgical planning decisions. The developed system is, however, only concerned with the configuration of the spine, and does not furnish any estimate of the effects of the surgical treatment on the external appearance of the trunk. A desirable complement to this spine simulator would be to develop a full trunk model that would allow the propagation of the surgical correction on the spine toward the external trunk surface through the soft tissue deformation.

Physics-based models of deformable objects have been studied since the early 80's and are common in animation where physical laws are applied to an object to simulate realistic movements. Deformable physics-based models are also used in biomedical applications, in particular for surgery simulation [30]. These applications require visual and physical realism, but the real biomechanical properties involved are not always well known. The two most popular approaches to physically modeling soft tissues are the Finite Element Method (FEM) and Mass-Spring Model (MSM). Commonly used in engineering to accurately analyze structures and continua, the conventional FEM still has a large memory cost and computation times that limit interactive applications. Variants of FEM-based methods have thus been introduced to solve these issues [36, 38, 37]. However most of them are applicable only to linear deformations valid for small displacements. Improvements have been made to include large deformations in real-time [39] but a small number of elements must be considered in order to attain interactivity due to the increased computational cost. Application examples are the simulation of plastic and maxillofacial surgeries [31, 40, 2] and breast reconstructive surgery [41]. The MSM approach is less physically accurate than continuum biomechanical models. Nonetheless, with different stiffness springs, Terzopoulos and Waters [33] animated a face composed of several layers of springs representing the epidermis, dermis, sub-cutaneous connective tissue, fascia and muscles. A generic model was adapted to real digitized faces by an optimization of the masses' positions using facial features [80]. Koch *et al.* [31] used a finite element surface connected to the skull by springs to simulate a facial

plastic surgery. The MSM approach has also been used to model hip joint replacement [81]. In general, mass-spring methods have many advantages: simple implementation, intuitiveness, efficiency, good first interactive impression and easy parallelization. On the other hand, classical MSM present some disadvantages: (i) since no volume behavior of the tetrahedra is incorporated into the model, flip-over of springs may possibly occur; (ii) there is no way to control the volume conservation during simulation.

In general, large deformations of soft tissue are dealt with by introducing nonlinearities in the formulation of the tissue properties. Nonlinear elasticity has been proven to yield better results as compared to linear elasticity in the case of large deformations [37, 39]. However, the complexity of the computation is increased with this solution. In this paper, we propose a novel incremental approach for simulating the trunk shape correction that takes into account the large deformations involved in the preoperative-to-postoperative changes, while maintaining the linear approximation. The main idea consists in reducing the nonlinear deformation process into a sequence of small deformations for which the linear elastic behavior holds, so that one can keep the initial linear formalism in the course of the simulation. The method is then applied to a set of real data of scoliotic patients ($n = 7$) who have undergone spine surgery and for whom preoperative and postoperative data are available.

4.3 Methodology

4.3.1 The scoliotic patients sample

Consenting AIS patients ($n = 7$) with thoracic (spinal) curve having undergone corrective spine surgery at Sainte-Justine University Hospital Center in Montréal, Canada were considered. The hospital's Research Ethics Committee has approved the study protocol. The average patient age at the time of surgery was 13.9 ± 1.5 (mean $\pm$ standard deviation) years old, and Cobb angles before surgery averaged 65.3° (standard deviation: 1.5°).

4.3.2 Data acquisition and construction of patient-specific trunk geometric model

A non-invasive active vision system and a calibrated biplanar X-ray imaging system are used respectively to acquire the trunk surface topography and to reconstruct the 3D geometry of the trunk's bone structures (spine, rib cage and pelvis). The surface geometry of the trunk is acquired using a calibrated system composed of four 3D optical digitizers (Creaform Inc., Levis, Canada), each one comprising a CCD camera and a structured light projector, placed around the patient (Fig. 5.1). The acquisition process, identical for each scanner, consists in projecting and capturing four fringe patterns deformed by the trunk's external shape. The system then computes, by triangulation, the depth of each surface point relative

to the reference plane of the digitizer. A fifth image, captured without fringes, defines the texture data mapped on the surface. The entire trunk geometry is obtained by registering and merging the partial surfaces obtained by each digitizer. This process takes 4-6 seconds with the patient standing still in the upright position, arms slightly abducted to prevent occluded areas in the field of view of the lateral scanners. The resulting surface mesh (containing 50k-




Figure 4.2 Trunk topography measurement and reconstruction. (A) Experimental set-up at Sainte-Justine Hospital of four Creaform optical digitizers. (B) Example of a Capturor II LF 3D optical digitizer, consisting of a CCD camera coupled with a structured light projector. (C) Set of four fringe images, each offset by $\frac{1}{4}$ phase, projected by a digitizer onto the back of a mannequin; the fifth image provided the surface texture. (D) Resulting phase image from the four fringe images; surface reconstruction uses the interferometry principle combined with active triangulation. (E) The process of registering and merging the partial surfaces from the different digitizers produces the complete trunk surface.

90k vertices, depending on the patient's height) was proven to have a reconstruction accuracy of 1.4mm over the whole torso (when applied to a mannequin). The 3D reconstruction of the bone structures (Fig. 5.2) has an accuracy evaluated at 2.1 ± 1.5 mm over a set of 3D positions of identified landmarks [20]. A detailed surface mesh of the patient's skeletal structures is then obtained by fitting a high-resolution atlas of 3D generic bone structures to the personalized data of the patient using dual kriging. The atlas was created using computed tomography scans of a dry cadaveric specimen and the accuracy of the resulting geometrical model was evaluated at 3.5 ± 4.1 mm [82]. The external trunk surface is then closed and registered with the bone structure data, and a tetrahedral mesh of the whole trunk is thereafter generated using Tetgen [83], a public domain tetrahedral mesh generator based on Shewchuk's Delaunay refinement algorithm [84].




Figure 4.3 Graphical user interface of the system for 3D reconstruction of the bone structures. This view shows the identification of anatomical landmarks on the vertebrae and ribs in the coronal and sagittal radiographs (left and middle), and a simplified 3D reconstruction (right) [1].

4.3.3 Numerical simulation of postoperative trunk shapes

We introduce a novel incremental approach for simulating the trunk deformation. Fig. 4.4 represents a flow chart of our postoperative trunk appearance simulation system, where




Figure 4.4 Flow chart of the postoperative trunk shape simulation.

only the key components of the simulation engine are indicated. The process starts with the preoperative data (the bone structures and the trunk surface). From these data, a patient-specific trunk geometry model is built. The resulting model along with the target postoperative internal configuration are then input into the trunk deformation simulator. The simulator outputs a new trunk shape which can then be further evaluated.

4.3.4 Modeling the trunk soft tissue deformation

The surgery of the scoliotic spine consists in attaching one or more metallic rods to the spine and performing certain maneuvers to correct its curvature. As a result of the change in the

spine configuration, one expects the whole trunk (and particularly the external surface) to change accordingly. We consider the human trunk as a deformable continuum occupying a bounded domain $\Omega \in \mathbb{R}^3$, with a continuous boundary Γ_Ω . A two-material body model (consisting in a bone structures region in Ω_b and a soft tissue region in $\Omega_s = \Omega \setminus \Omega_b$) is considered. In the following, spatial domains related to the preoperative trunk will be indicated by the superscript 0, while domains related to the postoperative trunk will be indicated by the superscript 1. One may view the trunk shape changes as follow: an arbitrary point in the trunk at $\mathbf{x}^0 \in \Omega^0$ is moved to a new position $\mathbf{x}^1 \in \Omega^1$, and the overall process induces a change from shape state Ω^0 to shape state Ω^1 .

Incremental approach to simulate the postoperative trunk external surface

From now on, we denote by $\mathcal{C}(\Omega)$ the space of smooth mappings from Ω to $\mathbb{R}^3$, and $\mathcal{B}(\Omega)$ the subspace of $\mathcal{C}(\Omega)$ corresponding to small deformations on Ω . Let $\mathcal{E}(\omega, \Omega^0; \mathbf{f})$ denote the deformation energy required to deform Ω^0 into ω through a deformation $\mathbf{f} \in \mathcal{F}$, where $\mathcal{F}$ denotes the space of (smooth) mappings such that

$$\mathcal{F} = \{\mathbf{f} \in \mathcal{C}(\Omega) | \mathbf{f}(\Omega_b^0) \approx \Omega_b^1\}.$$

Let us represent the deformation of a scoliotic trunk from the preoperative to the postoperative configurations by $\phi(\mathbf{x})$ for $\mathbf{x} = (x, y, z) \in \Omega^0$. By considering the principle of least action, the state of equilibrium of the postoperative trunk shape model is reached when the deformation energy is a minimum:

$$\begin{cases} \Omega^1 = \phi(\Omega^0), \\ \phi = \underset{\mathbf{f} \in \mathcal{F}}{\operatorname{argmin}} \left\{ \mathcal{E}(\omega, \Omega^0; \mathbf{f}) : \omega = \mathbf{f}(\Omega^0) \right\}, \end{cases} \quad (4.1)$$

for an energy functional $\mathcal{E}(\omega, \Omega^0; \mathbf{f})$ to be discussed later (Section 4.3.4). Eq. (4.1) may be rewritten as

$$\Omega^1 = \underset{\substack{\omega \\ \omega = \mathbf{f}(\Omega^0)}}{\operatorname{argmin}} \left\{ \mathcal{E}(\omega, \Omega^0; \mathbf{f}) : \mathbf{f} \in \mathcal{F} \right\}. \quad (4.2)$$

While Eq. (4.1) is primarily concerned with the search for the deformation ϕ in the space of smooth mappings $\mathcal{F}$, Eq. (4.2) processes admissible shapes and selects the optimal one which is the deformed trunk shape at equilibrium. We define the space of mappings $\mathcal{U}$ as

$$\mathcal{U} = \{\tilde{\mathbf{f}} \in \mathcal{C}(\Omega) | \tilde{\mathbf{f}}|_{\Omega_b} = \operatorname{Id}\},$$

where Id is the identity map. Let $\omega = \omega_s \cup \omega_b$ be a trunk shape variable. Let us define the mapping $\tilde{\varphi}$ (relaxation), $\tilde{\varphi}(\mathbf{x})$ for $\mathbf{x} \in \omega$, as follows:

$$\begin{aligned} \tilde{\varphi} &\in \mathcal{U}, \\ \tilde{\varphi}(\omega) &= \tilde{\omega}_s \cup \omega_b, \\ \tilde{\omega}_s &= \underset{\substack{\omega_s^+ \\ \omega_s^+ = \omega^+ \setminus \omega_b}}{\text{argmin}} \left\{ \mathcal{E}(\omega^+, \Omega^0; \tilde{\mathbf{f}}) : \right. \\ &\quad \left. \omega^+ = \tilde{\mathbf{f}}(\omega), \tilde{\mathbf{f}} \in \mathcal{U} \right\}, \end{aligned} \tag{4.3}$$

where $\mathcal{E}(\omega, \Omega^0; \mathbf{f})$ is the deformation energy model.

We now introduce a novel incremental approach for the simulation of postoperative trunk shape. Let $(t_k)_{k=0,1,2,\dots,N}$ be a sequence of real numbers such that $t_k \in [0, 1]$, $t_{k+1} > t_k$ for $k \in \{0, 1, 2, \dots, N-1\}$, $t_0 = 0$ and $t_N = 1$. Let $L^0 = \{\mathbf{l}_i^0 \in \Omega_b^0, i = 1, \dots, n\}$ and $L^1 = \{\mathbf{l}_i^1 \in \Omega_b^1, i = 1, \dots, n\}$ be, respectively, a collection of landmarks on the preoperative bone structures and the collection of corresponding anatomical landmarks on the target postoperative bone configuration. Let $\mathcal{S}$ denote the space of smooth transformations, defined as

$$\mathcal{S} = \{ \mathbf{f} \in \mathcal{C}(\Omega) \mid \mathbf{f}(\mathbf{l}_i^0) \approx \mathbf{l}_i^1, i = 1, \dots, n \}.$$

We have $\mathcal{S} \subset \mathcal{F}$. Let $\mathcal{G}_0$ denote the collection of sequences of transformations $\Phi = (\phi_{t_k})_{k=0,\dots,m}$, with small increments (See definition in 4.6, Definition 1), such that

$$\begin{aligned} \mathcal{G}_0 &= \left\{ (\phi_{t_k})_{k=0,\dots,m} \in \mathcal{G}, \quad m \in \mathbb{N} \quad \mid \quad \phi_{t_0} = \text{Id}_{\mathbb{R}^3}, \right. \\ &\quad \left. \phi_{t_m} \circ \phi_{t_{m-1}} \circ \dots \circ \phi_{t_1} \circ \phi_{t_0} \in \mathcal{S} \right\}. \end{aligned} \tag{4.4}$$

Our incremental approach defines a sequence of trunk shapes $(\Omega^{t_k})_{k=0,1,\dots,m}$, $m \in \mathbb{N}$, moving from the undeformed state Ω^0 to the deformed state Ω^1 based on a sequence of mappings $\Phi \in \mathcal{G}_0$. Let $\Omega_b^{t_k}$ and $\Omega_s^{t_k}$ be, respectively, the bone and soft tissue configurations of the trunk shape Ω^{t_k} ($\Omega^{t_k} = \Omega_s^{t_k} \cup \Omega_b^{t_k}$) at increment step k , within the sequence starting at Ω^0 under successive deformations. Our method computes Ω^1 as the final shape of the sequence

$(\Omega^{t_k})_{k=0,1,2,\dots,N}$ as follows:

$$\begin{aligned}\Omega^0 &= \Omega_s^0 \cup \Omega_b^0, \\ \Omega^{t_k} &= \Omega_s^{t_k} \cup \Omega_b^{t_k}, \quad k = 0, 1, \dots, N, \\ \Omega^{t_{k+1}} &= \tilde{\varphi} \circ \phi_{t_{k+1}}(\Omega^{t_k}), \quad (\phi_\tau)_{0 \leq \tau \leq 1} \in \mathcal{G}_0.\end{aligned}\tag{4.5}$$

In Algorithm (4.5), the first equation refers to the initial state of the trunk, the second one refers to the indexed trunk shape state at increment step t_k , and the third one states the transition rule from step k to step $k+1$. Our first analytical result deals with the properties of independence of the final equilibrium state from the chosen sequence $\Phi \in \mathcal{G}_0$. These properties are established by Theorem 1 and Theorem 2 (See 4.6). Our second analytical result establishes that Algorithm (4.5) gives the solution to the problem stated in Eq. 4.2 (See 4.6, Theorem 3). In this paper, we consider a family of thin plate spline mappings, $(\phi_{t_k})_{k=0,1,\dots,N} \in \mathcal{G}_0$, associated with the matching of the bone structure landmarks.

The incremental approach proposed in this section is usable for any appropriate deformation energy functional of the trunk. In the next section, we address a specific energy model to be used in the present work.

Deformation energy model

Let us assume that we have a conformal tetrahedral mesh describing the geometry of the anatomical structures of the trunk. We denote the mesh at its rest position as $\mathcal{M}^0$ and the initial position of each vertex as $\mathbf{P}_i^0$. We denote the vertex position of a deformed mesh $\mathcal{M}^1$ as $\mathbf{P}_i$. Let us represent the deformation by a displacement vector field $\mathbf{U}(\mathbf{x})$ for $\mathbf{x} = (x, y, z) \in \mathcal{M}^0$, and we write $\mathbf{f} = \text{Id} + \mathbf{U}$, where Id is the identity transformation. Given a deformed model $\mathcal{M}^1$, let us define the displacement vector for each point of the domain by linearly interpolating the displacement $\mathbf{U}_i \equiv \mathbf{P}_i - \mathbf{P}_i^0$ of the vertices inside each tetrahedron. If T_i represents the tetrahedron defined by the four vertices $\mathbf{P}_j^0$, $j = 1, \dots, 4$, in their rest position, then the displacement vector at a given point $\mathbf{x} = (x, y, z)$ is defined as:

$$\mathbf{U}_{T_i}(\mathbf{x}) = \sum_{j=1}^4 a_j^{T_i}(\mathbf{x}) \mathbf{U}_j,$$

where $a_j^{T_i}(\mathbf{x})$ are the barycentric coordinates of the point $\mathbf{x}$ inside T_i . The deformation energy $W_{T_i}(\mathbf{U})$ of a tetrahedron T_i can be expressed as an expansion over its features (characterized

by $\{\mathbf{P}_{T_i(j)}, j = 0, \dots, 3\}$, its vertices coordinates) as:

$$W_{T_i} = \sum_j W_j^{T_i} + \sum_{j,k} W_{jk}^{T_i} + \sum_{j,k,l} W_{jkl}^{T_i} + W_{jklm}^{T_i},$$

where the terms $W_j^{T_i}$, $W_{jk}^{T_i}$, $W_{jkl}^{T_i}$, and $W_{jklm}^{T_i}$, are the energy contributions from the nodes, edges, faces (triangles) and volume, respectively. The total deformation energy $\mathcal{E}$ required to deform $\mathcal{M}^0$ into $\mathcal{M}^1$ is the sum of the energies associated with each tetrahedron:

$$\mathcal{E}(\mathcal{M}, \mathcal{M}^0; \mathbf{f}) = \sum_{T_i \in \mathcal{M}} W_{T_i}.$$

Incompressible Tetrahedral Mass System Model The incompressible tetrahedral mass system model (ITMSM), in its original form, was introduced by Teschner *et al.* [85]. The model has some similarities with the FEM and MSM approaches, in that it is based on a tetrahedral discretization of the deformed domain. We adapt the original deformable model [85] to take into account the contribution of gravity. The energy $\mathcal{W}_T$ of a tetrahedron T in the soft tissue mesh is given by:

$$\mathcal{W}_T = \alpha \tilde{\mathcal{E}}_G + \tilde{\mathcal{E}}_D + \epsilon \tilde{\mathcal{E}}_A + \theta \tilde{\mathcal{E}}_V \quad (4.6)$$

with $\alpha = \frac{2gM_0H_0}{k_D}$, $\epsilon = \frac{k_A}{k_D}$ and $\theta = \frac{k_V}{k_D}$. The energy terms $\tilde{\mathcal{E}}_G$, $\tilde{\mathcal{E}}_D$, $\tilde{\mathcal{E}}_A$ and $\tilde{\mathcal{E}}_V$ are given by:

$$\tilde{\mathcal{E}}_G = \sum_{i \in T} \tilde{W}_i \quad (4.7)$$

$$\tilde{\mathcal{E}}_D = \sum_{i \neq j \in T} \frac{1}{|\mathcal{K}_{ij}|} \tilde{W}_{ij} \quad (4.8)$$

$$\tilde{\mathcal{E}}_A = \sum_{i \neq j \neq k \in T} \frac{1}{|\mathcal{K}_{ijk}|} \tilde{W}_{ijk} \quad (4.9)$$

$$\tilde{\mathcal{E}}_V = \tilde{W}_{ijkl} \quad (4.10)$$

where $\mathcal{K}_{ij}$ and $\mathcal{K}_{ijk}$ are the collections of tetrahedra in the soft tissue mesh containing edge ij and face ijk , respectively ($|\mathcal{K}_{ij}|$ and $|\mathcal{K}_{ijk}|$ represent the cardinality of these collections).

$\widetilde{W}_i$, $\widetilde{W}_{ij}$, $\widetilde{W}_{ijk}$ and $\widetilde{W}_{ijkl}$ are given by:

$$\widetilde{W}_i = -\left(\frac{m_i}{M_0}\right)\left(\frac{\mathbf{P}_i \cdot \mathbf{z}}{H_0}\right) \quad (4.11)$$

$$\widetilde{W}_{ij} = \left(\frac{\|\mathbf{P}_{ji}\| - D_0}{D_0}\right)^2 \quad (4.12)$$

$$\widetilde{W}_{ijk} = \left(\frac{\frac{1}{2}\|\mathbf{P}_{ji} \times \mathbf{P}_{ki}\| - A_0}{A_0}\right)^2 \quad (4.13)$$

$$\widetilde{W}_{ijkl} = \left(\frac{\frac{1}{6}\mathbf{P}_{ji} \cdot (\mathbf{P}_{ki} \times \mathbf{P}_{li}) - V_0}{V_0}\right)^2 \quad (4.14)$$

where $\mathbf{P}_{ji} = \mathbf{P}_j - \mathbf{P}_i$, $\mathbf{z}$ is the vertical upward oriented unit vector and m_i is the partial mass associated to mass point $\mathbf{x}_i$, defined as:

$$m_i = \frac{1}{4}\rho_T V_T, \quad (4.15)$$

with ρ_T representing the local density of the tissue and V_T the volume of tetrahedron T . The initial distance or rest length of the edge is denoted by D_0 , A_0 is the initial area of the triangle and V_0 is the initial volume of the tetrahedron. The mean tetrahedral mass and the trunk height are respectively M_0 and H_0 , while k_D is the stiffness associated to tetrahedra edges (considered uniform throughout the soft tissue). The coefficients θ and ϵ introduced in Eq. (4.6) are the weights of the different potential energy contributions: θ is the stiffness ratio between volume- and distance-preserving energies, while ϵ is the stiffness ratio between area- and distance-preserving energies. The coefficients α , ϵ and θ are empirically determined. See the properties of the energy model in 4.6 (Lemma 3 and Theorem 4). We coined the name ITMSM for our model due to the tetrahedron volume energy term appearing in the model, which acts as an incompressibility constraint.

4.3.5 Evaluation of the simulation

Evaluations are conducted using the preoperative and postoperative data of scoliotic patients (3D reconstructions of the bone structures and trunk surface geometry acquisitions). First, a 3D visualization allows for a qualitative comparison of the simulated and the real postoperative trunk shapes. Then, the simulation accuracy is evaluated based on the measurement of the back surface rotation (BSR) on the simulated trunk and on the actual postoperative trunk, at thoracic vertebral levels between $T4$ (4th thoracic vertebra) and $T12$ (12th thoracic vertebra). The BSR index is measured in a series of horizontal cross-sections of the external trunk surface. It is defined as the angle formed between the dual tangent to the posterior

side of a given cross-section and the axis passing through the patient's anterior superior iliac spines (ASIS), projected onto the axial plane. This trunk asymmetry index is widely considered to be clinically relevant in the study of the scoliotic trunk shape [86]. We exploit




Figure 4.5 Graphical user interface of the software tool used to compute the BSR indices from cross-sections at various vertebral levels

the BSR index for our quantitative evaluation as follows. First, by exploiting a common set of radio-opaque markers purposely placed on the skin surface, an elastic registration of the trunk surface geometry with the internal bone structures is performed [87]. Trunk surface cross-sections are then extracted by computing the intersections of the surface topography (mesh) with a set of horizontal planes passing through the centroids of the vertebrae. Finally, the BSR index at each vertebral level is measured from the associated trunk horizontal cross section (Fig. 4.5).

4.4 Results

Simulation results for a patient are presented in Fig. 4.6, where a qualitative comparison of the preoperative trunk surface (Fig. 4.6-A), the simulated postoperative surface (Fig. 4.6-B) and the actual postoperative trunk shape (Fig. 4.6-C) is shown. A visual inspection of the




Figure 4.6 Example of simulation results. (A) Preoperative patient trunk, (B) simulated trunk shape, (C) real postoperative trunk.

results for all the patients in our test set shows a qualitative similarity between the simulated postoperative trunk shape and the real postoperative trunk shape. The overall appearance of the postoperative trunk is qualitatively well reproduced. The region of the back along the spine (back valley) is satisfactorily well reproduced. However, a rib hump is still observable on the simulated trunk surface when compared to the actual postoperative trunk, and the actual shape is less well reproduced in the lumbar region of the back. As well, some discrepancies are noticeable in the upper region of the back around the scapulae.

For the present study, the thoracic region was considered as the main region of interest of the scoliotic trunk, since the rib humps are located in that part of the body. The BSR indices measured at different vertebral levels on the simulated postoperative trunks are compared with those measured on the actual postoperative and preoperative trunks of six patients (Fig. 4.7). For these case studies, which are all characterized by a thoracic spinal curve, the simulated trunks are quantitatively close to the actual postoperative trunk surfaces. This is consistent with the results of the qualitative comparison. The mean absolute error of the BSR index measured on the simulated trunks ranges from $1.20^\circ(\pm 0.73^\circ)$ to $3.2^\circ(\pm 0.83^\circ)$ in the thoracic region.

The seventh case study is a patient characterized by a double major spinal curve. It is presented separately in Fig. 4.8 since it exhibits a relatively high discrepancy between the simulated and actual trunk shapes, compared to the other cases. The mean absolute error of the BSR index on the simulated trunks, for double major and thoraco-lumbar curves patients, range from $3.1^\circ(\pm 1.45^\circ)$ to $5.23^\circ(\pm 1.44^\circ)$, in the thoracic region.

4.5 Discussion

In the present work, the BSR index has been considered as an evaluation metric for the postoperative trunk simulation outcomes. This choice is appropriate since the patient's first concern is for their trunk asymmetry and the BSR quantity has been proven to capture the information related to the rotation of the trunk and the rib hump [86, 87, 88].

A smallest detectable difference of 2.5° for the maximum BSR index was reported by Pazos et al.[88] and therefore it is considered here as a threshold value to judge the accuracy of the simulation with regard to trunk asymmetry. The method proposed in the present work produced simulated postoperative trunks that are not only qualitatively similar to their real counterparts but that also quantitatively fall within the acceptable error range for the BSR index in the thoracic region, as given by the threshold value.

One source of discrepancy in the simulated trunk shapes may be the effect of posture, i.e. differences in standing posture between the pre- and post-operative trunk acquisitions. Simi-




Figure 4.7 BSR indices (in degrees), measured at different vertebral levels from $T4$ to $T12$, for six patients. Blue: actual postoperative trunk, green: simulated trunk, yellow: preoperative trunk. Note that the horizontal scales are not the same on all the graphs.




Figure 4.8 Left: Double major curve scoliotic patient (preoperative geometry). Right: BSR indices measured on the actual postoperative trunk, the simulated trunk and the preoperative trunk surface. Blue: actual postoperative trunk, green: simulated trunk, yellow: preoperative trunk.

larly, another factor is possible weight change (i.e loss or gain) between the preoperative and postoperative acquisitions. Of course, such factors would be difficult to remove totally. However, other sources of discrepancy may be attributed to certain limitations of our approach. Firstly, we considered uniform tissue materials properties throughout the trunk instead of more realistic nonuniform physical properties. Indeed, the soft tissues were approximated by a uniform volumetric mesh and no differentiation was made between actual soft tissue layers (i.e. skin, fat, muscles). This may have affected the accuracy of the simulation. Secondly, materials property coefficients were tuned manually since we have not yet implemented a rigorous method to provide them to the simulator. Finally, a monolithic/non-articulated organization of the bone structures was used, and this does not reflect the exact configuration of the spine.

In future work, some of the present limitations will be addressed. In particular, a personalized tetrahedral mesh can be obtained from MRI images of the trunk, from which the thickness of each tissue layer (skin, fat, muscle) can be extracted. This clinical data will be incorporated into the model and will allow us to simulate the propagation of the spinal correction to the external surface through a mesh composed of three personalized layers. Additionally, we believe that the accuracy of the simulation will be improved by using rigidity constants calibrated from real data of a representative cohort of scoliotic patients with different types of spinal curvature.

In addition, our team is currently developing a non invasive tool to assess the reducibility of the trunk deformity by using the acquisition of the external trunk surface in voluntary lateral bending position. This could lead to new constraints that will be incorporated into our model to simulate the propagation of the spinal correction through the tetrahedral mesh

composed of three personalized layers.

4.6 Conclusion

Spinal correction surgery treats deformities of the trunk bone structures. Since the external appearance of the trunk is one of the main concerns of the patient and one of the factors of his/her satisfaction, a surgery planning strategy that takes into account the outcome for the external 3D shape of the trunk would be a significant contribution.

In this paper, we presented an incremental approach to the soft tissue deformation problem for the simulation of the postoperative trunk shape of scoliotic patients. The evaluation of the method was based on the preoperative and postoperative clinical data of scoliotic patients who underwent spine correction surgery. Although the soft tissues of the human trunk were approximated by a uniform volumetric mesh, our method achieves promising results in the simulation of the postoperative trunk surface.

Conflict of interest statement

The authors declare that there are no conflicts of interest.

Acknowledgments

This research was funded by the Natural Sciences and Engineering Research Council of Canada. The equipment was financed by the Canadian Foundation for Innovation. Author 1 was supported, in part, by the Fondation Sainte-Justine and Fondation des Étoiles foundations of Sainte-Justine University Hospital Center. All the authors are grateful to Philippe Labelle, who performed the initial calibration of the data. We would also like to thank Philippe Debanné for his useful comments and for providing some of the data.

APPENDIX: Modeling the trunk soft tissue deformation

Our first analytical result deals with the properties of independence of the final equilibrium state from the chosen sequence of small incremental mappings. First, we introduce the following definition of a sequence of mappings of small increments.

Definition 1. *We say that a sequence of mappings $\Phi = (\phi_{t_k})_{k \in \{0, \dots, m\}}$ is of small increments if $\delta\Phi_{k,k-1} \in \mathcal{B}(\Omega)$ for all $k \in \{1, \dots, m\}$, where $\delta\Phi_{k,k-1} \equiv \phi_{t_k} \circ \phi_{t_{k-1}} - \phi_{t_{k-1}}$. We write: $\Phi \in \mathcal{G}$.*

For small deformations of the trunk, we then have:

Theorem 1. Let Ω^0 and Ω^1 be preoperative and postoperative trunks where Ω^1 resulted from a small deformation of Ω^0 and let $\mathcal{H} = \{\mathbf{h} \in \mathcal{C}(\Omega^0) | \mathbf{h}(\Omega_b^0) = \Omega_b^1\}$. Then $\tilde{\Omega}^* = \tilde{\varphi} \circ g(\Omega^0)$ is independent of g for $g \in \mathcal{H}$.

Proof. Let $g_1, g_2 \in \mathcal{B}(\Omega)$ be two arbitrary smooth and small deformations on Ω . Let $\omega_1^* = \tilde{\varphi} \circ g_1(\omega^0)$. Then, by definition, $\omega_1^* = \tilde{\omega}_s^* \cup g_1(\omega_b^0)$, with

$$\tilde{\omega}_s^* = \underset{\substack{\omega_s^+ \\ \omega_s^+ = \omega^+ \setminus g_1(\omega_b^0)}}{\operatorname{argmin}} \left\{ \mathcal{E}(\omega^+, \Omega^0; \tilde{\mathbf{f}}) : \right. \\ \left. \omega^+ = \tilde{\mathbf{f}}(\omega), \tilde{\mathbf{f}} \in \mathcal{U} \right\},$$

Let $\omega_2^* = \tilde{\varphi} \circ g_2(\omega^0)$. Then $\omega_2^* = \tilde{\omega}_s^{**} \cup g_2(\omega_b^0)$, with

$$\tilde{\omega}_s^{**} = \underset{\substack{\omega_s^+ \\ \omega_s^+ = \omega^+ \setminus g_2(\omega_b^0)}}{\operatorname{argmin}} \left\{ \mathcal{E}(\omega^+, \Omega^0; \tilde{\mathbf{f}}) : \right. \\ \left. \omega^+ = \tilde{\mathbf{f}}(\omega), \tilde{\mathbf{f}} \in \mathcal{U} \right\},$$

Since $g_1, g_2 \in \mathcal{B}(\Omega)$, we have $g_1(\omega_b^0) = g_2(\omega_b^0) = \omega_b^1$. Thus,

$$\tilde{\omega}_s^{**} = \underset{\substack{\omega_s^+ \\ \omega_s^+ = \omega^+ \setminus \omega_b^1}}{\operatorname{argmin}} \left\{ \mathcal{E}(\omega^+, \Omega^0; \tilde{\mathbf{f}}) : \omega^+ = \tilde{\mathbf{f}}(\omega), \tilde{\mathbf{f}} \in \mathcal{U} \right\} = \tilde{\omega}_s^*$$

and

$$\omega_1^* = \tilde{\omega}_s^* \cup \omega_b^1 = \tilde{\omega}_s^{**} \cup \omega_b^1 = \omega_2^*.$$

This establishes the conclusion of Theorem 1. $\square$

For large deformations of the trunk, we have:

Theorem 2. Let N_1 and N_2 be two positive integers, and let $\mathbf{G}^{(1)} = (g_{t_{k_1}}^{(1)})_{k_1=0, \dots, N_1}$, $\mathbf{G}^{(2)} = (g_{t_{k_2}}^{(1)})_{k_2=0, \dots, N_2}$, be two sequences of mappings, with $\mathbf{G}^1, \mathbf{G}^2 \in \mathcal{G}_0$. Let $g^{(1)} = (\tilde{\varphi} \circ g_{t_{N_1}}^{(1)}) \circ \dots \circ (\tilde{\varphi} \circ g_{t_0}^{(1)})$ and $g^{(2)} = (\tilde{\varphi} \circ g_{t_{N_2}}^{(2)}) \circ \dots \circ (\tilde{\varphi} \circ g_{t_0}^{(2)})$, where $\tilde{\varphi}$ is defined in section 4.3.4. Then $g^{(2)}(\omega^0) = g^{(1)}(\omega^0)$.

Proof. Let $\gamma^{(i)} = g_{t_{N_i}}^{(i)} \circ (\tilde{\varphi} \circ g_{t_{N_i-1}}^{(i)}) \circ \dots \circ (\tilde{\varphi} \circ g_{t_0}^{(i)})$, $i = 1, 2$. Then $g^{(i)} = \tilde{\varphi} \circ \gamma^{(i)}$, $i = 1, 2$. By the definition of $\mathcal{G}_0$ and $\tilde{\varphi}$, we have $\omega_b^{*(1)} = \gamma^{(1)}(\omega_b^0) = \gamma^{(2)}(\omega_b^0) = \omega_b^{*(2)}$, and $g^{(i)}(\omega^0) = \omega^{*(i)} =$

$\tilde{\omega}_s^{*(i)} \cup \omega_b^{*(i)} = \tilde{\omega}_s^{*(i)} \cup \gamma^{(i)}(\omega_b^0)$, with

$$\begin{aligned} \tilde{\omega}_s^{*(i)} = \operatorname{argmin}_{\substack{\omega_s^+ \\ \omega_s^+ = \omega^+ \setminus \omega_b^{*(i)}}} \left\{ \mathcal{E}(\omega^+, \Omega^0; \tilde{\mathbf{f}}) : \right. \\ \left. \omega^+ = \tilde{\mathbf{f}}(\gamma^{(i)}(\omega^0)), \tilde{\mathbf{f}} \in \mathcal{U} \right\}, i = 1, 2. \end{aligned}$$

Thus, $\omega_s^{*(1)} = \omega_s^{*(2)}$. It follows that $g^{(1)}(\omega^0) = g^{(2)}(\omega^0)$. $\square$

Our second analytical result deals with the solution of the problem stated in Eq. 4.2. We have the following:

Theorem 3. *For any $\mathbf{F} = (\mathbf{f}_{t_j})_{j=0,1,\dots,m} \in \mathcal{G}_0$, if $\tilde{\Omega}^*$ is the final deformed shape of the sequence $(\Omega^{t_j})_{j=0,1,\dots,m}$ produced by Algorithm (4.5), then $\tilde{\Omega}^*$ satisfies Eq. (4.2), that is,*

$$\mathcal{E}(\tilde{\Omega}^*) = \min_{\substack{\omega \\ \omega = \mathbf{f}(\Omega^0)}} \left\{ \mathcal{E}(\omega, \Omega^0; \mathbf{f}) : \mathbf{f} \in \mathcal{F} \right\}.$$

In order to prove Theorem 3, we need the following lemmas:

Lemma 1. *Let $\mathbf{F} = (f_{t_j})_{j=0,\dots,m} \in \mathcal{G}_0$ be a fixed sequence. Let $\hat{\phi}_m, \hat{\phi}_{m-1}, \dots, \hat{\phi}_0 \in \mathcal{U}$. Then $(\hat{\phi}_m \circ f_{t_m}) \circ \dots \circ (\hat{\phi}_0 \circ f_{t_0}) \in \mathcal{F}$.*

Proof. Let $h = (\hat{\phi}_m \circ f_{t_m}) \circ \dots \circ (\hat{\phi}_0 \circ f_{t_0})$. Then h is smooth since the composition of smooth functions is smooth. Furthermore, $h \in \mathcal{F}$ since $\hat{\phi}_j|_{\omega_b^0} = \text{Id}$, and we have $h(\Omega_b^0) = (\hat{\phi}_m \circ f_{t_m}) \circ \dots \circ (\hat{\phi}_0 \circ f_{t_0})(\Omega_b^0) = f_{t_m} \circ \dots \circ f_{t_0}(\Omega_b^0) = \Omega_b^1$. $\square$

The next lemma states that any smooth function can be expressed as the composition of a sequence of small deformations.

Lemma 2. *Suppose $\mathbf{F} = (f_{t_j})_{j=0,\dots,m} \in \mathcal{G}_0$ is given. For any $f \in \mathcal{F}$, there exists $\hat{\phi}_m, \hat{\phi}_{m-1}, \dots, \hat{\phi}_0 \in \mathcal{U}$ such that $f = (\hat{\phi}_m \circ f_{t_m}) \circ \dots \circ (\hat{\phi}_0 \circ f_{t_0})$.*

Proof. Let us consider an arbitrary $\hat{\phi}_{m-1}, \dots, \hat{\phi}_0 \in \mathcal{U}$ (for example, one can consider $\hat{\phi}_{m-1} = \dots = \hat{\phi}_0 = \tilde{\phi}$ where $\tilde{\phi}$ is defined in section 4.3.4). Let us define $f_m = f_{t_m} \circ (\hat{\phi}_{m-1} \circ f_{t_{m-1}}) \circ \dots \circ (\hat{\phi}_0 \circ f_{t_0})$. Then $\bar{\bar{\phi}}_m = f - f_m \in \mathcal{U}$ (small deformation and $\bar{\bar{\phi}}_m|_{\Omega_b} = \text{Id}$), and we have $f = \bar{\bar{\phi}}_m \circ f_m$ which has the desired form. $\square$

Finally, let us prove that Ω^* produced by Algorithm (4.5) satisfies Eq. (4.2). Let us write $\phi^* = (\tilde{\varphi} \circ f_{t_m}) \circ \dots \circ (\tilde{\varphi} \circ f_{t_0})$. Then, from Algorithm (4.5), we have $\tilde{\Omega}^* = \phi^*(\Omega^0)$. By Lemma 2, for any $f \in \mathcal{F}$, there exists $\hat{\phi}_m, \hat{\phi}_{m-1}, \dots, \hat{\phi}_0 \in \mathcal{U}$ such that $f = (\hat{\phi}_m \circ f_{t_m}) \circ \dots \circ (\hat{\phi}_0 \circ f_{t_0})$. The mapping ϕ^* produces the sequence of shapes $(\tilde{\Omega}^{t_j})_{j=0,\dots,m}$ to which is associated the sequence

of energies $\mathcal{E}_0^*, \mathcal{E}_1^*, \dots, \mathcal{E}_m^*$. On the other hand, f (through its expansion) produces the sequence of shapes $(\bar{\Omega}^{t_j})_{j=0, \dots, m}$ to which is associated the sequence of energies $\bar{\mathcal{E}}_0^*, \bar{\mathcal{E}}_1^*, \dots, \bar{\mathcal{E}}_m^*$. From the definition of $\tilde{\varphi}$, we have $\mathcal{E}_j^* \leq \bar{\mathcal{E}}_j^*$, $j = 0, \dots, m$. Thus, it follows that

$$\mathcal{E}(\tilde{\Omega}^*) = \mathcal{E}(\tilde{\Omega}^{t_m}) \leq \mathcal{E}\{\omega : \omega = f(\Omega^0), f \in \mathcal{F}\}.$$

This establishes the conclusion of Theorem 3 $\square$.

The energy model presented in the paper has the following property:

Lemma 3. *The energy functional $\mathcal{E}(\Omega, \Omega^0; \mathbf{f})$, given by Eq. (4.6), is (strictly) convex.*

Proof. The energy $\mathcal{E}$ is a superposition of convex functions. It follows that $\mathcal{E}$ is convex. $\square$

It follows that the trunk shape obtained by solving the optimization problem has the following property, stated as a theorem:

Theorem 4. *The optimal shape from Eq. (4.2), associated with the energy functional from Eq. (4.6), is unique.*

Proof. Since the energy functional is convex, a local minimum is also a global minimum. The conclusion of Theorem 4 follows, since the global minimum of a convex functional is unique. $\square$

CHAPITRE 5

ARTICLE 2: STATISTICAL MODEL BASED 3D SHAPE PREDICTION OF POSTOPERATIVE TRUNKS FOR NON-INVASIVE SCOLIOSIS SURGERY PLANNING

K. C. Assi^{a,b,*}, H. Labelle^b, F. Cheriet^{a,b}

(a) *École Polytechnique de Montréal, P.O. Box 6097, Succursale Centre-ville,
Montréal, Québec, Canada H3C 3A7*

(b) *Sainte-Justine Hospital Research Center, 3175 Côte-Sainte-Catherine,
Montréal, Québec, Canada H3T 1C5*

5.1 Abstract

One of the major concern of scoliosis patients undergoing surgical treatment is the aesthetic aspect of the surgery outcome. It would be useful to predict the postoperative appearance of the patient trunk in the course of a surgery planning process in order to take into account the expectations of the patient. In this paper, we propose to use the least squares support vector regression for the prediction of the postoperative trunk 3D shape after spine surgery for adolescent idiopathic scoliosis. Five dimensionality reduction techniques used in conjunction with the support vector machine are compared. The methods are evaluated in terms of their accuracy, based on the leave-one-out cross-validation performed on a database of 141 cases. The results indicate that the 3D shape predictions using a dimensionality reduction obtained by simultaneous decomposition of the predictors and response variables have the best accuracy.

5.2 Introduction

Adolescent idiopathic scoliosis (AIS) is a three-dimensional deformation of the spine and rib cage, with a prevalence of approximately 3% in the general population. Depending on the severity of the trunk deformity, a spine correction surgery may be required. Among patients with AIS, 9% are treated by brace and one in a thousand needs surgery using posterior spinal instrumentation and fusion to correct the deformity. Neglecting to proceed for a surgical treatment may lead to functional complications such as postural, cardiac or pulmonary problems.

One of the main concern of scoliotic patients undergoing surgery is the postoperative external appearance of the trunk, i.e, the aesthetical aspect [17]. Assessment by surgeons

of scoliosis surgery outcomes are not necessarily correlated with patient satisfaction and vary with the observer [89]. Therefore, it would be important to be able to rigorously and quantitatively predict the outcome of the surgery in a surgery planning process. This will allow the surgeon to take into account the expectations of the patients.

Information technology in medicine is assisting physicians and clinicians in their practice by providing computer based data management and processing tools as an aid in medical decision making. Recently, Devedzic et al. [90] developed a web-based information system, ScolioMedIS, to help health professionals monitor, manage and use clinical data from scoliosis patients. ScolioMedIS [90] uses parameterized 3D anatomical models of the spine for the quantitative assessment of the deformity. By reducing the number of required radiographs, the system allows to minimize the amount of radiation exposure. One of the turning points in scoliosis research was the emergence, in the last two decades, of new techniques for the human trunk surface topography data acquisition and processing, mostly based on optical range image 3D technologies. The aim was to replace radiographic evaluation of scoliosis with systems free from ionizing radiation. Pazos et al. [91] developed a non-invasive technique with a four digital cameras using a projected structured light for the acquisition and 3D reconstruction of the whole trunk. This optical 3D digitizing system is used for clinical assessment of the trunk external asymmetry. Shannon [92] developed a system using video based motion capture technology allowing the simultaneous acquisition of multiple samples of back surface shape and the locations of bony landmarks. This system leads to a quantitative and reliable analysis of the trunk aesthetics. Some researchers have proposed, in the past recent years, various efficient 3D surface analysis combined with different trunk landmarks identification and selection techniques to detect spinal and torso deformities, leading to different trunk surface characterization schemes for scoliosis diagnosis. For example, using structured splines models of the trunk surface, Ajemba et al. [93] proposed a method of characterizing the torso shape deformity associated with scoliosis by both its type and severity. Seoud et al. [69] used some trunk surface topography analysis techniques to obtain the prediction of scoliosis curve types. These previous works succeeded in fulfilling their purpose but did not address the surgical treatment outcome prediction problem. The present paper contribution builds upon the above cited works in the analysis of the trunk surface topography for the management of scoliosis and proposes a method to predict the postoperative trunk 3D shape.

Machine learning prediction techniques, particularly support vector machines (SVM), have been increasingly and successfully applied to a wide variety of biological and medical engineering problems such as electroencephalography (EEG) signals analysis [64, 94], electromyography (EMG) signals analysis for neuromuscular disorder detection [95], brain glioma [65], heart disease diagnosis [96], macroinvertebrate image classification [97], and pro-

tein recognition [98], to cite but a few examples. In the case of scoliosis studies, one important question that was addressed by different research groups, during the last few years, is about relating the trunk surface with the configuration of the spine. Bergeron et al.[66] have investigated the correlation between the surface topography and the spinal curve, using support vector regression. Jaremko et al.[67] have used neural-network approaches to study and estimate Cobb angle from the trunk external surface asymmetry measurements. Ramirez et al. [68] have used support vector machine to assess the severity of the spine deformity from surface topography data. Although these works find applications in the follow-up or diagnosis of scoliosis patients, they were essentially limited to preoperative trunk shapes. These studies do not address the question of correlating the preoperative shape with the postoperative shape. Finding a solution to such a question would have important applications in scoliosis surgery planning.

Very few works have been done on the quantitative relationship between the preoperative and the postoperative trunk surfaces. Simulation of the postoperative bone structure have been conducted in [4]. But the study was limited only to the spine configuration. To the best of our knowledge, the first work on the simulation of the postoperative trunk surface in scoliosis surgery are the preliminary results reported in [29] by our research group. The approach is based on a particle system model of the soft-tissue of the trunk. This simulator has however some limitations. In particular, some aspect of the preprocessing requires the output of a postoperative bone structures simulator [4] as a starting point. The approach taken in the present work, is through shape prediction based on support vector machines, and complements the simulator in [29]. The output of the study would provide to the simulator an initial shape estimate to be used in the personalized trunk surface simulation. Our approach takes into account information contained in a database of scoliotic trunk 3D shapes. To the best of our knowledge, this is the first study of statistical based prediction of the postoperative trunk 3D shape after spine surgery for AIS.

The main idea of statistical model-based shape prediction is to find statistically plausible parameter values of the model, given the available patient data and some fitting criteria. Most statistical machine learning techniques may not be effective for high-dimensional data. Due to the *curse of dimensionality*, the accuracy and efficiency of most prediction algorithms degrade rapidly as the data dimension increases. Medical images and anatomical shapes data usually involves a large number of samples points and correlated features. Thus, it is a prerequisite to reduce the data dimension so that the prediction methods can be applied to the reduced data sets. For this reason, a typical prediction procedure may consist in four steps: (i) feature extraction, (ii) feature dimensionality reduction, (iii) regression function learning, and (iv) prediction [99]. The choice of support vector machine for regression as a learning

method was motivated by its strong generalizability capability. Dimensionality reduction is the process of mapping high-dimensional feature vectors onto lower-dimensional vectors while maintaining sufficient information to reproduce most of the variability of the original data set. Principal components analysis (PCA) [100] is by far the most popular unsupervised linear technique for dimension reduction. PCA constructs a low-dimensional representation of the data that describes as much of the variance in the data as possible. However, its effectiveness is limited by its global linearity. Kernel PCA (KPCA) [101] is the reformulation of the traditional linear PCA in a high-dimensional space that is constructed using a kernel function. KPCA computes the principal eigenvectors of the kernel matrix, rather than those of the covariance matrix. However, an important weakness of KPCA is that the size of the kernel matrix is proportional to the square of the number of instances in the data set. The Locality preserving projections (LPP) method [102] is a technique that aims at combining the benefits of linear techniques and local nonlinear techniques for dimensionality reduction by finding a linear mapping that minimizes the cost function of Laplacian eigenmaps. In contrast to PCA, LPP method is capable of successfully identifying complex data manifolds such as the Swiss roll. Neighborhood preserving embedding (NPE) [103] is similar to LPP. However, NPE proceeds by minimizing the cost function of a local nonlinear technique for dimensionality reduction under the constraint that the mapping from the high dimensional to the low-dimensional data representation is linear. Partial Least Squares (PLS) [104, 105] is a technique that generalizes and combines features from principal component analysis and multiple regression. It is particularly useful when one needs to predict a set of dependent variables from a very large set of independent predictor variables. The underlying assumption of all PLS methods is that the observed data is generated by a process which is driven by a small number of latent variables. In its general form, PLS creates orthogonal latent vectors by using the existing correlations between the sets of input and output variables while also keeping most of the variance of both sets. Due to its capability of effectively decreasing the correlation between the input influence factors, the PLS method has proven to be useful in situations where the number of observed variables is much greater than the number of observations and high multicollinearity among the variables exists. These methods were mainly used in the context of classification problems.

The aim of this paper is to compare different dimensionality reduction techniques for a statistical model based shape prediction of the trunk. We report the results obtained using a multivariate statistical model of the trunk feature curve. Five dimensionality reduction techniques such as principal component analysis (PCA), Kernel principal component analysis (KPCA), partial least squares (PLS), locality preserving projection (LPP) and neighborhood preserving embedding (NPE) are considered and compared on a database of 141 scoliosis

patients trunk shapes. The prediction results are evaluated using the leave-one-out cross-validation.

5.3 Materials and Methods

The methods for the trunk 3D shape prediction are described in this section. All the evaluations were made on real clinical datasets obtained using a non-invasive medical imaging system.

5.3.1 Data acquisition of the trunk surface

The data were acquired at the Sainte-Justine Hospital Research Center, and consist of 141 samples. Trunk data were acquired from patients with AIS of age between 11 and 18 years old, who have undergone spine surgery. The acquisition protocol was described by Pazos et al. [106, 88] and is summarized in this section. The surface geometry of the trunk is acquired using a calibrated system composed of four 3D optical digitizers (InSpeck Inc., Montreal, Canada), each assembled with a CCD camera and a structured light projector, placed around the patient (Figure 5.1). The acquisition process, identical for each scanner, consists in projecting and capturing four fringe patterns deformed by the trunk’s external shape. The system then computes, by triangulation, the depth of each surface point relative to the reference plane of the digitizer. A fifth image, captured without fringes, defines the texture data mapped on the surface. The entire trunk geometry is obtained by registering and merging the partial surfaces obtained by each digitizer. This process takes 4-6 seconds with the patient standing still in the upright position, arms slightly abducted to prevent occluded areas in the field of view of the lateral scanners. The resulting mesh contains 40k – 70k vertices, depending on the patient’s height and a previous study [88] of the system demonstrated a reconstruction accuracy of 1.4mm over the whole torso of a mannequin. Before the surface acquisition, visible landmarks are drawn on the patient’s skin. The accuracy of the 3D position of the identified landmarks was evaluated at $2.1 \pm 1.5\text{mm}$ [20]. The homologous landmarks coordinates for each geometry are latter used for the alignment of all the surfaces.

5.3.2 Feature curves representation of the trunk

The trunk surface may be viewed and represented as a finite collection of 3D curves. For the purpose of this work, we are interested in characteristic anatomical curves on the trunk external surface. One of the most visible features of the trunk external surface is the so-called back valley. Figure 5.2 shows the back valley curve along the spinous processes of a scoliotic patient in the preoperative and the postoperative status. The shape of this feature




Figure 5.1 Trunk topography measurement and reconstruction. (A) Experimental set-up of four optical digitizers. (B) Example of a Capturor 3D optical digitizer, consisting of a CCD camera coupled with a structured light projector. (C) Set of four fringe images, each offset by $\frac{1}{4}$ phase, projected by a digitizer onto the back of a mannequin. A fifth image provided the surface texture. (D) Resulting phase image from the four fringe images; surface reconstruction uses the interferometry principle combined with active triangulation. (E) The process of registering and merging the partial surfaces from the different digitizers produces the complete trunk surface




Figure 5.2 Feature curves (back valley) of the trunk surface. Left: preoperative surface. Right: postoperative surface. The curve top and bottom endpoints *A* and *B* correspond to the spinous process of *C7* and the spinous process of *L5*, respectively. *C* indicates the curve.

curve almost follows that of the spine. Due to the surgery procedure, the curve shape has changed from preoperative to postoperative state. The upper and lower end points (*A* and *B*) are anatomical landmarks corresponding to the spinous process of *C7* (seventh

cervical vertebra) and the spinous process of $L5$ (the fifth lumbar vertebra), respectively. A positioning system ensured standard posture before data acquisition. The results of the raw feature curve extraction is a polygonal line consisting of up to 75 three-dimensional coordinates samples from the back surface located along the back valley (Figure 5.3). An initial processing of the data provides a similar basis for comparison among all patients. To begin, four surface markers appearing on the trunk datasets were used to translate the point coordinates to a common 3D Euclidean space, having as origin the spinous process of $L5$ vertebra. The x -axis was oriented towards the front of the patient, the y -axis towards the




Figure 5.3 Anatomical landmarks for the normalization of the dataset. Four landmarks (A_1) PV, (A_2) MPSIS, (A_3) LASIS, and (A_4) RASIS are considered to define a unified coordinate systems. The origin is set at A_2 . The z -axis is perpendicular to the $(A_2A_3A_4)$ plane. The y -axis is parallel to ASIS and oriented to the left side of the patient. The x -axis is oriented to the front of the patient.

patient left (parallel to the ASIS axis). That space was scaled to the unit length of the distance between the endpoints A_1 and A_2 (Figure 5.3), after which the curve was rotated about the origin such that the curve upper end point A_1 coincide with the point $(0,0,1)$. The feature curves were represented explicitly as a finite set of corresponding points uniformly sampled from a parameterized function $\mathbf{f} = \mathbf{f}(t)$, $\mathbf{f} : [0, 1] \rightarrow \mathbb{R}^3$, fitting the initial points.

5.3.3 Statistical framework

The input and response variables $\mathbf{x}_i$ and $\mathbf{y}_i$ for the i -th observation ($i = 1, \dots, n$) are as follow. The variables $\mathbf{x}_i$ are obtained from the positions of N points uniformly sampled from the feature curve of the preoperative trunk shape, while the variables $\mathbf{y}_i$ are points sampled from the postoperative trunk shape:

$$\mathbf{x}_i = [\mathbf{P}_1^x \ \mathbf{P}_1^y \ \mathbf{P}_1^z \ \dots \ \mathbf{P}_N^x \ \mathbf{P}_N^y \ \mathbf{P}_N^z],$$

$$\mathbf{y}_i = [\mathbf{Q}_1^x \ \mathbf{Q}_1^y \ \mathbf{Q}_1^z \ \dots \ \mathbf{Q}_N^x \ \mathbf{Q}_N^y \ \mathbf{Q}_N^z].$$

The data are scaled and centered according to the procedure described in Section 5.3.2. The data matrices $\mathbf{X}$ and $\mathbf{Y}$, of size $n \times 3N$, contain the variables corresponding to the n preprocessed samples $\mathbf{x}_i$ and $\mathbf{y}_i$ of the dataset. The aim is to predict the shape of the postoperative curve 3D shape from the preoperative curve shape. The prediction of the postoperative 3D trunk shape $\mathbf{y}$ from the preoperative trunk shape $\mathbf{x}$ can be performed using the Least Square Support Vector Machine (LS-SVM) [107], in conjunction with a dimensionality reduction of the data prior to the LS-SVM regression. In this study, five dimensionality reduction methods are investigated, namely the Principal Component Analysis (PCA), the Kernel Principal Component Analysis (KPCA), the Partial Least Squares (PLS), the Locality Preserving Projection (LPP) and the Neighborhood Preserving Embedding (NPE). In the remanining of this paper, we adopt the following notations. The dot on top of a variable indicates that it is centered: $\dot{v} = v - \mu_V$, μ_V being the sample mean.

Principal Component Analysis

The PCA approach [100] finds directions $\mathbf{u}_i$ where the the variance of $\dot{\mathbf{X}}$ (or similarly $\mathbf{u}_i^T \dot{\mathbf{X}} \dot{\mathbf{X}}^T \mathbf{u}_i$) is maximum. For that, PCA solves the eigenvalue problem:

$$\dot{\mathbf{X}}^T \dot{\mathbf{X}} \mathbf{u} = \lambda \mathbf{u}.$$

The reduced dataset is obtained by linear projection: $\tilde{\mathbf{X}} = \dot{\mathbf{X}} \mathbf{T}$, where $\mathbf{T}$ is formed by the eigenvectors of the centered covariance matrix.

Kernel Principal Component Analysis

The Kernel PCA dimensionality reduction [101] computes the reduced dataset by the projection of the (training points) $\{\mathbf{x}_i\}_{i=1}^n$ as

$$\mathbf{P} = \tilde{\mathbf{U}}\tilde{\mathbf{\Lambda}}^{1/2},$$

where the columns of $\tilde{\mathbf{U}}$ are created by the eigenvectors $\{\tilde{\mathbf{u}}^i\}_{i=1}^n$, and $\tilde{\mathbf{\Lambda}}$ is a diagonal matrix $\mathbf{diag}(\tilde{\lambda}_1, \dots, \tilde{\lambda}_n)$ are obtained by solving the eigenvalue problem

$$\mathbf{K}\tilde{\mathbf{u}} = \tilde{\lambda}\tilde{\mathbf{u}},$$

with $\mathbf{K} = \Phi\Phi^T$ the $(n \times n)$ matrix associated to the $(n \times n)$ matrix of the centered nonlinear mappings of the input variables $\{\mathbf{x}_i\}_{i=1}^n \in \mathbb{R}^n$.

Partial Least Squares

The PLS dimensionality reduction method [104, 105] finds pairs of direction $\mathbf{u}_i, \mathbf{v}_i$, so that

$$\rho_i = \mathbf{u}_i^T \dot{\mathbf{X}} \dot{\mathbf{Y}}^T \mathbf{v}_i$$

is maximal, with the constraint that both $\mathbf{U}_r = [\mathbf{u}_1, \dots, \mathbf{u}_r]$ and $\mathbf{V}_r = [\mathbf{v}_1, \dots, \mathbf{v}_r]$ form orthonormal bases. Those directions are obtained by solving the eigenproblem:

$$\begin{aligned} \mathbf{S}_{\mathbf{xy}}\mathbf{S}_{\mathbf{yx}}\mathbf{u}_i &= \rho_i^2\mathbf{u}_i \\ \mathbf{S}_{\mathbf{yx}}\mathbf{S}_{\mathbf{xy}}\mathbf{v}_i &= \rho_i^2\mathbf{v}_i \end{aligned}$$

where $\mathbf{S}_{\mathbf{xy}}, \mathbf{S}_{\mathbf{yx}}$ are the sample covariance matrices of X and Y , and Y and X , respectively. The scores $\mathbf{T}_r$ are given by the projection:

$$\mathbf{T}_r = \dot{\mathbf{X}}^T \mathbf{U}_r.$$

Locality Preserving Projection

The Locality Preserving Projection (LPP) method [102] is a linear approximation of the nonlinear Laplacian EigenMap. It computes the mapped dataset $\tilde{\mathbf{X}} = \dot{\mathbf{X}}\mathbf{A}$, where $\mathbf{A}$ is composed by the eigenvectors of the generalized eigenvector problem

$$\dot{\mathbf{X}}^T \mathbf{L} \dot{\mathbf{X}} \mathbf{v} = \lambda \dot{\mathbf{X}}^T \mathbf{M} \dot{\mathbf{X}} \mathbf{v},$$

in which $\mathbf{L}$ is the graph Laplacean and $\mathbf{M}$ the degree matrix of the graph whose weights are given by $w_{ij} = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}}$.

Neighborhood Preserving Embedding

The NPE [103] projects the data with the projection $\tilde{\mathbf{X}} = \dot{\mathbf{X}}\mathbf{B}$ where the linear mapping $\mathbf{B}$ is formed by the eigenvectors associated to the first smallest nonzero eigenvalues of the generalized eigenproblem

$$\dot{\mathbf{X}}^T(\mathbf{I} - \mathbf{W})^T(\mathbf{I} - \mathbf{W})\dot{\mathbf{X}}\mathbf{v} = \lambda\dot{\mathbf{X}}^T\dot{\mathbf{X}}\mathbf{v},$$

where $\mathbf{I}$ represents the $n \times n$ identity matrix, and $\mathbf{W}$ the adjacency matrix of the neighborhood graph.

5.3.4 Least Squares Support Vector Regression

The least squares support vector machine (LS-SVM) for regression [107] is used for the prediction of the postoperative trunk 3D curve shapes. Given the dataset $\{(\mathbf{x}_i, y_i)_{i=1}^n\}$, we are interested in estimating a model of the form

$$y = \mathbf{w}^T \phi(\mathbf{x}) + \mathbf{b},$$

where $\mathbf{x} \in \mathbb{R}^n$, $y \in \mathbb{R}$ and $\phi(\cdot) : \mathbb{R}^n \rightarrow \mathbb{R}^{n_h}$ is the mapping to a high dimensional feature space. LS-SVM solves the optimization problem:

$$\begin{aligned} \min_{\mathbf{w}, \mathbf{b}, \mathbf{e}} \quad & \frac{1}{2} \mathbf{w}^T \mathbf{w} + \gamma \frac{1}{2} \sum_{i=1}^N e_i^2 \\ \text{subject to} \quad & y_i = \mathbf{w}^T \phi(\mathbf{x}_i) + \mathbf{b} + e_i, \quad i = 1, \dots, N, \end{aligned} \tag{5.1}$$

where $\gamma > 0$ is a regularization parameter. The associated Lagrangian is:

$$L_\alpha(\mathbf{w}, \mathbf{b}, \mathbf{e}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \gamma \frac{1}{2} \sum_{i=1}^N e_i^2 - \sum_{i=1}^N \alpha_i (\mathbf{w}^T \phi(\mathbf{x}_i) + \mathbf{b} + e_i - y_i).$$

The Karush-Kuhn-Tucker (KKT) conditions for optimality lead to the linear system

$$\begin{bmatrix} 0 & \mathbf{1}_N^T \\ \mathbf{1}_N & \mathbf{Z}^T \mathbf{Z} + \frac{1}{\gamma} \mathbf{I} \end{bmatrix} \begin{bmatrix} \mathbf{b} \\ \alpha \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ y \end{bmatrix},$$

where

$$\mathbf{Z}^T = \begin{bmatrix} \phi(\mathbf{x}_1)^T y_1 \\ \phi(\mathbf{x}_2)^T y_2 \\ \dots \\ \phi(\mathbf{x}_N)^T y_N \end{bmatrix}$$

The resulting LS-SVM model is given by $\hat{y}(\mathbf{x}) = \sum_{i=1}^N \alpha_i K(\mathbf{x}, \mathbf{x}_i) + \mathbf{b}$, where $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$ is the kernel function.

5.4 Results

A cohort of 141 scoliotic shapes data, from teenagers aged between 11 – 18 years old, are considered. A few samples of the data set obtained by the procedure described in Section 5.3.2




Figure 5.4 Samples of scaled data of the preoperative curve (blue) and postoperative curve (red). The data have been scaled to unit length of the distance between the curve endpoints.

are presented in Figure 5.4, where the preoperative back curves (blue) are shown along with the postoperative curves (red).

5.4.1 Validation

The dimensionality reduction methods combined to the LS-SVM regression for the trunk 3D shape prediction are evaluated using the leave-one-out cross-validation procedure. A sample of the data is, in turn, removed from the dataset and used as a test point. The statistical model is trained by using the remaining samples. The prediction procedure is then applied to the test sample. Each sample point is composed of a pair (preoperative and postoperative shapes). The predicted curve can then be compared with the actual postoperative feature curve and a shape prediction error can be computed. Quantitative prediction errors are obtained by computing the distances between corresponding points on the predicted back feature curve and the measured back curve of the postoperative test case. To evaluate our results, we compute the prediction error in terms of the normalized root mean square prediction error, which has the advantage of allowing prediction error to be measured on the same scale for all observations.

5.4.2 Results

The leave-one-out cross validation procedure described in Sections 5.4.1 was conducted on a database of $n = 141$ cases. The prediction errors distribution for the input data, reduced to (25) components, are presented in Figure 5.5 for the dimensionality reduction methods presented in Section 5.3.3. The mean prediction errors are $0.0145(\pm 0.0067)$ for the classical




Figure 5.5 Comparison of the effect of dimensionality reduction methods on the trunk 3D shape prediction using LS-SVR regression. Summary of prediction errors for different dimensionality reduction methods: Box plots of mean prediction errors. The performances are compared in normalized root mean squared error (NRMS) terms. From left to right, Principal Component Analysis, Kernel Principal Component Analysis, Partial Least Squares, Locality Preserving Projection, and Neighborhood Preserving Embedding.

PCA method, $0.0148(\pm 0.0086)$ for the KPCA, $0.0126(\pm 0.0052)$ for the PLS, $0.0149(\pm 0.0071)$

for the LPP and $0.0146(\pm 0.0065)$ for NPE. It appears that the PLS has the best results, on average, for the prediction. From these results it can be seen that the PLS-LSSVM regression has better performances and smaller standard deviations compared to the other methods. An example of the prediction with the PLS-LSSVM regression of postoperative 3D shape is presented in Figure 5.6, where the three-dimensional predicted postoperative curve is overlayed on the postoperative trunk surface mesh, along with the preoperative curve and the actual postoperative back valley curve. As one can notice the 3D shape predicted by the




Figure 5.6 Three-dimensional visualization of the curve shape for an example patient. Overlay of the predicted curves on the actual postoperative trunk surface. preoperative (black), actual postoperative (green) and predicted postoperative with PLS-LSSVR (blue).

PLS-LSSVM regression is close to the actual postoperative shape.

5.5 Discussion

Since the back valley line is an open curve with well identified endpoints, the use of an uniform sampling to define the corresponding points is reasonable. This procedure allows to solve the point correspondence problem which is necessary for the statistical model. The study, conducted on a database of 141 samples pairs, uses a finite set of corresponding points on the trunk feature curves.

The different dimensionality reduction methods appears to perform in a similar way. Unexpectedly, however, the kernel PCA appears to produce less accurate postoperative 3D

shape predictions compared to the classical PCA. This may be due to the difficulties related to the tuning parameters selection in the higher dimension space.

However, the PLS method in particular manages to capture well the relations between the preoperative shape and the postoperative shape compared to the other methods. The PLS exploits the correlation between the input space data and the response data, which explain the better performance obtained on the predictions. It performs a simultaneous decomposition of the input and response with the constraint that these components explain as much as possible of the covariance between input and response data.

The LPP and NPE methods proved to generate results very similar to the PCA and KPCA approaches. It is not surprising to see that the LPP and NPE methods perform on average as good as the classical PCA, since the neighborhood information is exploited in the prediction model. These results support the idea that closer points in the input shape space are expected to behave similarly in the response shape space. However, we believe that a procedure for learning the appropriate distance metric in the trunk shape spaces would improve the accuracy performance of the predictions based on LPP and NPE.

5.6 Conclusion

To date, the statistical approaches to the trunk 3D shapes analysis for the clinical management of scoliosis were mainly aimed at the scoliosis curve types detection and classification. To the best of our knowledge, there exists no previous research reporting on the statistical prediction of the trunk postoperative shape based on the preoperative data for surgically treated patients with scoliosis. In the present paper, we have contributed to the analysis of the trunk surface topography by proposing novel approaches to predict the postoperative trunk 3D shapes of scoliosis patients. The approaches consist in the combination of dimensionality reduction techniques with machine learning based prediction methods. This is the first work on the subject.

The prediction of the postoperative 3D shapes of scoliotic trunks, stated as a regression problem of predicting the positions of a finite set of points of the trunk feature curves knowing their initial positions in preoperative state, has been approached using least squares support vector machine. Different dimensionality reduction techniques in conjunction with the support vector regression have been compared. The accuracy of the prediction errors has been analyzed using the leave-one-out cross-validation. Although, the methods performed similarly on average, the PLS dimensionality reduction appears to provide better results. This study may however have some limitations, in that in particular, anthropometric predictor variables (such as gender, age, body mass index) were not explicitly included.

As a future work, additional landmark-curves will be considered in order to predict the whole trunk surface. Some aspects of the present work will be useful as a complementary data supplier to the framework of the personalized physically-based trunk soft-tissue modeling used for surgery simulation [29] by providing an initial guess of the simulated trunk.

Conflict of interest statement

The authors declare that they have no conflict of interest.

Acknowledgments

This research was funded by the Natural Sciences and Engineering Research Council of Canada. The equipment was financed by the Canadian Foundation for Innovation. Author 1 was supported, in part, by the Fondation Sainte-Justine and Fondation des Étoiles foundations of Sainte-Justine University Hospital Center.

CHAPITRE 6

ARTICLE 3: MODIFIED LARGE MARGIN NEAREST NEIGHBOR METRIC LEARNING FOR REGRESSION

K. C. Assi^{a,b,*}, H. Labelle^b and F. Cheriet^{a,b}, *Member, IEEE*

(a) *École Polytechnique de Montréal, P.O. Box 6097, Succursale Centre-ville,
Montréal, Québec, Canada H3C 3A7*

(b) *Sainte-Justine Hospital Research Center, 3175 Côte-Sainte-Catherine,
Montréal, Québec, Canada H3T 1C5*

6.1 Abstract

The main objective of this letter is to formulate a new approach of learning a Mahalanobis distance metric for nearest neighbor regression from a training sample set. We propose a modified version of the large margin nearest neighbor metric learning method to deal with regression problems. As an application, the prediction of post-operative trunk 3D shapes in scoliosis surgery using nearest neighbor regression is described. Accuracy of the proposed method is quantitatively evaluated through experiments on real medical data.

6.2 Introduction

The k-nearest neighbors (k-NN) rule [70] is one of the oldest and simplest methods in statistical prediction. Nearest neighbor regression consists in assigning to a new data point the response of the most similar in a dataset [73]. In k-NN regression, the output variable is predicted as a weighted average of the k nearest observations in a dataset, where the neighborhood is defined in terms of a chosen distance metric. Applications of k-NN methods range from computer vision, image retrieval and classification, to face recognition [108], speech recognition [109], human activity recognition and pose estimation, text analysis, and wireless sensor networks [110].

One of the key point in nearest neighbor based methods is to define a distance measure in the input space to identify nearest neighbors, and this mostly depends on the domain application. The default distance metric often used is the Euclidean distance. However ideally, each application requires a specific adapted distance metric since nearest neighbor methods have been demonstrated to have improved performance when used with a learned appropriate distance metric from a sample examples. One of the most learned metric is the Mahalanobis distance, and one of the most widely used Mahalanobis distance learning methods for k-NN

classification is the large margin nearest neighbor (LMNN) proposed by Weinberger et al. [75, 77]. Other metric learning methods for classification have also been proposed by different researchers such as adaptive metric nearest neighbor (ADAMENN) [78], and discriminant adaptive nearest neighbor (DANN) [79]. However these approaches have the disadvantage of requiring more than one parameter to be tuned, which make them less attractive compared to LMNN. The LMNN method has since been extended to other distances, for example in the χ^2 -LMNN [111] where the χ^2 histogram distance is used in place of the Mahalanobis distance. Unfortunately most of the metric learning for k-NN approaches are essentially designed for classification problems [112]. Although nearest neighbors regression play an important role in statistical prediction [72], to the best of our knowledge, very few metric learning methods were proposed for nearest neighbor regression problems. The k-NN regression gives fairly similar performance as linear regression with respect to the average RMSEs in some applications, and it would be interesting to design an appropriate metric learning algorithm for k-NN regression.

In this letter, we propose a metric learning method for k-NN regression. We extend the LMNN method proposed in [75, 77] to the case of nearest neighbor regression. Although based on the same framework, however, our method introduces new features to deal with the specific case of regression, which otherwise can not be addressed in the classical LMNN. We then apply our model to the nearest neighbor prediction of postoperative 3D trunk shapes of scoliotic patients.

6.3 Modified large margin nearest neighbor metric learning

Let $D_n = \{z_i = (\mathbf{x}_i, \mathbf{y}_i) : \mathbf{x}_i \in \mathcal{X}, \mathbf{y}_i \in \mathcal{Y}, i = 1, \dots, n\}$ be a dataset where $\mathcal{X}$ and $\mathcal{Y}$ are some metric spaces. We will refer to $\mathcal{X}$ and $\mathcal{Y}$ as the input and response space, respectively. The desired properties of distance metrics for regression are expressed as follows. Intuitively, in order to reduce regression prediction error, one may wish that two inputs $\mathbf{x}_i$ and $\mathbf{x}_j$ are close one to another in the input space if their respective responses $\mathbf{y}_i$ and $\mathbf{y}_j$ are also close one to another in the response space. More specifically, we would like, for any triplet of pairs $(\mathbf{x}_i, \mathbf{y}_i)$, $(\mathbf{x}_j, \mathbf{y}_j)$, $(\mathbf{x}_l, \mathbf{y}_l)$, if $\mathbf{x}_i$ is much closer to $\mathbf{x}_j$ than to $\mathbf{x}_l$ with respect to a distance $\delta_{\mathcal{X}}$ defined on $\mathcal{X}$ then it is likely $\mathbf{y}_i$ is much closer to $\mathbf{y}_j$ than to $\mathbf{y}_l$ with respect to a chosen error distance $\delta_{\mathcal{Y}}$ in the response space. In this case, the proximity order of the triplet is preserved.

6.3.1 Intuition of our modified LMNN

We base our model on the following intuitions to insure an accurate nearest neighbor regression: (i) each training input $\mathbf{x}_i$ and its k nearest neighbors should preserve proximity order,




Figure 6.1 Illustration of the intuition behind the modified LMNN metric learning for regression. The point $\mathbf{x}_j$ is referred to as the target neighbor. The point $\mathbf{x}_l$ is referred to as an impostor since it violates the proximity order preservation (in this case). The training consists in finding a learned metric $\delta_{\mathcal{X}}$ such that: (1) the target neighbor is pushed closer to the input query point within a smaller radius after training, (2) impostor is pushed outside the smaller radius domain by a finite margin.

(ii) for a given triplet $(\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_l)$, training inputs $\mathbf{x}_l$ that violate proximity order should be widely separated from $\mathbf{x}_i$ in such a way that proximity order is restored. Borrowing from the same terminology as in [75], for an input $\mathbf{x}_i$ with response $\mathbf{y}_i$ and target neighbor¹ $\mathbf{x}_j$, we call an impostor any input $\mathbf{x}_l$ with response $\mathbf{y}_l$ such that

$$\begin{cases} \delta_{\mathcal{Y}}(\mathbf{y}_i, \mathbf{y}_l) > \delta_{\mathcal{Y}}(\mathbf{y}_i, \mathbf{y}_j) \\ \delta_{\mathcal{X}}(\mathbf{x}_i, \mathbf{x}_l) \leq \delta_{\mathcal{X}}(\mathbf{x}_i, \mathbf{x}_j) + \epsilon, \end{cases} \quad (6.1)$$

where $\epsilon > 0$ is the margin. Specifically, an impostor $\mathbf{x}_l$ is any input violating proximity order and that invades the perimeter within a ϵ -margin defined by any target neighbor $\mathbf{x}_j$ of the input $\mathbf{x}_i$. We aim to learn a linear transformation of the input space such that the training inputs satisfy the above mentioned properties. Figure 6.1 illustrates the main idea behind our modified LMNN metric learning for regression. This is a regression oriented adaptation of the idealized error reduction scenario of the classical LMNN [75]. It shows how nearest neighbor regression errors in the original input space are corrected by learning an appropriate linear transformation. Before learning, a training input has both target neighbor and impostor in its local neighborhood. During learning, the impostor is pushed outside the perimeter established by the target neighbor. After learning, the mapped inputs points are such that there exists a finite margin between the perimeter and the impostor, and proximity order in both input and response spaces is restored. From the way they are presented, these

¹Target neighbors are selected by using prior knowledge (if available) or by simply computing the k nearest neighbors using Euclidean distance [75].

ideas can be cast into the framework of the large margin nearest neighbor and be stated as two competing terms in our model's loss function, where one term penalizes large distances between nearby inputs that preserve proximity order, while the other term penalizes small distances between inputs which violate proximity order.

6.3.2 Proximity order preservation indicator

The key point of our metric learning approach for regression problems is the introduction of the proximity order preservation concept. Let us define the proximity order function $F_{\mathcal{M}, \delta_{\mathcal{M}}}$ for a metric space $\mathcal{M}$ equipped with the distance $\delta_{\mathcal{M}}$, as for $\tau_{ijl} = (u_i, u_j, u_l) \in \mathcal{M}^3$,

$$F_{\mathcal{M}, \delta_{\mathcal{M}}}(\tau_{ijl}) = \delta_{\mathcal{M}}(u_i, u_j) - \delta_{\mathcal{M}}(u_i, u_l).$$

For the triplets of pairs of input and response $((\mathbf{x}_i, \mathbf{y}_i), (\mathbf{x}_j, \mathbf{y}_j), (\mathbf{x}_l, \mathbf{y}_l))$, we denote $\mathbf{t}_{ijl} = (\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_l)$ and $\mathbf{t}_{ijl}^* = (\mathbf{y}_i, \mathbf{y}_j, \mathbf{y}_l)$ as the triplets in $\mathcal{X}$ and $\mathcal{Y}$, respectively. Let us define the triplets labeling function Π as:

$$\Pi_{\mathcal{Y}, \delta_{\mathcal{Y}}}(\mathbf{t}) := \begin{cases} 1 & \text{if } F_{\mathcal{Y}, \delta_{\mathcal{Y}}}(\mathbf{t}^*) \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (6.2)$$

The function $\Pi_{\mathcal{Y}, \delta_{\mathcal{Y}}}$ assigns 0/1 labels to triplets $(\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_l)$ based on a chosen distance $\delta_{\mathcal{Y}}$ used for measuring errors in the response space $\mathcal{Y}$. Let $\mathcal{C}_{\delta_{\mathcal{X}}}$ be a function on triplets of $\mathcal{X}$ associated to distance $\delta_{\mathcal{X}}$ defined as :

$$\mathcal{C}_{\delta_{\mathcal{X}}}(\mathbf{t}) := \begin{cases} 1 & \text{if } F_{\mathcal{X}, \delta_{\mathcal{X}}}(\mathbf{t}) \geq 0 \\ 0 & \text{otherwise} \end{cases} \quad (6.3)$$

We introduce the proximity order preservation indicator ν_{ijl} , as

$$\nu_{ijl} = \nu(\mathbf{t}_{ijl}) = \mathcal{C}_{\delta_{\mathcal{X}}^{(0)}}(\mathbf{t}_{ijl}) \Pi_{\mathcal{Y}, \delta_{\mathcal{Y}}}(\mathbf{t}_{ijl}). \quad (6.4)$$

Note that ν_{ijl} is equal to 1 only if the proximity order of the triplet is preserved. A k-NN regression using a distance $\delta_{\mathcal{X}}$ with a lower rate of proximity order violation is likely to have a better accuracy performance (See Appendix, Proposition 1 and Corrolary 1). We use this to define a cost term that penalizes small distances between input points which violate the proximity order.

6.3.3 Loss function

Given a training set of features $\mathbf{x}_i$ along with their response $\mathbf{y}_i$ with $(\mathbf{x}_i, \mathbf{y}_i) \in \mathbb{R}^{\dim_1} \times \mathbb{R}^{\dim_2}$, ($i = 1, \dots, n$), we are interested in learning a Mahalanobis distance metric parameterized by a linear transformation $\mathbf{L}$, i.e.

$$D_{\mathbf{L}}(\mathbf{x}_i, \mathbf{x}_j) = \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|^2 = (\mathbf{x}_i - \mathbf{x}_j)^\top \mathbf{L}^\top \mathbf{L} (\mathbf{x}_i - \mathbf{x}_j), \quad (6.5)$$

which allows an accurate nearest neighbor regression. The parameter matrix $\mathbf{L}$ is to be chosen such as to minimize the distance between the mappings of a vector and its k nearest neighbors

$$\mathcal{E}_1(\mathbf{L}) = \sum_{ij} \eta_{ij} \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|^2, \quad (6.6)$$

where η_{ij} is given by

$$\eta_{ij} = \begin{cases} 1 & \text{if } j \text{ is a target neighbor of } i \\ 0 & \text{otherwise.} \end{cases}$$

The parameter $\mathbf{L}$ should also allow that the distance of $\mathbf{x}_i$ from a target neighbor $\mathbf{x}_j$ be less than its distance from an incorrect neighbor $\mathbf{x}_l$ (referred to as an impostor). To this end, we use ν_{ijl} in (6.4) and consider minimizing a hinge loss over triplets of input vectors

$$\mathcal{E}_2(\mathbf{L}) = \sum_{ijl} \eta_{ij}(1 - \nu_{ijl}) \left[\epsilon + \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_j)\|^2 - \|\mathbf{L}(\mathbf{x}_i - \mathbf{x}_l)\|^2 \right]_+, \quad (6.7)$$

where $[z]_+ = \max\{z, 0\}$, and ϵ is the margin. We end up with a total cost function $\mathcal{E}(\mathbf{L})$ that combines the two competing terms $\mathcal{E}_1$ and $\mathcal{E}_2$ using a weight parameter $\mu \in (0, 1)$:

$$\mathcal{E}(\mathbf{L}) = (1 - \mu)\mathcal{E}_1(\mathbf{L}) + \mu\mathcal{E}_2(\mathbf{L}). \quad (6.8)$$

Since $\mathbf{M} = \mathbf{L}^\top \mathbf{L} \succeq 0$, and by introducing a nonnegative slack variables ξ_{ijl} for each triplet, the minimization of the cost function $\mathcal{E}(\mathbf{L})$ can be formulated as a convex semidefinite pro-

gramming problem (SDP),

$$\begin{aligned}
& \underset{\mathbf{M}, \xi}{\text{minimize}} && (1 - \mu) \sum \eta_{ij} (\mathbf{x}_i - \mathbf{x}_j)^\top \mathbf{M} (\mathbf{x}_i - \mathbf{x}_j) \\
& && + \mu \sum_{ijl} \eta_{ij} (1 - \nu_{ijl}) \xi_{ijl} \\
& \text{subject to} && (\mathbf{x}_i - \mathbf{x}_l)^\top \mathbf{M} (\mathbf{x}_i - \mathbf{x}_l) \\
& && - (\mathbf{x}_i - \mathbf{x}_j)^\top \mathbf{M} (\mathbf{x}_i - \mathbf{x}_j) \geq \epsilon - \xi_{ijl}, \\
& && \xi_{ijl} \geq 0, \\
& && \mathbf{M} \succeq 0.
\end{aligned} \tag{6.9}$$

The SDP problem (6.9) resulting from our formulation has the same form as the one proposed by Weinberger *et al.* [75] for their LMNN. However there are some differences in the terms involved, in particular the introduction of the proximity order preservation indicator ν_{ijl} (6.4) in the loss function. Equation (6.9) addresses nearest neighbor regression problems, whereas [75] aimed to solve only nearest neighbor classification problems.

6.4 Results

Applications to prediction of scoliotic trunk 3D shapes after spine surgery using nearest neighbor (NN) regression were conducted. For the experiments, some characteristic feature curves of the human scoliotic trunk surface topography were considered. The so-called back valley curves were extracted on preoperative and postoperative trunk surfaces. The shape of this feature curve almost follows that of the spine, but is also influenced by the muscle surrounding the spine and supporting the trunk in the upright posture. The upper and lower end points of the curve are anatomical landmarks corresponding to the spinous process of C7 (seventh cervical vertebra) and L5 (the fifth lumbar vertebra), respectively. This feature curve has the advantage of capturing the changing taking place in the back from the preoperative to the postoperative state. It is indeed the feature curve on the trunk surface whose shape change is the most directly influenced by a spine surgery instrumentation. Figure 6.2 (Left) shows the back valley curve along the spinous processes of a scoliotic patient in the preoperative (red) and the postoperative (blue) status overlayed on the patient postoperative trunk mesh. The associated deformation field is depicted on Figure 6.2 (Right). A dataset of 141 pairs of scoliotic shapes data, from teenagers aged between 11 – 18 years old, is considered. Our proposed Mahalanobis distance metric learning is evaluated using the leave-one-out cross-validation procedure. Each sample point is composed of a pair (the preoperative and postoperative shapes). The predicted curve can then be compared with




Figure 6.2 Left: Overlaid back valley curves (preoperative (blue) and postoperative (red)) on a patient surface mesh. Right: Displacement vector field along the back valley curve from preoperative to postoperative state.

the actual postoperative feature curve and a shape prediction error can be computed. To evaluate our results, we compute the prediction error in terms of the normalized root mean square prediction error, which has the advantage of allowing prediction error to be measured on the same scale for all observations. Quarter polar plots are used to visualize pointwise prediction errors along the back valley curve. The radius represents errors values while the angles θ (or the points along the arc) correspond each to the location of points along the back valley curve, where $\theta = 0$ is the bottom endpoint and $\theta = 90$ is the upper endpoint. The error unit is relative to the span of the spine, which is set to 1 after a common rigid registration of all trunk shapes data. Distances with better performances have errors graph closer to the origin point of the polar plot.

The proposed learned metric is compared with two other metrics: the default Euclidean distance and an arbitrary Mahalanobis metric which is defined by a random semidefinite positive matrix. The quarter polar plots of the mean errors are presented in Figure 6.3. The mean errors for the learned Mahalanobis are less than the ones for the Euclidean and arbitrary Mahalanobis metrics, all along the back valley, with a maximum mean error (0.043) attained around the mid-level of the trunk for the learned Mahalanobis and a maximum of 0.055, 0.056 for the Euclidean and arbitrary Mahalanobis respectively attained around the mid-lumbar level. A maximum error difference between the learned Mahalanobis and the Euclidean distance is found around the mid-lumbar level (MLL). The mean prediction error at the MLL level decreased significantly (0.016) between NN prediction using the Euclidean metric (Mean $\pm$ SD: 0.0531 ± 0.037 , $N = 141$) and prediction using learned Mahalanobis metric (Mean $\pm$ SD: 0.0371 ± 0.0213 , $N = 141$), (two-sample t-test assuming equal variance [113], $p < 0.001$). It appears that the NN regression using our learned Mahalanobis metric




Figure 6.3 Quarter polar plots of the mean pointwise prediction errors distribution along the back valley curve of $N = 141$ scoliotic patients. (a) Red: Learned Mahalanobis metric, (b) Green: Arbitrary Mahalanobis metric, (c) Black: Euclidean metric.

has the lower errors, on average, for the nearest neighbor regression prediction.

We cast our metric learning for nearest neighbor regression as the SDP problem (6.9), which has the same form as the classical LMNN formulation. However, it is important to mention the main differences. Weinberger et al.'s LMNN was aimed to solve k-NN classification problems and for that the second term of their loss function contains an indicator (y_{il}) which expresses whether or not target neighbors have the same label (i.e $y_{il} = 1$ if and only if $y_i = y_l$ and, $y_{il} = 0$ otherwise). This indicator is no longer relevant in the case of a k-NN regression problem since the response space is continuous, and had to be replaced by some other appropriate relevant indicator. Here in our formulation, we make use of a triplet indicator ν_{ijl} which expresses whether or not proximity order, under the distance used, between target neighbors is preserved from the input space to the response space. This indicator is fixed during the learning process for a given training set, and has the advantage of allowing us to keep the same form of the metric learning SDP as LMNN in [75], while at the same time allowing to deal with regression. Our proposed modified LMNN metric learning method produces a Mahalanobis metric that outperforms the Euclidean metric for nearest neighbor regression on scoliotic trunk 3D shapes data.

6.5 Conclusion

In this letter, we have presented a new metric learning method for regression. The proposed method is an extension of the large margin nearest neighbor metric learning method to tackle nearest neighbor regression problems. It has been successfully applied to the prediction of

3D trunk shapes data, and the learned metric has significantly improved the accuracy of the prediction compared to the default Euclidean metric. The modified LMNN described here could also be applied to general functional nearest neighbor regression.

APPENDIX: Risk of a distance metric for nearest neighbor regression

In nearest neighbor regression, the response estimate $\tilde{\mathbf{y}} \in \mathcal{Y}$ of a new data point $\mathbf{x} \in \mathcal{X}$, is given by

$$\tilde{\mathbf{y}} = r_{\text{NN}_{\delta_{\mathcal{X}}}}(\mathbf{x}) = \mathbf{y}_{k:\mathbf{x}_k = \text{NN}_{\delta_{\mathcal{X}}}(\mathbf{x})}, \quad (6.10)$$

where $\text{NN}_{\delta_{\mathcal{X}}}(\mathbf{x})$ denotes the nearest neighbor of $\mathbf{x}$ in $D_n^{\mathcal{X}} = \{\mathbf{x}_i : (\mathbf{x}_i, \mathbf{y}_i) \in D_n, i = 1, \dots, n\}$ with respect to the distance $\delta_{\mathcal{X}}$. Let $(X_0, Y_0) \in D_n$ such that X_0 is the true nearest neighbor of X in $D_n^{\mathcal{X}}$ with respect to $\delta_{\mathcal{X}}$. We define the error $\text{err}_{\text{NN}_{\delta_{\mathcal{X}}}}(X, Y) = \delta_{\mathcal{Y}}(Y, r_{\text{NN}_{\delta_{\mathcal{X}}}}(X)) = \|Y - r_{\text{NN}_{\delta_{\mathcal{X}}}}(X)\|$. We are interested in selecting a distance $\delta_{\mathcal{X}}$ to reduce the expected error $\mathbb{E}[\text{err}_{\text{NN}_{\delta_{\mathcal{X}}}}]$. From the initial dataset D_n , one can derive a dataset $\mathcal{D}$ of $\{0, 1\}$ -labeled triplets

$$\begin{aligned} \mathcal{D} = \{s = (\mathbf{t}_{ijl}, \lambda_{ijl}) \in \mathcal{X}^3 \times \{0, 1\}, \\ \mathbf{t}_{ijl} = (\mathbf{x}_i, \mathbf{x}_j, \mathbf{x}_l), \lambda_{ijl} = \Pi_{\mathcal{Y}, \delta_{\mathcal{Y}}}(\mathbf{t}_{ijl})\}. \end{aligned} \quad (6.11)$$

When $\mathcal{C}_{\delta_{\mathcal{X}}}(\mathbf{t}) \neq \lambda$, a violation of the proximity order occurs. The loss function for the distance $\delta_{\mathcal{X}}$ is defined for $s = (\mathbf{t}, \lambda) \in \mathcal{X}^3 \times \{0, 1\}$ as

$$\ell(\delta_{\mathcal{X}}, s) = \mathbf{1}_{\{\mathcal{C}_{\delta_{\mathcal{X}}}(\mathbf{t}) \neq \lambda\}} = 1 - \nu_{\mathbf{t}}, \quad (6.12)$$

where $\nu_{\mathbf{t}} = \mathcal{C}_{\delta_{\mathcal{X}}}(\mathbf{t})\Pi_{\mathcal{Y}, \delta_{\mathcal{Y}}}(\mathbf{t})$ is obtained from (6.4). The risk of a distance $\delta_{\mathcal{X}}$ is then defined as the expected loss :

$$R(\delta_{\mathcal{X}}) = \mathbb{E}[\ell] = \mathbb{P}_{s=(\mathbf{t}, \lambda) \sim P'}\{\mathcal{C}_{\delta_{\mathcal{X}}}(\mathbf{t}) \neq \lambda\}. \quad (6.13)$$

The key property of distances supporting our metric learning approach is: the lower the proximity order violation rate, the better the nearest neighbor regression. Let us illustrate this idea on a single triplet. Consider the three points sample set $D_3 = \{(\mathbf{x}_0, \mathbf{y}_0), (\mathbf{x}_1, \mathbf{y}_1), (\mathbf{x}_2, \mathbf{y}_2)\}$, and let $s_0 = (\mathbf{t}_{012}, \lambda_{012})$, with $\mathbf{t}_{012} = (\mathbf{x}_0, \mathbf{x}_1, \mathbf{x}_2)$ and $\lambda_{012} = 1$. Without loss of generality, let us choose $(\mathbf{x}_0, \mathbf{y}_0)$ as the test point. Suppose that $\delta_{\mathcal{X}}^{(1)}$ and $\delta_{\mathcal{X}}^{(2)}$ are two distances in $\mathcal{X}$ such that $\ell(\delta_{\mathcal{X}}^{(1)}, s_0) = 0$ and $\ell(\delta_{\mathcal{X}}^{(2)}, s_0) = 1$, i.e., $\ell(\delta_{\mathcal{X}}^{(1)}, s_0) < \ell(\delta_{\mathcal{X}}^{(2)}, s_0)$. In this case, $r_{\text{NN}_{\delta_{\mathcal{X}}^{(1)}}}(\mathbf{x}_0) = \mathbf{y}_1$, $r_{\text{NN}_{\delta_{\mathcal{X}}^{(2)}}}(\mathbf{x}_0) = \mathbf{y}_2$ and $\text{err}_{\text{NN}_{\delta_{\mathcal{X}}^{(1)}}}(\mathbf{x}_0, \mathbf{y}_0) = \|\mathbf{y}_0 - \mathbf{y}_1\| < \|\mathbf{y}_0 - \mathbf{y}_2\| = \text{err}_{\text{NN}_{\delta_{\mathcal{X}}^{(2)}}}(\mathbf{x}_0, \mathbf{y}_0)$. This property is formally stated as:

Proposition 1. *Let $\delta_{\mathcal{X}}^{(1)}$ and $\delta_{\mathcal{X}}^{(2)}$ be two distances in $\mathcal{X}$ with risk $R(\delta_{\mathcal{X}}^{(1)})$ and $R(\delta_{\mathcal{X}}^{(2)})$ respec-*

tively, such that $R(\delta_{\mathcal{X}}^{(1)}) < R(\delta_{\mathcal{X}}^{(2)})$. Then

$$\mathbb{E}[\text{err}_{\text{NN}_{\delta_{\mathcal{X}}^{(1)}}}] < \mathbb{E}[\text{err}_{\text{NN}_{\delta_{\mathcal{X}}^{(2)}}}]. \quad (6.14)$$

The best distance $\delta_{\mathcal{X}}$ in $\mathcal{X}$ is the one with minimum risk. The minimum risk distance δ^* is

$$\delta^* = \arg \inf_{\delta_{\mathcal{X}}} R(\delta_{\mathcal{X}}). \quad (6.15)$$

and

Corollary 1. *For all $\delta_{\mathcal{X}} \in D$,*

$$\mathbb{E}[\text{err}_{\text{NN}_{\delta^*}}] \leq \mathbb{E}[\text{err}_{\text{NN}_{\delta_{\mathcal{X}}}}]. \quad (6.16)$$

Minimizing the distance risk may allow us to design a metric learning method for regression.

CHAPITRE 7

MÉTHODOLOGIE ET RÉSULTATS COMPLÉMENTAIRES: RÉGRESSION PROCHE VOISIN POUR LA PRÉDICTION DE TRONC POSTOPÉRATOIRE

Dans le chapitre 4, nous avons présenté une méthode de simulation de l'apparence postopératoire du tronc scoliotique basée sur la physique. L'un des ingrédients de base de cette méthode est de disposer de la configuration osseuse ciblée en postopératoire: celle-ci est sensée être fournie par un autre simulateur [114]. Dans le présent chapitre, nous présentons une nouvelle méthodologie de prédiction du champ de déformations du tronc, pouvant entre autres servir à produire une approximation de la forme du tronc postopératoire et une approximation de la configuration osseuse cible. Les informations contenues dans un ensemble de données de troncs scoliotiques sont prises en compte pour obtenir une surface externe postopératoire par une approche de régression par proche-voisin.

7.1 Prédiction de forme utilisant la régression par proche voisin

Soit $\mathcal{X}$ et $\mathcal{Y}$ deux espaces métriques. Le modèle général standard de régression, pour des données $(\mathbf{x}_i, y)_{i=1, \dots, n}$ ($\mathbf{x}_i \in \mathcal{X}$, $y \in \mathcal{Y}$), peut être écrit comme suit:

$$\begin{aligned} r : \mathcal{X} &\rightarrow \mathcal{Y} \\ y &= r(\mathbf{x}) + \epsilon \end{aligned} \quad \text{avec} \quad \mathbb{E}(\epsilon|\mathbf{x}) = 0. \tag{7.1}$$

L'objet que nous désirons estimer est l'opérateur nonlinéaire

$$r(.) = \mathbb{E}(Y|X = .). \tag{7.2}$$

L'algorithme du proche voisin est l'un des exemples les plus simples parmi les méthodes nonparamétriques pour la régression :

$$\tilde{y} = y_{k:\mathbf{x}_k = NN_{d_{\mathcal{X}}}(\mathbf{x})},$$

où $NN_{d_{\mathcal{X}}}(\mathbf{x})$ désigne le plus proche voisin de $\mathbf{x}$ dans $D_n^{\mathcal{X}} = \{\mathbf{x}_i : (\mathbf{x}_i, y_i) \in D_n, i = 1, \dots, n\}$ par rapport à la distance $d_{\mathcal{X}}$ définie sur $\mathcal{X}$.

7.1.1 Prédiction de forme 3D de tronc postopératoire

Nous considérons que l'état de forme du tronc en posture debout est entièrement décrit par la paire $\Sigma = (\Sigma_0, \Sigma_1)$ où Σ_0 représente la structure osseuse, et Σ_1 la surface externe du tronc (Fig.7.1). Considérons la paire $z = (\Sigma, \Sigma')$ de formes de troncs préopératoire Σ et postopéra-




Figure 7.1 Représentation du tronc en posture debout. Σ_1 : surface externe. Σ_0 : structures osseuses.

toire Σ' (où $\Sigma = (\Sigma_0, \Sigma_1)$ et $\Sigma' = (\Sigma'_0, \Sigma'_1)$ sont des paires de géométries du tronc, avec l'indice 0 référant à la structure osseuse et l'indice 1 à la surface externe). Soit $\mathbf{D}_z^N$ l'ensemble de données de formes de troncs : $\mathbf{D}_z^N = \{z_n, n = 1, \dots, N\}$, où $z_n = (\Sigma^{(n)}, \Sigma'^{(n)})$, avec $\Sigma^{(n)} = (\Sigma_0^{(n)}, \Sigma_1^{(n)})$ et $\Sigma'^{(n)} = (\Sigma'_0^{(n)}, \Sigma'_1^{(n)})$. Pour un point $z_i = (\Sigma^{(i)}, \Sigma'^{(i)})$, $i \in \{1, \dots, N\}$, correspondant au patient i , soit $\phi_0^{(i)} \in \mathcal{D}_\phi^0$, $\phi_1^{(i)} \in \mathcal{D}_\phi^1$ désignant les déformations telles que :

$$\begin{aligned}\Sigma'_1{}^{(i)} &= \phi_1^{(i)}(\Sigma_1^{(i)}) + \epsilon', \\ \Sigma'_0{}^{(i)} &= \phi_0^{(i)}(\Sigma_0^{(i)}) + \epsilon,\end{aligned}\tag{7.3}$$

où ϵ et ϵ' sont des bruits (de moyenne nulle). Le principe du modèle de la relation entre les formes préopératoires et postopératoires est illustré dans la figure Fig.7.2. La déformation $\phi_1^{(i)}$ est entièrement définie par un champ de vecteurs déplacement $v_{1,(i)}^{\alpha_{1,(i)}}$ qui à son tour est paramétré par un ensemble fini de vecteurs déplacement $\alpha_{1,(i)}$ définis à des points repères. Soit $\mathbf{D}_\alpha^N$ l'ensemble de paires de vecteurs paramètres associé aux déformations $\phi_0^{(i)}$ et $\phi_1^{(i)}$: $\mathbf{D}_\alpha^N = \{(\alpha_{0,(i)}, \alpha_{1,(i)}), i = 1, \dots, N\}$. Étant donné un ensemble d'apprentissage $\{(\Sigma^{(k)}, \Sigma'^{(k)})_{k=1, \dots, N}\}$, l'on peut dériver et stocker l'ensemble $\mathbf{D}_\alpha^N$ de paramètres de déformations de formes. Nous introduisons l'espace de déformations de formes $\mathcal{D}_\phi^1$ dans notre cadre




Figure 7.2 Diagramme de déformations de formes du tronc. Σ_0 et Σ_1 sont vues comme des structures couplées.

théorique afin de décrire notre algorithme de prédiction basé sur le proche voisin. La Figure 7.3 résume le processus de prédiction de forme du tronc, où $\mathcal{X}$, $\mathcal{Y}$ sont les espaces de formes de troncs préopératoire et postopératoire, respectivement. Supposons que l'on nous




Figure 7.3 Régression des champs de déformation de formes du tronc.

présente un nouveau patient avec une forme externe préopératoire $\Sigma_1^{(new)}$, et la forme externe

postopératoire $\Sigma_1'^{(\text{new})}$ est à prédire. La déformation réelle ϕ_1 est inconnue, mais doit être estimée pour la prédiction. Le processus d'apprentissage prend place dans $\mathcal{X} \times \mathcal{D}_\phi^1$. Supposons que Σ_1 est le plus proche voisin de $\Sigma_1^{(\text{new})}$. Alors, l'estimé par proche voisin de la déformation ϕ_1 est: $\hat{\phi}_1 = \phi_{\alpha_1}$. La déformation estimée est ensuite appliquée à la forme préopératoire pour obtenir la prédiction:

$$\tilde{\Sigma}_1'^{(\text{new})} = \hat{\phi}_1(\Sigma_1^{(\text{new})}).$$

Notons qu'un estimé de $\hat{\phi}_0$ s'obtient de la même manière, si l'on s'intéresse à une approximation de la configuration osseuse postopératoire cible. Nous pouvons maintenant énoncer l'algorithme de prédiction de forme de tronc par regression proche voisin de la façon suivante

Algorithm 1 Prédiction de forme de tronc postopératoire utilisant la régression par le plus proche voisin

1: **INPUT** :

- a) Dataset $\mathbf{D}_z^N$,
- b) 1-NN regresser (w.r.t distance function $d_{\mathcal{X}}^0$),
- c) Query: new patient $z_{\text{new}} = (\Sigma^{(\text{new})}, \Sigma'^{(\text{new})})$, where $\Sigma^{(\text{new})}$, is known, $\Sigma'^{(\text{new})}$ is unknown.

2: **OUTPUT**: $\Sigma_1'^{(\text{new})}$

3: **BEGIN**

4: From $\mathbf{D}_z^N$, Derive $\mathbf{D}_\alpha^N = \{(\alpha_{0,(i)}, \alpha_{1,(i)}), i = 1, \dots, N\}$

5: Estimate deformation $\phi_1^{(\text{new})}$ by using 1-NN,

6: Compute $\tilde{\Sigma}_1'^{(\text{new})} \leftarrow \phi_1^{(\text{new})}(\Sigma_1^{(\text{new})})$

7: Return $\tilde{\Sigma}_1'^{(\text{new})}$

8: **END**

Les méthodes proches voisins nécessitent la définition de distance dans les espaces mis en jeu. Une distance pour l'espace de formes de troncs scoliotiques est proposée dans le Chapitre 6.

7.2 Expériences

Le protocole d'acquisition de données de géométries de troncs est décrite dans [106, 88] mais est résumé ici. La géométrie de surface du tronc est acquise en utilisant un système calibré composé de quatre numériseurs optiques, chacun équipé d'une caméra CCD et d'un projecteur de lumière structurée, disposés autour du patient. Les structures osseuses du tronc sont reconstruites à partir d'images radiographiques. Les géométries externes et internes

sont ensuite recalées et ramenées dans un système de référence commun. Les expériences de prédiction de formes de troncs postopératoires ont été réalisées sur l'ensemble de données médicales en utilisant notre algorithme de regression par proche voisin. Puisque les données préopératoires et postopératoires de patients scoliotiques sont disponibles, il est possible de réaliser une mesure de la performance en précision de la prédiction.

7.3 Résultats

Un ensemble de données ($N = 5$) de formes de troncs d'adolescents âgés entre 14 et 16 ans avec courbure thoracique droite est considéré, dont trois sont montrées dans la Figure 7.4. La rangée de haut (Figure 7.4) correspond aux formes de troncs préopératoires et la rangée de bas aux formes 3D postopératoires. Les apparences externes avant chirurgie sont très différentes. Elles apparaissent comme améliorées après chirurgie, et une inspection qualitative suggère que l'issue du patient B est plus proche de celle de C que de A . Les courbes BSR correspondantes pour les formes de troncs sont montrées dans la figure Fig. 7.4 (colonne de droite).

Les résultats de prédiction de forme de tronc postopératoire utilisant la régression par proche-voisin sont montrés dans la Figure 7.5. La colonne de gauche correspond à la surface du tronc préopératoire, la colonne du milieu à la surface postopératoire réelle, et la colonne de droite donne la surface de tronc prédite. La forme prédite est qualitativement en accord avec la surface postopératoire réelle. La surface du tronc post-chirurgical est quantitativement comparée à la surface prédite, et la Figure 7.6 donne à la fois une vue qualitative et quantitative de la précision de la prédiction. L'erreur de prédiction est approchée en chaque point de la surface par la distance au point projeté sur l'autre surface (erreur point-à-surface). La visualisation de l'erreur (Figure 7.6) est obtenue en coloriant les erreurs ponctuelles sur la surface postopératoire prédite. Les erreurs sur le côté de la région lombaire, les clavicules, les homoplates et les régions des seins sont communes à tous les cas. Les indices de BSR pour le même patient, à différents niveaux du tronc, sont montrés dans la Figure 7.7. On peut noter que la forme prédite du tronc est quantitativement proche de la forme réelle du tronc postopératoire.

Le tableau Table 7.1 présente la performance de précision de notre algorithme de prédiction par proche voisin, obtenue avec l'ensemble de données décrit en Section 7.2. Les statistiques de l'erreur de prédiction mesurées comme l'écart entre l'indice de rotation de la surface du dos (BSR) du tronc prédit et celui de la surface réelle de tronc postopératoire à différents niveaux vertébraux sont montrées dans le tableau Table 7.1. Les mesures ont été réalisées en utilisant l'évaluation par la validation croisée *leave-one-out* pour la régression par proche voisin. La moyenne d'erreur de prédiction s'étend de 0.6° à 4.8° .




Figure 7.4 Formes 3D de tronc de trois patients scoliotiques: rangée de haut: données préopératoires, rangée de bas: données postopératoires. La colonne de droite représente les courbes *BSR* des tronc préopératoire et postopératoire: (i) 1 (bleu) pour le patient de la colonne de gauche, (ii) 2 (rouge) pour le patient de la colonne du milieu, et (iii) 3 (noir) pour le patient de la colonne de droite.




Figure 7.5 Comparaison de formes de troncs prédites et réelles: (a) colonne de gauche: surface préopératoire, (b) colonne de milieu: surface réelle postopératoire, (c) colonne de droite: surface postopératoire prédite.




Figure 7.6 Mesure d'erreur de prédiction par la distance point-à-surface entre le tronc postopératoire réelle et le tronc prédit.

7.4 Discussion

Les indices de BSR entre les niveaux vertébraux $T4$ et $L4$ ont été considérés pour une analyse quantitative de la qualité de la prédiction des formes de troncs postopératoires. Bien




Figure 7.7 Indice de rotation de la surface du dos mesuré sur le tronc postopératoire réel et sur la surface prédite, pour un patient.

que l'indice BSR ne décrit pas tous les détails de la forme du tronc, il renferme quantitativement des caractéristiques importantes de l'asymétrie du tronc scoliotique en plus d'être un indice clinique pertinent. Dans ce présent chapitre, nous avons utilisé une approche basée sur le principe de la prédiction par proche voisin pour la détermination d'une approximation du champ de déformations du tronc. Ce champ peut aussi bien servir pour prédire la forme externe de la surface du tronc, mais aussi pour obtenir un estimé d'une configuration de la structure osseuse postopératoire cible pour le simulateur au chapitre 4. En ce qui concerne la performance générale de la prédiction, il faut mentionner que le nombre réduit de données considérées ici rend difficilement significatif, au point de vue statistique, les précisions obtenues. Aussi, on peut remarquer que l'orientation des épaules et de l'avant bras sont légèrement différentes dans les postures préopératoire et postopératoire, ce qui peut avoir un impact (d'une certaine manière) sur la mesure de la précision de la prédiction de forme. Des variations possibles dans le poids (gain ou perte de poids, et tissus gras) entre les dates d'acquisitions de données préopératoires et les acquisitions postopératoires pourraient aussi

Tableau 7.1 Tableau des statistiques de performance en précision de prédiction de notre algorithme. La mesure de performance considérée est la différence dans l'indice de rotation de la surface du dos pour différentes sections horizontales du tronc. Les estimations sont faites sur un ensemble de données de 5 patients. SD : Écart type, CI : Interval de confiance. Les values des statistiques suivantes sont rapportées : MEAN, SD, MAX, MIN, MEDIAN.

Level	MEAN	SD	MAX	MIN	MEDIAN	[95%CI]
T4	0.90	0.60	1.55	0.33	0.71	[0.43 1.38]
T5	1.08	1.02	2.88	0.32	0.71	[0.58 2.64]
T6	0.85	0.95	2.51	0.16	0.49	[0.35 2.10]
T7	0.65	0.59	1.68	0.23	0.38	[0.34 1.39]
T8	0.69	0.38	1.13	0.06	0.74	[0.33 0.93]
T9	1.08	0.57	1.71	0.51	0.79	[0.64 1.51]
T10	0.84	0.59	1.54	0.21	0.54	[0.40 1.30]
T11	2.99	2.22	5.77	0.00	2.78	[1.11 4.62]
T12	4.31	3.61	10.08	1.06	3.22	[2.07 8.18]
L1	4.14	4.17	10.97	0.71	3.60	[1.90 8.21]
L2	4.78	2.86	8.12	0.32	5.57	[2.15 6.63]
L3	2.73	2.10	6.40	1.09	2.04	[1.66 5.56]
L4	2.19	1.57	4.24	0.54	2.62	[1.01 3.38]

être responsables de certains écarts observés. La variation de forme induite par la respiration n'est pas explicitement prise en compte (et est considérée négligeable) dans le modèle. Ces résultats complémentaires mettent en évidence que la prédiction de formes par régression proche voisin produisent des résultats satisfaisants.

CHAPITRE 8

DISCUSSION GÉNÉRALE

Les chapitres précédents ont traité et proposé des solutions aux limitations des méthodes utilisées pour la simulation d'apparence de troncs scoliotiques postopératoires. Plus spécifiquement, la méthodologie générale a abordé quatre objectifs spécifiques de recherche. La réalisation de ces objectifs de recherche a conduit au développement de différents outils originaux. Premièrement, une nouvelle approche incrémentale pour le modèle de déformation du tronc a été introduite. Deuxièmement, une approche statistique pour la prédiction de courbes anatomiques du tronc a été proposée. Troisièmement, une nouvelle méthode d'apprentissage machine de métriques pour l'espace des formes de troncs a été établie et étudiée. Enfin, quatrièmement, une nouvelle méthode de régression par proche voisin pour la prédiction de déformations de troncs a été développée et étudiée. Nous procédons, dans ce présent chapitre, à une discussion générale des différentes contributions de cette thèse.

8.1 Stabilité de simulation d'apparence

Les méthodes usuelles de modélisation de déformations de tissus mous entrent dans deux catégories : les méthodes d'éléments finis pour l'élasticité linéaire ou nonlinéaire (FEM), et les systèmes masse-ressort (MSS). Les FEM présentent la limitation de l'exigence de long temps de calculs dans le cas de maillages de grande taille. Les modèles MSS présentent certes une simplicité de la modélisation, mais ont l'inconvénient de manquer de l'effet de volume associé par exemple à l'incompressibilité des tissus. Ces limitations ont motivé le choix du modèle d'énergie de déformation initialement proposé par Teschner et al. [85]. Le modèle dans [85] présente des similitudes avec une variante d'éléments finis dite tenseur de masse [115], mais garde la simplicité de la représentation des interactions entre noeuds du même type que les MSS. Ce modèle d'énergie de tissus fut utilisé avec un succès modéré au cas de simulation d'apparence d'un tronc scoliotique dans [29].

Une nouvelle approche pour la simulation de l'apparence externe postopératoire du tronc scoliotique a été proposée au Chapitre 4 et se démarque en différents points de l'approche rapportée dans [29]. Notre méthode offre l'avantage de combiner la simplicité du modèle d'énergie de Teschner et al. pour les tissus mous du tronc et une séquence de petites déformations préservant le caractère linéaire du modèle physique. La formulation théorique de notre modèle de changement de forme du tronc de l'état préopératoire à l'état postopératoire

a été établie.

8.2 Précision de prédiction

Les méthodes d’analyse de formes de troncs développées aux chapitres 5, 6 et 7 avaient pour but d’améliorer la précision de la forme des troncs postopératoires simulés. L’une est basée sur une approche par apprentissage machine pour les courbes anatomiques du tronc, et l’autre sur l’apprentissage de métriques pour l’espace des formes de troncs pour l’approximation de champs de déformations par proche voisin.

8.2.1 Courbes anatomiques du tronc

Une approche statistique basée sur les machines à vecteurs de support a été utilisée pour prédire les courbes caractéristiques sur la surface externe postopératoire de troncs scoliotiques. À notre connaissance, il s’agit du premier travail réalisé établissant le lien statistique entre ces courbes dans l’état préopératoire et dans l’état postopératoire. Une approche similaire a initialement été utilisé par Bergeron et al. [66] pour la prédiction de la colonne vertébrale à partir de la topographie du tronc. Notre approche se distingue de celle adoptée dans [66] en ce que : (1) la relation prédictive est construite entre l’état préopératoire et l’état postopératoire, d’une part, et (2) plusieurs algorithmes de réduction de dimensionalité ont été explorés, d’autre part. Notre approche est pour permettre une meilleure simulation de l’apparence postopératoire lorsque combinée avec le modèle physique de simulation du tronc entier. L’intérêt qu’il y a à procéder ainsi est motivé par la possibilité de tirer profit de l’information implicite contenue dans une base de données de formes de tronc avant et après une chirurgie de la scoliose.

8.2.2 Apprentissage de métriques

La méthode de définition de distance dans l’espace des formes de troncs scoliotiques rapportée au Chapitre 6 constitue la première application, à notre connaissance, du formalisme d’apprentissage de métriques pour la prédiction de formes au contexte spécifique de l’anatomie 3D du tronc humain. Nous avons pu montrer une performance supérieure à celle d’une distance euclidienne (qui est généralement le premier candidat de distance présent). Notre approche s’inspire de la méthode de Weinberger et al. [75] (initialement développée pour les problèmes de classification) et la généralise au contexte de la régression. Bien que appliquée ici aux formes de troncs, la méthode d’apprentissage de métrique proposée peut être utilisée pour différents autres espaces de données.

8.2.3 Régression par proche voisins

L'une des applications naturelles de la définition de distance dans un espace est la recherche de proche voisin dans un ensemble de données. Nous avons proposé une nouvelle approche par proche voisin pour l'approximation de formes de troncs postopératoire de troncs en nous basant sur la définition d'une métrique dans l'espace de formes. Connexe aux résultats présentés dans le chapitre 7, la recherche de proche voisins devrait aussi permettre de transférer implicitement des caractéristiques et propriétés d'un patient à un autre dans la simulation physique de l'apparence postopératoire.

8.3 Limitations générales

Malgré les contributions effectuées lors de cette recherche, il demeure néanmoins certaines limitations dans notre approche qu'il importe de soulever ici.

Anatomie et propriétés physiques des tissus : Notre modèle basé sur la physique est un modèle à deux matériaux, les tissus mous et les os, avec des propriétés qui sont considérées homogènes, uniformes et isotropes. Les tissus ne sont pas anatomiquement explicitement différenciés dans le modèle (peau, gras, muscles et organes viscéraux), ce qui est une approximation de la réalité.

Paramètres de modèle de tissus mous : L'une des limitations de cette étude réside dans l'estimation des valeurs de paramètres pour un patient donné. Dans le cadre de cette étude, elles ont été fixées empiriquement. La mise en oeuvre de techniques expérimentales non-invasives de mesure de coefficients d'élasticité (in vivo) des tissus mous du tronc demeure une difficulté à surmonter.

Caractère statistique : La méthodologie de prédiction de courbes anatomiques est essentiellement statistique, ce qui en fait une approche non personnalisée. En effet, ce qui est exploité ici est l'effet de moyenne et de groupe. Par ailleurs, certaines variables anthropométriques telles que l'âge, l'indice de masse corporel (BMI) ne sont pas explicitement incorporées.

Distance de formes : La métrique de formes de troncs utilisée est basée uniquement sur des caractéristiques de la surface externe. En particulier, elle utilise (dans sa formulation actuelle) uniquement une courbe anatomique sur la surface du dos, plutôt que la surface entière du tronc. Par ailleurs, les caractéristiques de forme associées à la configuration osseuse devraient aussi, en principe, être prises en considération.

Ces limitations générales sont sensées pointer vers des directions de nouveaux travaux de recherche.

CHAPITRE 9

CONCLUSION

L'aspect esthétique de l'apparence externe du tronc postopératoire du tronc de patients scoliotiques candidats à une chirurgie correctrice de la colonne vertébrale est l'une de leur préoccupation majeure et un facteur de satisfaction d'une chirurgie. Disposer d'un outil de planification de chirurgie qui prend en considération l'apparence externe du tronc est d'une utilité de grande importance. Cette thèse a abordé le problème de la simulation et la prédiction de l'apparence externe du tronc postopératoire en chirurgie pour la scoliose. Après la présentation du contexte de l'étude au Chapitre 1 et une revue de la littérature sur les méthodes existantes au Chapitre 2, la formulation de la problématique et des objectifs spécifiques de recherche de cette thèse a été abordée au chapitre 3. Les nouvelles méthodes proposées et développées ont ensuite été présentées aux Chapitres 4, 5, 6 et 7. Les sections ci-dessous résumement les contributions principales de cette recherche et formulent des recommandations pour surmonter les différentes limitations soulevées dans la discussion générale (Chapitre 8).

Synthèse des travaux

Nous avons développé dans cette thèse une méthode de modélisation du tronc humain pour la simulation de l'apparence externe postopératoire du tronc suite à une chirurgie de la scoliose. L'intention au final est de pouvoir incorporer l'aspect esthétique du tronc dans un simulateur plus global en planification de chirurgie de la scoliose. La première partie du travail a consisté à développer un modèle physique de déformation pour le tronc scoliotique. Contrairement au modèle existant, un nouveau modèle physique de déformation incrémentale est proposé pour tenir compte des grandes déformations du tronc. La deuxième partie a consisté à améliorer la précision des prédictions en proposant deux méthodes de détermination de formes à priori de tronc postopératoire (une méthode statistique d'apprentissage machine et une méthode de type proche voisin). Des contributions originales à l'état de l'art aussi bien en simulation physique de tissus mous qu'en apprentissage machine pour l'analyse de formes ont résulté de cette recherche. Les résultats de cette étude fournissent ainsi la base théorique et méthodologique du développement d'un simulateur de l'apparence postopératoire du tronc pour les systèmes de planification de chirurgie de la scoliose. Ce travail présente toutefois quelques limitations dont les améliorations pourraient constituer l'objet de travaux futures.

Recommandations et perspectives

Les limitations des méthodes proposées dans le cadre de cette recherche ont été exposés au chapitre 8. Des recommandations sont ici suggérées pour contourner les difficultés soulevées.

Modèle anatomique amélioré

Le modèle physique utilisé fait l'hypothèse de tissus mous aux propriétés uniformes dans le tronc entier. En réalité, différentes couches devraient être considérées : la peau, la couche de gras et les muscles. Nous suggérons donc la recommandation suivante.

Recommandation 1 : *Développer une méthode de reconstruction 3D personnalisée des structures anatomiques du tronc où entre autres les couches correspondants à la peau, au gras, aux muscles et aux organes viscéraux sont différenciées.*

Harmouche [116] a récemment réalisé, dans ses travaux de thèse de doctorat, une fusion multimodale d'images en recalant des images de Rayons X et des images IRM pour le tronc scoliotique. Ces résultats peuvent constituer une base pour le développement d'un modèle géométrique du tronc contenant des structures anatomiques différenciées.

Simulation physique améliorée

Le modèle physique utilisé fait l'hypothèse de tissus mous aux propriétés uniformes dans le tronc entier. Nous suggérons donc la recommandation suivante.

Recommandation 2 : *Développer une méthode d'estimation des paramètres de modèle physique personnalisé et spécifique aux couches des tissus.*

Le traitement et l'analyse d'images IRM et/ou de rayons X du patient pourraient permettre une personnalisation géométrique des différentes couches anatomiques. Par ailleurs, afin de justifier du caractère statistiquement significatif de la précision des simulations avec le modèle physique, un plus grand nombre de données de patients devrait être étudié.

Recommandation 3 : *Préparer un grand nombre de données de patients.*

La durée du cycle de construction d'un modèle tétraédrique du tronc scoliotique est, pour l'instant, un facteur limitant puisqu'elle contient certaines étapes réalisées manuellement. Cette composante de l'étude pourrait être accélérée si un moyen automatique de construction de modèle géométrique est disponible. Nous pensons qu'en développant un modèle té-

traédrique générique du tronc qui sera par la suite adapté aux données personnalisées d'un patient, il est possible d'automatiser cette étape et ainsi produire le traitement de données de plusieurs patients en peu de temps.

Analyse de formes améliorée

Recommandation 4 : *Proposer une représentation de formes du tronc considérant la surface toute entière, ainsi que la configuration osseuse sous-jacente.*

La distance de forme proposée prend en compte uniquement des courbes caractéristiques de la surface du tronc pour la représentation de formes et la définition d'un espace de formes de troncs. Nous avons, dans un premier temps limité la représentation à la courbe de la vallée du dos. Il serait intéressant de considérer d'une part la surface entière du tronc dans la représentation, et d'autre part d'incorporer les données du tronc en posture de tests de flexion latérale.

Aussi, nous pensons que les données de forme du tronc en flexion latérale pourraient contribuer à améliorer la précision de la simulation d'apparence postopératoire.

Recommandation 5 : *Incorporer dans la simulation l'analyse de données de topographie de surface du tronc de patients en posture de tests de flexion ('bending') latérale du tronc.*

La correction attendue pour la courbure de la colonne vertébrale lors d'une chirurgie de la scoliose est généralement estimée à partir de mesures d'angle de Cobb sur des radiographies du patient en posture de flexion latérale maximale (*bending*) du tronc en posture debout ou en position couchée. Les précisions d'estimation sont de $\pm 5^\circ$ pour la correction thoracique frontale dans 65% des cas et de $\pm 1^\circ$ avec des radiographies en tests de *bending* avec point d'appui [117]. Des données de topographie de surface du tronc de patients en posture de flexion latérale ont permis de démontrer qu'il est possible de mesurer des changements significatifs de déformations scoliotiques à partir du test de flexion latérale non invasif (Débanné et al., 2010) [118]. Il est raisonnable de penser qu'une analyse appropriée des données de formes du tronc en flexion latérale pourrait améliorer la simulation et la prédiction de l'apparence postopératoire.

RÉFÉRENCES

- [1] S. Kadoury, F. Cheriet, C. Laporte, and H. Labelle. A versatile 3D reconstruction system of the spine and pelvis for clinical assessment of spinal deformities. *Medical and Biological Engineering and Computing*, 45(6) :591–602, 2007.
- [2] W. Mollemans, F. Schutyser, N. Nadjmi, F. Maes, and P. Suetens. Predicting soft tissue deformations for maxillofacial surgery planning system : from computational strategies to a complete clinical validation. *Medical Image Analysis*, 11(3) :282–301, 2007.
- [3] C.-E. Aubin, H. Labelle, and O. C. Ciolofan. Variability of spinal instrumentation configurations in adolescent idiopathic scoliosis. *European Spine Journal*, 16(1) :57–64, 2007.
- [4] C.-E. Aubin, H. Labelle, C. Chevretils, G. Desroches, J. Clin, and A. B. Eng. Preoperative planning simulator for spinal deformity surgeries. *Spine*, 33(20) :2143–2152, 2008.
- [5] V. J. Raso, E. Lou, D. L. Hill, J. K. Mahood, M. J. Moreau, and N. G. Durdle. Trunk distorsion in adolescent idiopathic scoliosis. *J.Pediatr. Orthop.*, 18 :222–226, 1998.
- [6] C. Denoel, M. F. I. Aguirre, G. Bianco, P. H. Mahaudens, R. Vanwijck, S. Garson, R. Sinna, and A. Debrun. Idiopathic scoliosis and breast asymmetry. *Journal of Plastic Reconstructive and Aesthetic Surgery*, 62 :1303–1308, 2009.
- [7] T. G. Lowe, M. Edgar, J. Y. Margulies, N. H. Miller, V. J. Raso, K. A. Reinker, and C. H. Rivard. Etiology of idiopathic scoliosis : current trends in research. *J Bone Joint Surg Am*, 82-A :1157–1168, 2000.
- [8] E. J. Rogala, D. S. Drummond, and J. Gurr. Scoliosis : incidence and natural history. a prospective epidemiological study. *J Bone Joint Surg Am*, 60 :173–176, 1978.
- [9] J.R. Cobb. Outline for the study of scoliosis. *Am. Acad. Orthop. Surg. Instruct. Lect.*, 5 :261–275, 1948.
- [10] S. Negrini. Bracing adolescent idiopathic scoliosis today. *Disabil Rehabil Assist Technol*, 3 :107–111, 2008.
- [11] R.R. Betz and H. Shufflebarger. Anterior versus posterior instrumentation for the correction of thoracic idiopathic scoliosis. *Spine*, 26(9) :1095–1100, 2001.

- [12] P. Papin, H. Labelle, S. Delorme, C.E. Aubin, J.A. De Guise, and J. Dansereau. Long-term three-dimensional changes of the spine after posterior spinal instrumentation and fusion in adolescent idiopathic scoliosis. *European Spine Journal*, 8(1) :16–21, 1999.
- [13] S. Delorme, P. Violas, J. Dansereau, J. de Guise, C.-E. Aubin, and H. Labelle. Preoperative and early postoperative three-dimensional changes of the rib cage after posterior instrumentation in adolescent idiopathic scoliosis. *European Spine Journal*, 10(2) :101–107, 2001.
- [14] M. Asher, S. M. Lai, D. Burton, and B. Manna. Maintenance of trunk deformity correction following posterior instrumentation and arthrodesis for idiopathic scoliosis. *Spine*, 29 :1782–1788, 2004.
- [15] R. K. Pratt, J. K. Webb, R. G. Burwell, and A. A. Cole. Changes in surface and radiographic deformity after universal spine system for right thoracic adolescent idiopathic scoliosis : is rib-hump reassertion a mechanical problem of the thoracic cage rather than an effect of relative anterior spinal overgrowth ? *Spine*, 26 :1778–1787, 2001.
- [16] U. Willers, E. E. Transfeldt, and R. Hedlund. The segmental effect of cotrel-dubousset instrumentation on vertebral rotation, rib hump and the thoracic cage in idiopathic scoliosis. *European Spine Journal*, 5(6) :387–393, 1996.
- [17] T. R. Haher, A. Merola, R. I. Zipnick, J. Gorup, D. Mannor, and J. Orchowski. Meta-analysis of surgical outcome in adolescent idiopathic scoliosis. a 35-year english literature review of 11,000 patients. *Spine*, 20(14) :1575–1584, 1995.
- [18] A. E. Geissele, J. W. Ogilvie, M. Cohen, and D. S. Bradford. Thoracoplasty for the treatment of rib prominence in thoracic scoliosis. *Spine*, 19(14) :1636–1642, 1994.
- [19] K.H. Bridwell. Surgical treatment of idiopathic adolescent scoliosis. *Spine*, 24(24) :2607–2616, 1999.
- [20] C.-E. Aubin, J. Dansereau, F. Parent, H. Labelle, and J. A. de Guise. Morphometric evaluations of personalised 3d reconstructions and geometric models of the human spine. *Medical and Biological Engineering and Computing*, 35(6) :611–618, 1997.
- [21] D. Périé, C. E. Aubin, M. Lacroix, Y. Lafon, and H. Labelle. Biomechanical modelling of orthotic treatment of the scoliotic spine including a detailed representation of the brace-torso interface. *Medical and Biological Engineering and Computing*, 42 :339–344, 2004.

- [22] J. Carrier, C.-E. Aubin, I. Villemure, and H. Labelle. Biomechanical modelling of growth modulation following rib shortening or lengthening in adolescent idiopathic scoliosis. *Medical and Biological Engineering and Computing*, 42(4) :541–548, 2004.
- [23] Clin J., Aubin C.-E., Parent S., Ronsky J., and Labelle H. Biomechanical modeling of brace design. *Stud. Health Technol. Inform.*, 123 :255–260, 2006.
- [24] J. Clin, C.-E. Aubin, and H. Labelle. Virtual prototyping of a brace design for the correction of scoliotic deformities. *Medical and Biological Engineering and Computing*, 45(5) :467–473, 2007.
- [25] J. Clin, C.-E. Aubin, S. Parent, A. Sangole, and H. Labelle. Comparison of the biomechanical 3D efficiency of different brace designs for the treatment of scoliosis using a finite element model. *Eur. Spine J.*, 19(7) :1169–1178, 2010.
- [26] J. Clin, C.-E. Aubin, S. Parent, and H. Labelle. A biomechanical study of the charleston brace for the treatment of scoliosis. *Spine*, Publish Ahead of Print, 2010.
- [27] J. Clin, C.-E. Aubin, H. Labelle, and S. Parent. Immediate correction in brace treatment : how much is needed to obtain a long-term effectiveness ? In *8th Meeting of the International Research Society of Spinal Deformities (IRSSD 2010)*, Montréal, Québec, Canada, 2010.
- [28] M. Beauséjour, C.E. Aubin, A.G. Feldman, and H. Labelle. Simulations de tests d’inflexion latérale à l’aide d’un modèle musculo-squelettique du tronc. *Annales de chirurgie*, 53 :742–750, 1999.
- [29] O. Dionne, K. C. Assi, S. Grenier, H. Labelle, F. Guibault, and F. Cheriet. Simulation of the postoperative trunk appearance in scoliotic surgery. In *International Symposium On Biomedical Imaging, ISBI 2012*, pages 1208–1211, 2012.
- [30] U. Meier, O. López, C. Monserrat, M. C. Juan, and M. Alcaniz. Real-time deformable models for surgery simulation : a survey. *Computer Methods and Programs Biomedicine*, 77(3) :183–197, 2005.
- [31] R. M. Koch, M. H. Gross, F. R. Carls, D. F. von Büren, G. Fankhauser, and Y. I. H. Parish. Simulating facial surgery using finite element models. In *Proceedings of the 23rd annual conference on Computer graphics and interactive techniques*, pages 421–428. ACM, 1996.

- [32] R. M. Koch, S. H. M. Roth, M. H. Gross, A. P. Zimmermann, and H. F. Sailor. A framework for facial surgery simulation. In *Proceedings of the 18th spring conference on Computer graphics*, pages 33–42, 2002.
- [33] D. Terzopoulos and K. Waters. Physically-based facial modeling, analysis, and animation. *Journal of Visualization and Computer Animation*, 1(2) :73–80, 1990.
- [34] E. Keeve, S. Girod, and B. Girod. Craniofacial surgery simulation. In *Visualization in Biomedical Computing*, pages 541–546. Springer : Berlin, 1996.
- [35] W. Mollemans, F. Schutyser, J.V. Cleynenbreugel, and P. Suetens. Tetrahedral mass spring model for fast soft tissue deformation. In *Surgery Simulation and Soft Tissue Modeling IS4TM 2003, LNCS 2673*, pages 145–154. Springer : Berlin, 2003.
- [36] M. Bro-Nielsen. Surgery simulation using fast finite elements. In *VBC '96 : Proceedings of the 4th International Conference on Visualization in Biomedical Computing*, pages 529–534. Springer-Verlag, 1996.
- [37] S. Cotin, H. Delingette, and N. Ayache. Real-time elastic deformations of soft tissues for surgery simulation. *IEEE Transactions On Visualization and Computer Graphics*, 5(1) :62–73, 1999.
- [38] Matthias Müller, Julie Dorsey, Leonard McMillan, Robert Jagnow, and Barbara Cutler. Stable real-time deformations. In *SCA '02 : Proceedings of the 2002 ACM SIGGRAPH/Eurographics symposium on Computer animation*, pages 49–54. ACM, 2002.
- [39] Guillaume Picinbono, Herve Delingette, and Nicholas Ayache. Real-time large displacement elasticity for surgery simulation : Non-linear tensor-mass model. In *MICCAI '00 : Proceedings of the Third International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 643–652. Springer-Verlag, 2000.
- [40] M. Chabanas, V. Luboz, and Y. Payan. Patient specific finite element model of the face soft tissues for computer-assisted maxillofacial surgery. *Medical Image Analysis*, 7(2) :131–151, 2003.
- [41] Liesbet Roose, Wim De Maerteleire, Wouter Mollemans, and Paul Suetens. Validation of different soft tissue simulation methods for breast augmentation. *International Congress Series*, 1281 :485–490, 2005.
- [42] R. Mahnken and E. Stein. A unified approach for parameter identification of inelastic material models in the frame of the finite element method. *Computer Methods in Applied Mechanics and Engineering*, 136(3-4) :225 – 258, 1996.

- [43] R. Mahnken and E. Stein. Parameter identification for viscoplastic models based on analytical derivatives of a least-squares functional and stability investigations. *International Journal of Plasticity*, 12(4) :451 – 479, 1996.
- [44] R. Mahnken and E. Stein. Parameter identification for finite deformation elastoplasticity in principal directions. *Computer Methods in Applied Mechanics and Engineering*, 147(1-2) :17 – 39, 1997.
- [45] T. Seibert, J. Lehn, S. Schwan, and F.G. Kollmann. Identification of material parameters for inelastic constitutive models : Stochastic simulations for the analysis of deviations. *Continuum Mechanics and Thermodynamics*, 12(2) :95 – 120, 2000.
- [46] T. Harth, S. Schwan, J. Lehn, and F. G. Kollmann. Identification of material parameters for inelastic constitutive models : statistical analysis and design of experiments. *International Journal of Plasticity*, 20(8-9) :1403 – 1440, 2004.
- [47] W. T. D’Arcy. *On Growth and Form*. Cambridge University Press, 1917.
- [48] U. Grenander and M. I. Miller. Computational anatomy : an emerging discipline. *Q. Appl. Math.*, LVI(4) :617–694, 1998.
- [49] Daniel P. Huttenlocher, Gregory A. Klanderman, Gregory A. Kl, and William J. Rucklidge. Comparing images using the hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15 :850–863, 1993.
- [50] Guillaume Charpiat, Olivier Faugeras, and Renaud Keriven. Approximations of shape metrics and application to shape warping and empirical shape statistics. *Found. Comput. Math.*, 5(1) :1–58, 2005.
- [51] *Distance-Based Shape Statistics*, volume 5, 2006.
- [52] D.G. Kendall. Shape manifolds, procrustean metrics, and complex projective spaces. *Bulletin of the London Mathematical Society*, 16(2) :81–121, 1984.
- [53] F. L. Bookstein. Size and shape spaces for landmark data in two dimensions. *Statistical Science*, 1(2) :181–242, 1986.
- [54] Simone Ceolin, William A. P. Smith, and Edwin Hancock. Facial shape spaces from surface normals and geodesic distance. In *DICTA '07 : Proceedings of the 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications*, pages 416–423, Washington, DC, USA, 2007. IEEE Computer Society.

- [55] Simone Ceolin, William Smith, and Edwin Hancock. Facial shape spaces from surface normals. In *Image Analysis and Recognition*, pages 955–965. 2008.
- [56] C. R. Rao. Information and accuracy attainable in estimation of statistical parameters. *Bulletin of the Calcutta Mathematical Society*, 37 :81–91, 1945.
- [57] *Shape analysis using the Fisher-Rao Riemannian metric : unifying shape representation and deformation*, 2006.
- [58] Adrian M. Peter and Anand Rangarajan. Information geometry for landmark shape analysis : Unifying shape representation and deformation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31 :337–350, 2009.
- [59] Simone Ceolin and Edwin R. Hancock. Using the fisher-rao metric to compute facial similarity. In *ICIAR (1)*, pages 384–393, 2010.
- [60] J. Glaunes, A. Trouvé, and L. Younes. Diffeomorphic matching of distributions : A new approach for unlabelled point-sets and sub-manifolds matching. In *In CVPR*, pages 712–718, 2004.
- [61] M. Vaillant and J. Glaunès. Surface matching via currents. In *Proceedings of Information Processing in Medical Imaging (IPMI 2005), number 3565 in Lecture Notes in Computer Science*, pages 381–392, 2005.
- [62] J. Glaunès, A. Qiu, M. I. Miller, and L. Younes. Large deformation diffeomorphic metric curve mapping. *Int. J. Comput. Vision*, 80(3) :317–336, 2008.
- [63] S. Durrleman, X. Pennec, A. Trouvé, and N. Ayache. Statistical models of sets of curves and surfaces based on currents. *Medical Image Analysis*, 13(5) :793–808, 2009. Includes Special Section on the 12th International Conference on Medical Imaging and Computer Assisted Intervention.
- [64] N. Acir and C. Guzelis. Automatic spike detection in eeg by a two-stage procedure based on support vector machines. *Computers in Biology and Medicine*, 34(7) :561–575, 2004.
- [65] G.-Z. Li, J. Yang, C.-Z. Ye, and D.-Y. Geng. Degree prediction of malignancy in brain glioma using support vector machines. *Comput. Biol. Med.*, 36(3) :313–325, 2006.
- [66] C. Bergeron, F. Cheriet, J. Ronsky, R. Zernicke, and H. Labelle. Prediction of anterior scoliotic spinal curve from trunk surface using support vector regression. *Eng. Appl. Artificial Intell.*, 18(8) :973–983, 2005.

- [67] J. Jaremko, P. Poncet, J. Ronsky, J. Harder, J. Harder, J. Dansereau, H. Labelle, and R. Zernicke. Genetic algorithm-neural network estimation of cobb angle from torso asymmetry in scoliosis. *J. Biomech. Eng.*, 124(5) :496–503, 2002.
- [68] L. Ramirez, N.G. Durdle, V.J. Raso, and D.L. Hill. A support vector machines classifier to assess the severity of idiopathic scoliosis from surface topography. *IEEE Trans. Inf. Technol. Biomed.*, 10(1) :84–91, 2006.
- [69] L. Seoud, M.M. Adankon, H. Labelle, J. Dansereau, and F. Cheriet. Prediction of scoliosis curve type based on the analysis of trunk surface topography. In *Biomedical Imaging : From Nano to Macro, 2010 IEEE International Symposium on*, pages 408–411, 2010.
- [70] T.M. Cover and P.E. Hart. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, IT-13 :21–27, 1967.
- [71] T. M. Cover. Estimation by the nearest neighbor rule. *IEEE Transactions on Information Theory*, IT-14(1) :50–55, 1968.
- [72] L. Devroye, L. Györfi, A. Krzyżak, and G. Lugosi. On the strong universal consistency of nearest neighbor regression function estimates. *The Annals of Statistics*, 22 :1371–1385, 1994.
- [73] S. R. Kulkarni and S. E. Posner. Rates of convergence of nearest neighbor estimation under arbitrary sampling. *IEEE Trans. Inf. Theory*, 41 :1028–1039, 1995.
- [74] G. Biau, F. Cérou, and A. Guyader. Rates of convergence of the functional k-nearest neighbor estimate. *IEEE Transactions on Information Theory*, 56 :2034–2040, 2010.
- [75] Kilian Weinberger, John Blitzer, and Lawrence Saul. Distance metric learning for large margin nearest neighbor classification. In Y. Weiss, B. Schölkopf, and J. Platt, editors, *Advances in Neural Information Processing Systems 18*, pages 1473–1480. MIT Press, Cambridge, MA, 2006.
- [76] K. Weinberger and L. Saul. Fast solvers and efficient implementations for distance metric learning. pages 1160–1167, 2008.
- [77] K.Q. Weinberger and L.K. Saul. Distance metric learning for large margin nearest neighbor classification. *Journal of Machine Learning Research*, 10.
- [78] C. Domeniconi, J. Peng, and D. Gunopulos. Locally adaptive metric nearest neighbor classification. *IEEE Trans. Pattern Anal. Mach. Intell.*, 24(9) :1281–1285, 2002.

- [79] T. Hastie and R. Tibshirani. Discriminant adaptive nearest neighbor classification. *IEEE Trans. Pattern Anal. Mach. Intell.*, 18(6) :607–615, 1996.
- [80] Y. Lee, D. Terzopoulos, and K. Waters. Realistic modeling for facial animation. In *SIGGRAPH '95 : Proceedings of the 22nd annual conference on Computer graphics and interactive techniques*, pages 55–62, New York, NY, USA, 1995. ACM.
- [81] S. Sarni, A. Maciel, R. Boulic, and D. Thalmann. Evaluation and visualization of stress and strain on soft biological tissues in contact. In *SMI '04 : Proceedings of the Shape Modeling International 2004*, pages 255–262, Washington, DC, USA, 2004. IEEE Computer Society.
- [82] S. Delorme, Y. Petit, J. A. de Guise, H. Labelle, C.-E. Aubin, and J. Dansereau. Assessment of the 3D reconstruction and high-resolution geometrical modeling of the human skeletal trunk from 2D radiographic images. *IEEE Transactions on Biomedical Engineering*, 50(8) :989–98, 2003.
- [83] H. Si. Tetgen : A quality tetrahedral mesh generator and three-dimensional delaunay triangulator. <http://tetgen.berlios.de/>.
- [84] J. R. Shewchuk. Tetrahedral mesh generation by delaunay refinement. In *SCG '98 : Proceedings of the fourteenth annual symposium on Computational geometry*, pages 86–95. ACM, 1998.
- [85] M. Teschner, B. Heidelberger, M. Müller, and M. Gross. A versatile and robust model for geometrically complex deformable solids. In *Proceedings of the Computer Graphics International*, pages 312–319. IEEE Computer Society, 2004.
- [86] J. L. Jaremko, P. Poncet, J. Ronsky, J. Harder, and J. Dansereau. Indices of torso asymmetry related to spinal deformity in scoliosis. *Clinical Biomechanics*, 17(8) :559–568, 2002.
- [87] L. Seoud, F. Cheriet, H. Labelle, and J. Dansereau. A novel method for the 3d reconstruction of scoliotic ribs from frontal and lateral radiographs. *IEEE Transactions in biomedical engineering*, 58(5) :1135–1146, 2011.
- [88] V. Pazos, F. Cheriet, J. Dansereau, Janet Ronsky, Ronald F. Zernicke, and Hubert Labelle. Reliability of trunk shape measurements based on 3-d surface reconstructions. *European Spine Journal*, 16(11) :1882–1891, 2007.

- [89] R. Buchanan, J. G. Birch, A. A. Morton, and R. H. Browne. Do you see what I see? Looking at scoliosis surgical outcomes through orthopedists' eyes. *Spine*, 28(24) :2700–2704, 2003.
- [90] Goran Devedzic, Sasa Cukovic, Vanja Lukovic, Danijela Milosevic, K. Subburaj, and Tanja Lukovic. Scoliomedis : Web-oriented information system for idiopathic scoliosis visualization and monitoring. *Computer Methods and Programs in Biomedicine*, 108(2) :736–749, 2012.
- [91] V. Pazos, F. Cheriet, H. Labelle, and J. Dansereau. 3d reconstruction and analysis of the whole trunk surface for non-invasive follow-up of scoliotic deformities. *Studies in health technology and informatics*, 91 :296–299, 2002.
- [92] T.M.L. Shannon. *Dynamic Surface Topography and Its Application to the Evaluation of Adolescent Idiopathic Scoliosis*. PhD thesis, Oxford Brookes University, Oxford, U.K., september 2010.
- [93] Peter O. Ajemba, Nelson G. Durdle, and V. James Raso. Characterizing torso shape deformity in scoliosis using structured splines models. *IEEE Trans. Biomed. Engineering*, 56(6) :1652–1662, 2009.
- [94] S. Li, W. Zhou, Q. Yuan, S. Geng, and D. Cai. Feature extraction and recognition of ictal eeg using emd and svm. *Computers in Biology and Medicine*, 43(7) :807–816, 2013.
- [95] A. Subasi. Classification of emg signals using pso optimized svm for diagnosis of neuromuscular disorders. *Computers in Biology and Medicine*, 43(5) :576–586, 2013.
- [96] E. Comak, A. Arslan, and I. Türkoglu. A decision support system based on support vector machines for diagnosis of the heart valve diseases. *Computers in biology and Medicine*, 37(1) :21–27, 2007.
- [97] S. Kiranyaz, T. Ince, J. Pulkkinen, M. Gabbouj, J. Ärje, S. Kärkkäinen, V. Tirronen, M. Juhola, T. Turpeinen, and K. Meissner. Classification and retrieval on macroinvertebrate image databases. *Computers in Biology and Medicine*, 41(7) :463–472, 2011.
- [98] H. M. Muda, P. Saad, and R. M. Othman. Remote protein homology detection and fold recognition using two-layer support vector machine classifiers. *Computers in Biology and Medicine*, 41(8) :687–699, 2011.
- [99] T. Hastie, R. Tibshirani, and Friedman. *The elements of statistical learning*.

- [100] H. Hotelling. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 24 :417—441, 1933.
- [101] B. Schölkopf, A.J. Smola, and K.-R. Müller. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 10(5) :1299–1319, 1998.
- [102] X. He and P. Niyogi. Locality Preserving Projections. Cambridge, MA, 2004. MIT Press.
- [103] X. He, D. Cai, S. Yan, and H.-J. Zhang. Neighborhood preserving embedding. In *Proceedings of IEEE International Conference on Computer Vision*, volume 2, pages 1208–1213. IEEE, 2005.
- [104] H. Wold. Soft Modeling by Latent Variables; the Nonlinear Iterative Partial Least Squares Approach. *Perspectives in Probability and Statistics. Papers in Honour of M. S. Bartlett*, 1975.
- [105] S. Wold, H. Ruhe, H. Wold, and W.J. Dunn III. The collinearity problem in linear regression. the partial least squares (PLS) approach to generalized inverse. *SIAM Journal of Scientific and Statistical Computations*, 5(3) :735–743, 1984.
- [106] V. Pazos, F. Cheriet, L. Song, H. Labelle, and J. Dansereau. Accuracy assessment of human trunk surface 3d reconstructions from an optical digitizing system. *Medical and Biological Engineering and Computing*, 43(1) :11–15, 2005.
- [107] J.A.K. Suykens, V.T. Gestel, J. De Brabanter, B. De Moor, and J. Vandewalle. *Least Squares Support Vector Machines*. World Scientific, Singapore, 2002.
- [108] S.-M. Huang and J.-F. Yang. Unitary regression classification with total minimum projection error for face recognition. *IEEE signal processing letters*, 20(5) :443–446, 2013.
- [109] B.L. Pellom, R. Sarikaya, and J.H.L. Hansen. Fast likelihood computation techniques in nearest-neighbor based search for continuous speech recognition. *IEEE Signal Processing Letters*, 8(8) :221–224, 2001.
- [110] S. Marano, V. Matta, and P. Willett. Nearest-neighbor distributed learning by ordered transmissions. *IEEE Transactions on Signal Processing*, 61(21) :221–224, 2013.
- [111] Dor Kedem, Stephen Tyree, Kilian Weinberger, Fei Sha, and Gert Lanckriet. Non-linear metric learning. In P. Bartlett, F.C.N. Pereira, C.J.C. Burges, L. Bottou, and K.Q.

- Weinberger, editors, *Advances in Neural Information Processing Systems 25*, pages 2582–2590. 2012.
- [112] B. Kulis. Metric learning : A survey. *Foundations and Trends in Machine Learning*, 5(4) :287–364, 2013.
 - [113] J. Devore and N. Farnum. *Applied Statistics for Engineers and Scientists*. Duxbury Press, 1999.
 - [114] C.-É. Aubin, Y. Petit, I.A.F. Stokes, F. Poulin, M. Gardner-Morse, and H. Labelle. Biomechanical modeling of posterior instrumentation of the scoliotic spine. *Computer Methods in Biomechanics and Biomedical Engineering*, 6(1) :27–32, 2003.
 - [115] S. Cotin, H. Delingette, and N. Ayache. A hybrid elastic model allowing real-time cutting, deformations and force-feedback for surgery training and simulation. *The Visual Computer*, 16 :437–452, 2000.
 - [116] R. Harmouche, F. Cheriet, H. Labelle, and J. Dansereau. 3D registration of MR and X-ray spine images using an articulated model. *Computerized Medical Imaging and Graphics*, 36(5) :410 – 418, 2012.
 - [117] K.M Cheung and K.D Luk. Prediction of correction of scoliosis with se of the fulcrum bending radiograph. *J. Bone Joint Surg. Am.*, 79 :1144–1150, 1997.
 - [118] P. Debanné, V. Pazos, H. Labelle, and F. Cheriet. Evaluation of reducibility of trunk asymmetry in lateral bending. In *8th Meeting of the International Research Society of Spinal Deformities (IRSSD 2010)*, Montréal, Québec, Canada, 2010.