

Intelligence artificielle pour la conception et l'ajustement des masques respiratoires

par

Eya MLIKA

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

MONTRÉAL, LE "22 DÉCEMBRE 2025"

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Eya Mlika, 2025



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

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE:

M. Luc Duong, PhD, directeur de mémoire
Département de génie logiciel et des technologies de l'information à École de technologie supérieure

M. Bahe Hachem, PhD, codirecteur
Numalogics Inc.

M. Mohamed Cheriet, PhD, président du jury
Département de génie des systèmes à École de technologie supérieure

Mme Sylvie Ratté, PhD, membre du jury
Département de génie logiciel et des technologies de l'information à École de technologie supérieure

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

LE "05 DÉCEMBRE 2025"

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Je tiens à exprimer ma profonde gratitude au professeur Luc Duong, mon directeur de recherche, pour sa confiance, son accompagnement et sa rigueur scientifique tout au long de ce projet. Sa guidance et sa bienveillance ont été déterminantes pour la réussite de ce travail.

Je remercie également M. Bahe Hachem, mon codirecteur, pour son expertise, sa disponibilité et ses conseils toujours pertinents. Son encadrement attentif a grandement enrichi cette recherche.

Je souhaite exprimer ma reconnaissance à M. Yamen Al Habash et M. Loïc Degueldre pour leur aide précieuse, leurs échanges techniques et leur soutien constant.

Ma gratitude s'adresse également à M. Mohamed Cheriet, président du jury, et à Mme Sylvie Ratté, membre du jury, pour le temps consacré à l'évaluation de ce mémoire et pour leurs commentaires éclairés.

Ce projet a été réalisé en collaboration avec Numalogics et a bénéficié d'un soutien financier du Consortium industriel de recherche et d'innovation en technologies de la santé (MEDTEQ+) ainsi que du ministère de l'Économie et de l'Innovation du Québec. Leur appui a été déterminant pour la conduite et l'aboutissement de ce travail de recherche.

Je remercie chaleureusement l'équipe de Numalogics pour sa collaboration et son appui scientifique, ainsi que mes collègues des laboratoires LIVE et LINCS (A-3440) pour leur esprit d'équipe et leurs échanges stimulants. Une mention spéciale à Aruny Pathammavong pour sa gentillesse et son soutien.

Je n'oublie pas mes amis (Yosr, Chihab, Maher, Hazem, Housseem et Hakim) pour leur présence et leurs encouragements, ni ma famille pour son amour et sa confiance, véritables sources de force et de motivation.

Enfin, j'adresse une pensée empreinte de compassion à tous les peuples qui subissent la souffrance et l'injustice, en particulier au peuple de Gaza, symbole de courage et de dignité. Puissent la science et la solidarité contribuer à un monde plus juste et plus humain.

Intelligence artificielle pour la conception et l'ajustement des masques respiratoires

Eya MLIKA

RÉSUMÉ

Contexte : Les masques respiratoires constituent un élément essentiel de protection individuelle contre les contaminants atmosphériques, tant dans les milieux médicaux qu'industriels. Cependant, leur port prolongé peut engendrer un inconfort significatif et provoquer des lésions cutanées. Ces problèmes résultent souvent d'un ajustement inadéquat du masque.

Objectif : Ce mémoire a pour objectif de développer un modèle d'apprentissage automatique capable de prédire la déformation faciale et la distribution des pressions exercées par un masque respiratoire, à partir d'un jeu restreint de données biomécaniques annotées. L'objectif ultime est de favoriser un ajustement personnalisé optimisant à la fois la protection et le confort.

Méthodologie : Une architecture de réseau de neurones en graphes semi-supervisée a été proposée pour représenter la géométrie faciale sous forme de graphes. Le modèle exploite 45 visages étiquetés et 120 non étiquetés, combinant un autoencodeur variationnel et des contraintes inspirées de la théorie du contact hertzien. Un module complémentaire basé sur XGBoost assure la classification des zones de déformation.

Résultats : Notre approche permet d'obtenir une RMSE de déformation de 0,164 mm ($R^2 = 0,9896$) et une RMSE de pression de 0,0492 kPa ($R^2 = 0,9517$), soit une amélioration de 34,27 % par rapport à Random Forest, de 20,62 % par rapport à PointNet++ et de 10,01 % par rapport à TPSNET. La validation croisée à cinq volets confirme une généralisation robuste et un temps d'inférence inférieur à 2 secondes.

Conclusion : Cette étude présente un modèle d'ajustement personnalisé en temps réel des masques respiratoires capable de prédire avec précision la déformation faciale et la pression de contact.

Mots-clés: Déformation faciale 3D, réseaux de neurones graphiques, ajustement personnalisé des masques, modèle semi-supervisé, autoencodeurs graphiques variationnels

Artificial Intelligence for the Design and Adjustment of Respiratory Masks

Eya MLIKA

ABSTRACT

Background : Respiratory masks are essential for protection against airborne contaminants in both medical and industrial environments. However, prolonged use often leads to discomfort and pressure sores. This issue, typically caused by poor fit, compromises user comfort, protection efficiency, and compliance with safety guidelines.

Objective : This study aims to predict facial deformation and pressure distribution during mask usage, based on a limited set of annotated biomechanical data, to ensure optimal fit.

Method : We developed a semi-supervised graph neural network that models facial geometries as graph structures. The proposed framework utilizes 45 labeled and 120 unlabeled facial datasets, employing a variational graph autoencoder constrained by Hertzian contact theory. It also integrates an XGBoost-based module for deformation zone classification.

Results : Our approach achieves a deformation RMSE of 0.164 mm ($R^2 = 0.9896$) and a pressure RMSE of 0.0492 kPa ($R^2 = 0.9517$), representing a 34.27% improvement over Random Forest, 20.62% over PointNet++, and 10.01% over TPSNET. Five-fold cross-validation confirms robust generalization with minimal overfitting and inference time under 2 seconds.

Conclusion : This study presents a real-time personalized respiratory mask fitting model capable of accurately predicting facial deformation and contact pressure. The approach demonstrates strong generalization from limited labeled data, enhancing comfort, safety, and compliance in medical and industrial applications.

Keywords: 3D Facial Deformation, Graph Neural Networks, Personalized Mask Fitting, Semi-supervised Model, Variational Graph Autoencoders

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE	7
1.1 Introduction	7
1.2 La représentation 3D du visage	7
1.3 Morphologie faciale et modélisation 3D	9
1.4 Déformation rigide et non rigide	10
1.5 État de l’art des approches de modélisation et de prédiction des déformations faciales	11
1.5.1 Méthode de simulation biomécanique	11
1.5.2 Approches d’apprentissage automatique pour la prédiction des déformations	12
1.5.2.1 Modèles d’apprentissage classiques	12
1.5.2.2 Réseaux de neurones pour nuages de points : PointNet et PointNet++	15
1.5.2.3 Approches de déformation cohérente et non rigide	17
1.5.3 Méthodes de modélisation géométrique et topologique	20
1.5.3.1 Modèles de déformation géométrique	21
1.5.3.2 Réseaux de neurones graphiques (GNN)	23
1.5.3.3 Autoencodeurs variationnels graphiques	25
1.5.3.4 Intégration des contraintes physiques	26
1.6 Sommaire de la revue de littérature	28
CHAPITRE 2 PREDICTING FACIAL DEFORMATION DURING RESPIRATORY MASK FITTING WITH SEMI-SUPERVISED GRAPH NEURAL NETWORKS	31
2.1 Introduction	31
2.2 Related work	32
2.3 Materials and Methods	35
2.3.1 Dataset	35
2.3.2 Graph Construction	36
2.3.3 Model Architecture	39
2.3.4 Deformation Zone Classification Module	40
2.3.5 Enhanced Variational Graph Autoencoder Framework	41
2.3.6 Loss Functions	42
2.3.7 Semi-Supervised Training and Implementation Details	44
2.4 Results	45
2.4.1 Key Performance Indicators	45
2.4.2 Hyperparameter Sensitivity Analysis	49
2.4.3 Benchmarking Analysis	51

	2.4.3.1	Quantitative Benchmarking Analysis	51
	2.4.3.2	Qualitative Benchmarking Analysis	52
	2.4.4	Ablation Study	53
2.5		Discussion	57
	2.5.1	Interpretation of Key Results	57
	2.5.2	Comparison with Existing Methods	58
	2.5.3	Biomechanical Interpretation	58
	2.5.4	Limitations and future work	58
2.6		Conclusion	59
CHAPITRE 3 DISCUSSION			61
CONCLUSION ET RECOMMANDATIONS			67
ANNEXE I	PERSONALIZED FITTING OF RESPIRATORY MASK USING DEEP LEARNING AND 3D FACIAL MODELLING		69
ANNEXE II	COMPARAISON CRITIQUE DES APPROCHES EXISTANTES POUR LA MODÉLISATION DES DÉFORMATIONS FACIALES		79
BIBLIOGRAPHIE			83

LISTE DES TABLEAUX

	Page
Tableau 2.1	Primary Performance Metrics for the Proposed Model 46
Tableau 2.2	Quantitative Benchmarking of Deformation Models for 3D Facial Deformation Prediction 52
Tableau 2.3	Summary of Ablation Study Results : Quantitative impact of each component on deformation (RMSE, mm). Relative degradation (%) is measured against the full semi-supervised graph neural network model 54

LISTE DES FIGURES

	Page
Figure 0.1	Marques de pression faciale liées au port d'un masque 2
Figure 0.2	Classification des tailles de masques selon la morphologie faciale 3
Figure 0.3	Pipeline de personnalisation de l'ajustement des masques respiratoires par intelligence artificielle 6
Figure 1.1	Représentations faciales en 3D 8
Figure 1.2	Complexité morphologique du visage humain 9
Figure 1.3	Protocole pour la simulation de l'ajustement du masque 12
Figure 1.4	Validation qualitative des déformations 3D prédites par rapport aux résultats FEA 13
Figure 1.5	Analyse des indicateurs d'erreur de pression et de position pour le modèle Random Forest 14
Figure 1.6	Architecture du modèle PointNet 16
Figure 1.7	Architecture hiérarchique du modèle PointNet++ 17
Figure 1.8	Architecture du modèle Coherent Point Drift Network (CPD-Net) 18
Figure 1.9	Architecture du modèle Controlled Point Deformation Network (CDPNet) 20
Figure 1.10	Déformation de maillage 3D à l'aide d'un réseau de convolution graphique 24
Figure 2.1	Pipeline for Graph Construction and Feature Extraction in Face Mask Interaction Modeling 37
Figure 2.2	Overall architecture of the proposed two-stage model 40
Figure 2.3	Heat map of deformation errors per point (mm) under a mask tightening of 11 N 47
Figure 2.4	Heat map of pressure errors per point (kPa) under a mask tightening of 11 N 47

Figure 2.5	Histogram of Facial Deformation Distribution and Prediction Error under Mask Tightening (Force = 11 N)	48
Figure 2.6	Histogram of Predicted and Measured Pressure Ranges with Error under Mask Tightening (Force = 11 N)	49
Figure 2.7	Impact of Graph Connectivity on Deformation Error	50
Figure 2.8	Validation loss across learning rate values (log scale)	51
Figure 2.9	Qualitative error heatmaps of deformation prediction for Face 1 under 13 N tightening force	53
Figure 2.10	Training dynamics of the losses	56
Figure 2.11	Impact of loss weighting on predictive accuracy	57

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

AI	Artificial Intelligence (Intelligence artificielle)
3D	Three-Dimensional (Trois dimensions)
ARKit	Apple Augmented Reality Kit (Ensemble de développement de réalité augmentée pour iOS)
CAD	Computer-Aided Design (Conception assistée par ordinateur)
CNN	Convolutional Neural Network (Réseau de neurones convolutionnel)
CPD-Net	Coherent Point Drift Network (Réseau de dérive cohérente de points)
RF	Random forest(Forêt d'arbres de décision)
DT	Decision Tree(Arbres de décision)
ElasticNet	Elastic Network (Réseau élastique)
CDP-Net	Controlled Point Deformation Network (Réseau de déformation à points contrôlés)
DL	Deep Learning (Apprentissage profond)
FEA	Finite Element Analysis (Analyse par éléments finis)
GCN	Graph Convolutional Network (Réseau de convolution sur graphe)
GNN	Graph Neural Network (Réseau de neurones sur graphe)
ICP	Iterative Closest Point (Algorithme d'appariement itératif de points)
K-NN	K-Nearest Neighbors (Méthode des k plus proches voisins)
KL Divergence	Kullback–Leibler Divergence (Mesure de divergence entre distributions)
MAPE	Mean Absolute Percentage Error (Erreur absolue moyenne en pourcentage)
MAE	Mean Absolute Error (Erreur absolue moyenne)
ML	Machine Learning (Apprentissage automatique)
MLP	Multi-Layer Perceptron (Perceptron multicouche)
MPa	Megapascal (Unité de pression : 10^6 pascals)
PINN	Physics-Informed Neural Network (Réseau de neurones informé par la physique)
PPE	Personal Protective Equipment (Équipement de protection individuelle)
RMSE	Root Mean Square Error (Erreur quadratique moyenne)
STD	Standard Deviation (Écart-type)
TPS	Thin Plate Spline (Spline en Plate minces)
TPS-Net	Thin Plate Spline Network (Réseau neuronal basé sur la transformation TPS)
VGAE	Variational Graph Autoencoder (Autoencodeur variationnel sur graphe)
WHO	World Health Organization (Organisation mondiale de la santé)
OSHA	Occupational Safety and Health Administration (Agence américaine de santé et sécurité au travail)
CNESST	Commission des normes, de l'équité, de la santé et de la sécurité du travail (Québec)

LISTE DES SYMBOLES ET UNITÉS DE MESURE

E	Module d'Young (MPa)
ν	Coefficient de Poisson (sans unité)
R	Rayon de courbure local (mm)
δ_i	Déformation locale normalisée au point i
P_i	Pression de contact hertzienne au point i (kPa)
C	Constante de proportionnalité dans la loi de Hertz
x, y, z	Coordonnées spatiales 3D (mm)
$\mathbf{f}(x)$	Fonction de déformation non rigide
W	Matrice des coefficients de pondération pour TPS
A	Matrice affine (rotation, mise à l'échelle)
b	Vecteur de translation
$U(r)$	Fonction de base radiale des Thin Plate Splines
$\mathcal{L}$	Fonction de perte du modèle
R^2	Coefficient de détermination
σ	Déviation standard (STD)
λ	Coefficient de régularisation
$\mathbb{R}^3$	Espace tridimensionnel réel

INTRODUCTION

Les masques de protection respiratoire constituent un élément central des stratégies de prévention visant à réduire l'exposition aux polluants atmosphériques et aux agents infectieux, tant en milieu médical qu'industriel. Dans le contexte des soins de santé, ces dispositifs forment une barrière efficace contre la transmission des agents pathogènes, contribuant à la protection du personnel soignant et des patients (Ippolito *et al.*, 2020). En environnement industriel, leur port est également essentiel pour limiter l'inhalation de substances dangereuses susceptibles d'entraîner des pathologies respiratoires, comme le soulignent les recommandations de l'Occupational Safety and Health Administration (OSHA) (2024). À ce titre, les masques respiratoires sont reconnus comme des équipements de protection individuelle indispensables et font l'objet de cadres réglementaires stricts, notamment ceux de l'Organisation mondiale de la santé (World Health Organization (WHO), 2022).

Cependant, malgré leur rôle critique, les masques actuellement disponibles sur le marché présentent des limites importantes en matière d'ajustement facial. La majorité de ces dispositifs sont conçus selon des tailles standardisées : petit (S), moyen (M), grand (L), une approche qui ne prend pas en compte la grande variabilité morphologique de la population (Yu, Griffin, Durfee & Arnold, 2024). Or, la morphologie faciale est influencée par de multiples facteurs, tels que l'âge, le sexe, l'origine ethnique et les caractéristiques anatomiques individuelles (Martelly, Rana & Shimada, 2025; Lee, Lee, Yang & You, 2022). Cette inadéquation entre la géométrie du masque et celle du visage conduit fréquemment à des ajustements imparfaits.

Les conséquences de ce mauvais ajustement sont multiples : inconfort prolongé, irritations cutanées, douleurs localisées liées à des concentrations excessives de pression, difficultés respiratoires, et surtout perte d'étanchéité au niveau du joint masque et visage, compromettant directement l'efficacité protectrice du dispositif (Figure 0.1). Ces problématiques sont particulièrement

critiques lors d'un port prolongé, comme observé chez les professionnels de santé ou les travailleurs exposés à des environnements à risque.



Figure 0.1 Illustration des marques de pression cutanée observées après un port prolongé de masque respiratoire
Adaptée de (Boluk, 2021)

Comme l'illustre la Figure 0.2, les plages dimensionnelles associées aux tailles standard ne couvrent qu'une fraction des morphologies faciales existantes, laissant une proportion significative d'utilisateurs avec des masques inadaptés. Bien que plusieurs approches de personnalisation aient été proposées ces dernières années, celles-ci reposent majoritairement sur des simulations biomécaniques complexes telles que les méthodes par éléments finis afin de modéliser l'interaction du masque avec le visage (Taeckens *et al.*, 2022). Or, ces simulations sont coûteuses en calcul et nécessitent des temps de traitement importants, souvent incompatibles avec un usage clinique ou industriel en conditions réelles. Ces contraintes computationnelles limitent

fortement leur adoption à grande échelle et empêchent toute adaptation rapide ou interactive (Ardon-Dryer *et al.*, 2021). Il apparaît ainsi nécessaire de développer des méthodes alternatives capables de modéliser finement l'interaction entre la géométrie faciale et le masque tout en permettant une prédiction rapide, voire en temps quasi réel, afin d'optimiser simultanément confort, étanchéité et efficacité respiratoire.




Figure 0.2 Plages de dimensions des tailles de masques (Small(S), Medium (M), Large (L)) selon la largeur et la longueur du visage
Adaptée de (Lee *et al.*, 2022)

Face à ce constat, il devient crucial de développer des approches de personnalisation pour l'ajustement des masques respiratoires, capables de garantir à la fois confort et efficacité protectrice. L'hypothèse sous-jacente à ce projet est qu'il est possible de prédire de manière fiable la déformation faciale et les pressions de contact générées par un masque à partir d'une simple acquisition 3D du visage. Une telle approche, exploitant l'apprentissage profond et la modélisation biomécanique, permettrait de proposer des solutions accessibles, économiquement viables et adaptées à la diversité morphologique de la population.

La problématique de ce projet réside dans l'absence de solutions permettant de personnaliser l'ajustement des masques respiratoires de manière à la fois précise, biomécaniquement cohérente et compatible avec des contraintes de calcul en temps quasi réel. Les approches actuellement disponibles reposent soit sur des tailles standardisées insuffisantes pour couvrir la diversité morphologique faciale, soit sur des simulations biomécaniques complexes et coûteuses difficilement déployables en pratique. Dès lors, la question centrale de ce projet est de déterminer comment exploiter une simple acquisition 3D du visage afin de prédire de manière fiable les déformations faciales et les pressions de contact induites par le port d'un masque, sans recourir à des simulations numériques intensives, en vue de permettre une personnalisation rapide, robuste et généralisable de l'ajustement des masques respiratoires (Lee *et al.*, 2022; Taeckens *et al.*, 2022; Ardon-Dryer *et al.*, 2021).

L'objectif principal de ce mémoire est de développer une approche basée sur l'apprentissage automatique, capable de prédire la déformation faciale et les pressions de contact générées lors du port de masques respiratoires personnalisés.

Les principales contributions de ce mémoire se déclinent comme suit :

1. Développement d'un réseau de neurones graphiques (GNN) pour prédire simultanément la déformation 3D du visage et la pression de contact lors du port d'un masque.
2. Développement d'un pipeline en deux phases combinant un modèle XGBoost pour l'identification des zones de déformation et un autoencodeur variationnel sur graphe (VGAE) amélioré pour la prédiction simultanée de la déformation et de la pression, atteignant une précision submillimétrique.
3. Intégration explicite de la théorie de Hertz dans la fonction de perte, afin d'imposer une contrainte mécanique entre la force appliquée, la déformation locale et la pression prédite.

Ce projet est mené en collaboration avec **Numalogics**, une entreprise spécialisée dans la simulation biomécanique et la modélisation 3D. Ce partenariat constitue un atout majeur pour la présente recherche, l'expertise de Numalogics ayant permis la réalisation de simulations réalistes. Ces simulations fournissent les données de référence nécessaires au développement, à l'entraînement et à la validation des modèles proposés.

Le mémoire est organisé comme suit. Le premier chapitre présente une revue de littérature portant sur les enjeux liés à l'ajustement des masques respiratoires ainsi que sur les contributions récentes de la modélisation numérique et de l'intelligence artificielle appliquées à la personnalisation des dispositifs médicaux. La démarche méthodologique globale du projet est ensuite structurée autour de trois axes complémentaires, illustrés par le schéma de la Figure. Le premier axe concerne la création d'une base de données de visages complète. Le deuxième axe porte sur la prédiction de la déformation faciale à l'aide d'un modèle basé sur les *Thin Plate Spline Networks*. Ces deux axes sont détaillés dans un premier article scientifique accepté au journal *3DBODYTECH* et présenté à la conférence *2024 3DBODY.TECH Conference & Expo*, inclus en Annexe I.

Le troisième axe correspond à l'approche principale développée dans ce mémoire et fait l'objet du deuxième chapitre, qui contient un article scientifique soumis à la revue *Medical Engineering & Physics*. Ce chapitre présente une méthode semi-supervisée basée sur une représentation en graphe, permettant de prédire conjointement la déformation faciale et les pressions de contact. Enfin, le troisième chapitre propose une analyse approfondie des résultats expérimentaux obtenus, ainsi qu'une discussion des limites de l'approche et des perspectives d'amélioration.

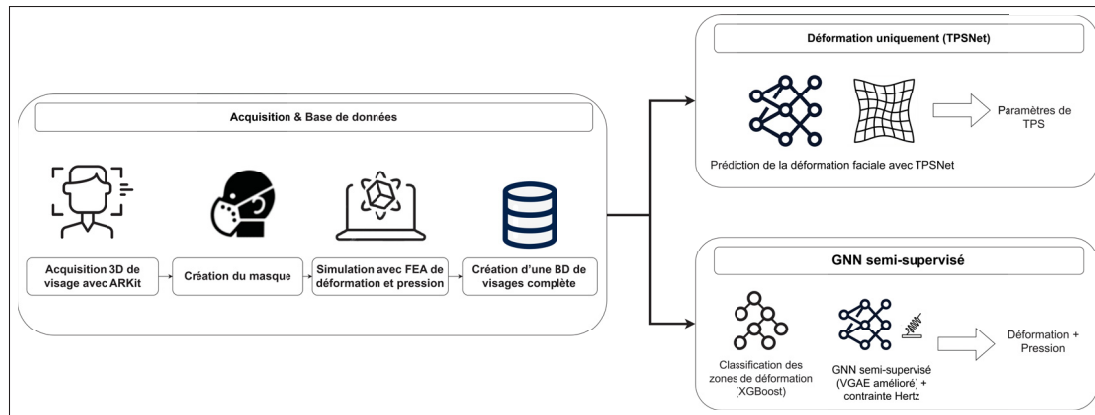


Figure 0.3 Pipeline de personnalisation de l'ajustement des masques respiratoires par intelligence artificielle

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 Introduction

Dans ce chapitre, nous présentons les fondements théoriques et expérimentaux nécessaires à la réalisation des objectifs de ce mémoire. Dans un premier temps, nous exposons les concepts essentiels liés à la modélisation morphologique du visage et à la déformation tridimensionnelle. Nous abordons ensuite l'état de l'art selon trois axes : les méthodes de simulation biomécanique, les approches d'apprentissage automatique appliquées à la prédiction de déformations, et les techniques dédiées à la modélisation géométrique.

1.2 La représentation 3D du visage

La représentation tridimensionnelle du visage consiste à créer un modèle 3D capable de capturer à la fois les traits généraux et la morphologie unique de chaque individu. Les principales méthodes de représentation 3D peuvent être regroupées en trois catégories (Gao, Ruan, Shi & Zhou, 2022) :

- Le nuage de points est une collection discrète de points représentant la surface externe et la structure interne d'un objet. Chaque point est défini par trois coordonnées spatiales (x, y, z) qui localisent précisément sa position dans l'espace tridimensionnel. Cette représentation est généralement obtenue à partir des acquisitions 3D capables de capturer plusieurs millions de points, offrant ainsi un niveau de détail élevé sur la morphologie faciale.
- Les voxels modélisent le volume du visage en le divisant en cellules cubiques régulières, analogues à des pixels en trois dimensions.
- Les maillages polygonaux décrivent la surface du visage à l'aide de sommets, d'arêtes et de faces (souvent triangulaires), permettant une modélisation continue et structurée de la géométrie (Figure 1.1).




Figure 1.1 Exemples de représentations de modèles 3D : nuages de points, voxels et maillages polygonaux
Tirée de (Gao *et al.*, 2022)

Comparativement aux voxels, qui nécessitent une discrétisation volumétrique coûteuse en mémoire et entraînent une perte de résolution spatiale, le nuage de points permet de préserver la finesse géométrique du visage sans interpolation volumique (Maturana & Scherer, 2015). De plus, contrairement aux maillages polygonaux qui exigent une connectivité topologique explicite entre les sommets, cette représentation reste flexible, facilitant son intégration dans les architectures d'apprentissage profond (Zhang & Chen, 2001).

Plusieurs travaux ont démontré que les nuages de points constituent une représentation plus fidèle et efficace que les modèles maillés ou voxelisés pour la modélisation de formes complexes. En effet, ils conservent directement les données issues du capteur sans étape de reconstruction susceptible d'altérer la géométrie réelle (Park & Lee, 2019; Bassier, Vergauwen & Poux, 2020). Ils offrent également une meilleure adaptabilité pour l'apprentissage automatique, car ils ne nécessitent ni maillage ni volume prédéfini, tout en restant léger et rapide à traiter (Peng *et al.*, 2021).

Ainsi, le nuage de points constitue la représentation la plus appropriée pour ce travail car il permet de capturer avec précision la géométrie faciale tridimensionnelle tout en offrant une modélisation efficace des déformations locales induites par l'application du masque.

1.3 Morphologie faciale et modélisation 3D

La morphologie du visage humain présente une complexité géométrique considérable, résultant de l'interaction entre les structures osseuses rigides, les masses musculaires et les tissus mous (Kähler, Haber & Seidel, 2003). Une illustration de cette complexité est présentée à la Figure 1.2.




Figure 1.2 Représentation tridimensionnelle illustrant la complexité morphologique du visage humain
Adaptée de (Kähler *et al.*, 2003)

La représentation tridimensionnelle de cette géométrie nécessite l'extraction de descripteurs adaptés, capables de caractériser à la fois la structure globale et les variations locales de la surface faciale. Les caractéristiques spatiales reposent sur les coordonnées brutes $[X_i, Y_i, Z_i]^T$,

traduisant la morphologie générale, et peuvent être enrichies par des vecteurs de position relatifs ainsi que par des mesures de variance locale décrivant la dispersion des points de voisinage.

Ces indicateurs sont essentiels pour distinguer les zones planes des zones courbes ou irrégulières, souvent associées à des concentrations locales de pression (Bustos, Keim, Saupe, Schreck & Vranić, 2005). Les descripteurs géométriques, dérivés de l'analyse spectrale des matrices de covariance locales, permettent d'extraire des mesures normalisées telles que la linéarité, la planéité et la sphéricité. Ces paramètres se sont avérés particulièrement pertinents pour différencier les arêtes marquées (par exemple, la crête nasale), les surfaces planes (comme les joues) et les zones arrondies (telles que le menton) (Pauly, Keiser & Gross, 2003; Zhang & Chen, 2001).

L'intégration conjointe de ces descripteurs constitue ainsi une étape fondamentale pour modéliser et analyser la réaction du visage suite à un contact avec le masque.

1.4 Déformation rigide et non rigide

La déformation tridimensionnelle d'un objet correspond à une transformation géométrique modifiant sa forme ou sa position dans l'espace. On distingue généralement deux grandes catégories :

- La déformation rigide est une transformation qui préserve les distances et les angles entre les points d'un objet. Elle correspond uniquement à des rotations et des translations. Autrement dit, l'objet change de position ou d'orientation, mais sa forme et ses dimensions internes restent inchangées. Ces transformations sont principalement utilisées pour l'alignement de modèles tridimensionnels, comme dans l'algorithme *Iterative Closest Point* (ICP) qui estime la transformation rigide optimale entre deux ensembles de points en minimisant leurs distances moyennes (Besl & McKay, 1992) .
- La déformation non rigide est une transformation qui altère la forme interne de l'objet, en autorisant des variations locales de distances ou d'angles. Elle permet de représenter des phénomènes physiques réalistes, comme les déformations des tissus mous du visage soumis à une contrainte mécanique. Ce type de déformation est continu, non uniforme et dépend de la

région anatomique considérée. l'algorithme le plus reconnu de cette transformation est Spline en Plate minces (*Thin plate spline* TPS) (Bookstein, 2002). Ainsi, les déformations rigides traduisent un déplacement global sans altération de la forme, tandis que les déformations non rigides modélisent les changements réels de géométrie observés lors d'une interaction mécanique ou physiologique.

1.5 État de l'art des approches de modélisation et de prédiction des déformations faciales

Cette section présente les principales approches de modélisation et de prédiction des déformations faciales, en distinguant les méthodes biomécaniques, les techniques d'apprentissage automatique et les modèles géométriques et topologiques récents.

1.5.1 Méthode de simulation biomécanique

Plusieurs études menées par notre groupe de recherche se sont intéressées aux méthodes de conception de masques respiratoires sur mesure, spécifiquement adaptés à la morphologie faciale des utilisateurs. Ce processus repose sur une application mobile intégrant la technologie de numérisation 3D via ARKit, permettant d'acquérir rapidement et avec précision la géométrie du visage (Agostini, Castonguay-Henri, Viens, Borduas & Duong, 2022).

L'étape suivante consiste en une analyse par éléments finis (FEA), visant à simuler les interactions mécaniques entre le masque et le visage, comme illustré à la Figure 1.3. Cette approche permet d'évaluer la distribution des pressions de contact ainsi que les zones potentielles de déformation au niveau des contours du masque pour différentes forces de serrage. Les tissus mous du visage sont modélisés par des lois de comportement non linéaires isotropes, couramment utilisées pour approximer la réponse mécanique globale des tissus biologiques sous de faibles et moyennes déformations, tandis que le masque est représenté comme une structure rigide dotée d'une interface en silicone modélisée comme un matériau flexible. Ces simulations permettent de générer des cartes de pression et d'étanchéité, essentielles pour évaluer le confort et l'efficacité du dispositif (Taeckens *et al.*, 2022).




Figure 1.3 Protocole pour la simulation de l’ajustement du masque
Tirée de (Taeckens *et al.*, 2022)

Bien que la méthode des éléments finis (FEA) fournisse une modélisation détaillée des interactions entre le masque et le visage, son utilisation à grande échelle demeure limitée en raison de son coût computationnel élevé. En effet, selon la complexité du maillage et des conditions aux limites, une simulation complète peut nécessiter de plusieurs dizaines de minutes à plusieurs heures de calcul et de post-traitement (Taylor, Cheng & Ourselin, 2008). Dans le cas d’une simulation typique de l’interaction masque–visage, la durée moyenne est d’environ 30 minutes.

1.5.2 Approches d’apprentissage automatique pour la prédiction des déformations

Cette section examine les approches d’apprentissage automatique développées pour prédire les déformations faciales, en mettant d’abord l’accent sur les modèles classiques, puis sur les réseaux neuronaux profonds capables d’exploiter la complexité des données tridimensionnelles.

1.5.2.1 Modèles d’apprentissage classiques

Dans le but d’automatiser le processus de personnalisation en temps réel, une approche d’apprentissage automatique dédiée à la prédiction des pressions de contact et des déformations faciales induites par le port de masques respiratoires a été proposée (Al Habash, Hachem,

Taeckens, Degueldre & Duong, 2024). Trois modèles ont été comparés : Forêt d'arbres de décision (RF), Arbre de décision (DT) et Réseau élastique (ElasticNet). Parmi eux, le modèle RF a obtenu les meilleures performances globales, avec une erreur quadratique moyenne (RMSE) de 1,875 et une erreur absolue moyenne en pourcentage (MAPE) de 0,169, respectant ainsi un seuil de tolérance de 5 %. La Figure 1.4 illustre les résultats de prédiction de la déformation obtenus avec Random Forest.




Figure 1.4 Validation qualitative des déformations 3D prédites par rapport aux résultats obtenus par analyse par éléments finis FEA

Tirée de (Al Habash *et al.*, 2024)

L'évaluation par région faciale a révélé différentes zones anatomiques où l'erreur est élevée et d'autres où elle est plus faible, comme indiqué à la Figure 1.5. Les régions centrales, relativement rigides, telles que le nez (RMSE = 0,66) et la moustache (RMSE = 0,76), présentent les erreurs les plus faibles. Toutefois, ces régions sont associées à des amplitudes de déformation limitées, ce qui implique que même des RMSE faibles peuvent représenter une part importante de la déformation réelle. En revanche, les régions plus déformables, comme le cou (RMSE = 2,56)

et la joue gauche (RMSE = 1,83), affichent des erreurs plus élevées, traduisant la difficulté du modèle à prédire avec précision de faibles déformations locales.

L'analyse statistique confirme que seules deux zones l'œil droit et le nez donnent des résultats significatifs ($p = 0,001$), tandis que les autres régions ne présentent pas de différences notables. Par ailleurs, les erreurs relatives varient fortement, allant de 0,0 % pour la bouche à 37,3 % pour le cou, ce qui met en évidence la difficulté des modèles traditionnels à capturer uniformément les propriétés biomécaniques faciales.

	RMSE	MAPE (%)		MAE	
		P	Coord	P	Coord
Left eye	1.599	0.106	0.334	-	0.934
Right eye	1.196	0.13	0.21	0.001	0.875
Left cheek	1.83	0.206	0.245	-	1.205
Right cheek	1.585	0.193	0.218	-	1.181
Nose	0.662	0.246	0.065	0.001	0.453
Mustache	0.759	0.036	0.048	-	0.485
Mouth	1.169	0.0	0.335	-	0.656
Chin	1.806	0.165	0.844	-	1.373
Neck	2.555	0.373	0.132	-	2.011
Forehead	2.101	0.002	0.245	-	1.436
Global	1.875	0.169	0.258	-	1.344

Figure 1.5 Analyse des indicateurs d'erreur de pression et de position pour le modèle Random Forest selon les différentes régions du visage

Tirée de (Al Habash *et al.*, 2024)

Bien que le modèle Random Forest (RF) permette de prédire les déformations faciales, il présente plusieurs limites importantes. Cette approche ne prend pas en compte la dynamique spatiale des déformations, c'est-à-dire la manière dont les déplacements des points d'une région du visage sont corrélés et influencés par la structure anatomique voisine. Autrement dit, le modèle traite chaque point de manière indépendante, sans considérer la continuité géométrique ni les interactions locales entre les tissus, ce qui se traduit par une perte de cohérence spatiale. En conséquence, des erreurs localisées apparaissent dans certaines zones du visage, en particulier dans les régions

souples et fortement déformables. Les principales causes sont les suivantes : Tout d’abord, les données issues des acquisitions 3D avec ARKit sont structurées et relativement précises par rapport aux autres technologies de numérisation 3D mobiles évaluées dans la littérature pour la personnalisation de masques respiratoires. En particulier, les acquisitions ARKit présentent une fiabilité élevée, avec des erreurs de mesure de l’ordre du millimètre, jugées compatibles avec les exigences de conception et d’ajustement de masques respiratoires personnalisés (Borduas, Castonguay, Laurin & Beland, 2020). Cependant, elles demeurent partiellement incomplètes dans certaines zones, notamment autour du menton et du cou, en raison des limitations de champ de vision et des conditions d’éclairage. Ces lacunes peuvent accentuer les imprécisions du modèle, particulièrement dans les régions soumises à de fortes déformations. Dans ce contexte, plusieurs architectures d’apprentissage profond ont été développées spécifiquement pour traiter les nuages de points 3D, en tant que représentations directes d’un objet.

1.5.2.2 Réseaux de neurones pour nuages de points : PointNet et PointNet++

Le modèle PointNet a marqué une avancée significative dans le traitement direct des nuages de points bruts (Qi, Su, Mo & Guibas, 2017a). Il traite le nuage de points comme un ensemble non ordonné, où chaque point est analysé indépendamment par un perceptron multicouche partagé, avant qu’une opération de *max pooling* n’agrège l’ensemble des informations en un descripteur global invariant à la permutation des points, comme illustrés à la Figure 1.6. Cette architecture met ainsi en évidence le caractère essentiellement global de la représentation apprise.

Cependant, dans le cadre de la modélisation des déformations non rigides, cette approche purement globale ne prend pas en compte les dépendances spatiales entre points voisins, ce qui limite la capacité du modèle à représenter les variations locales de forme et de structure.




Figure 1.6 Architecture du modèle PointNet
Tirée de (Qi *et al.*, 2017a)

Pour pallier cette limitation, PointNet++ a été introduit comme une extension hiérarchique du modèle original reposant sur l'application récursive de PointNet à des voisinages locaux définis à l'aide de la méthode des k plus proches voisins (Qi, Yi, Su & Guibas, 2017b). Chaque niveau du réseau réalise une étape d'abstraction d'ensemble combinant échantillonnage, regroupement spatial et apprentissage local, permettant d'analyser le nuage de points à différentes échelles spatiales, comme illustré à la Figure 1.7. Cette approche multiéchelle permet ainsi de capturer simultanément les structures locales et globales des nuages de points, améliorant la représentation géométrique des objets complexes.




Figure 1.7 Architecture hiérarchique du modèle PointNet++
Tirée de (Qi et al., 2017b)

PointNet constitue une avancée majeure dans le traitement direct des nuages de points, en permettant une extraction efficace des caractéristiques globales. Toutefois, son absence de mécanismes pour modéliser les relations locales entre points voisins limite son application dans le cadre des déformations non rigides (Qi et al., 2017b).

PointNet++ remédie à cette faiblesse grâce à sa hiérarchie multiéchelle, qui combine les informations globales et locales pour une représentation plus fine de la géométrie. Néanmoins, ces architectures demeurent sensibles à la densité d'échantillonnage et au manque des données issues d'appareil de capture 3D (Bytyqi, Wolpert & Schömer, 2020). De plus, elles reposent exclusivement sur des descripteurs géométriques, sans intégrer les contraintes physiques ou biomécaniques inhérentes à l'interaction masque-visage, telles que les forces de contact ou la rigidité des tissus.

1.5.2.3 Approches de déformation cohérente et non rigide

Parallèlement, des approches non supervisées telles que CPD-Net (*Coherent Point Drift Network*) apprennent un champ de déplacement continu entre deux ensembles de points source et cible, tout

en imposant une cohérence spatiale et topologique des correspondances (Wang, Li, Chen & Fang, 2019).

L'architecture, illustrée à la Figure 1.8, met en évidence le principe général de CPD-Net, qui vise à apprendre un champ de déplacement continu entre un nuage de points sources et un nuage cible. Le modèle repose sur l'extraction et l'agrégation de descripteurs globaux, suivies d'un module de déformation cohérente imposant une régularité spatiale des transformations. Cette conception permet de modéliser des déformations non rigides tout en préservant la continuité anatomique et la cohérence locale des structures lors de la transformation de la surface faciale.




Figure 1.8 Architecture du modèle CPD-Net
Tirée de (Wang *et al.*, 2019)

Malgré ses contributions notables à la modélisation des déformations non rigides, CPD-Net présente plusieurs limites lorsqu'il est appliqué au contexte biomécanique de la déformation faciale induite par le port d'un masque respiratoire.

Premièrement, le modèle demeure fortement dépendant de la qualité et de la densité des correspondances initiales entre les points source et cible. Cette dépendance le rend sensible aux données incomplètes issues des numérisations ARKit, ce qui entraîne une perte de précision dans les zones faciales complexes, notamment le cou.

Deuxièmement, le cadre non supervisé de CPD-Net repose exclusivement sur des contraintes géométriques et de cohérence topologique, sans prise en compte explicite des lois biomécaniques. Comme illustré à la Figure 1.8, le modèle apprend un champ de déplacement à partir de descripteurs géométriques globaux, sans être conditionné par des forces externes. Cette absence de couplage avec des informations mécaniques limite sa capacité à reproduire fidèlement les déformations induites par la pression localisée exercée par un masque respiratoire.

Une approche relevant de la même famille de modèles de déformation cohérente et non rigide a été proposée pour la modélisation de déformations contrôlées par des propriétés géométriques, appliquée à la prédiction de la forme postopératoire de la colonne vertébrale (Khani, Debanné, Labelle, Parent & Cheriet, 2023). Le *Controlled Point Deformation Network* (CDPNet) exploite conjointement les caractéristiques géométriques et des informations cliniques afin de contraindre l'apprentissage des transformations entre des repères vertébraux tridimensionnels.

Comme le montre la Figure 1.9, les descripteurs extraits du modèle préopératoire sont combinés à des métadonnées cliniques pour prédire les vecteurs de déplacement 3D menant à la géométrie post-opératoire. Deux fonctions de perte complémentaires, l'une géométrique et l'autre liée à la transformation rigide, sont utilisées afin de guider le réseau vers une représentation anatomiquement et biomécanique cohérente de la déformation du rachis.




Figure 1.9 Architecture du modèle Controlled Point Deformation Network (CDPNet)

Tirée de (Khani *et al.*, 2023)

L'approche CDPNet illustre la capacité d'un réseau à intégrer simultanément des contraintes géométriques et des informations cliniques. Bien que ces métadonnées soient intrinsèquement liées à la morphologie et non externes au système étudié, elles offrent une perspective intéressante pour enrichir les modèles de déformation. En effet, leur intégration démontre comment des informations structurelles additionnelles peuvent être exploitées pour améliorer la cohérence anatomique, ouvrant ainsi la voie à l'adaptation de ce principe à d'autres formes de déformations, notamment faciales.

1.5.3 Méthodes de modélisation géométrique et topologique

Cette section présente les principales approches de modélisation géométrique et topologique utilisées pour représenter les déformations allant des modèles analytiques classiques aux réseaux de neurones graphiques informés par la physique.

1.5.3.1 Modèles de déformation géométrique

Les modèles de déformation par splines en plaques minces (TPS), offrent un cadre mathématique rigoureux pour représenter des changements de forme continus et lisses à partir d'un ensemble de points de contrôle, constituant ainsi une base fondamentale pour la modélisation précise des déformations non rigides du visage (Bookstein, 2002; Rohr *et al.*, 2002).

Une transformation non rigide tridimensionnelle peut s'écrire, de manière générale, comme :

$$\mathbf{T}(\mathbf{x}) = \mathbf{Ax} + \mathbf{b} + \mathbf{f}(\mathbf{x}), \quad \mathbf{x} \in \mathbb{R}^3. \quad (1.1)$$

où $\mathbf{A} \in \mathbb{R}^{3 \times 3}$ représente la composante affine (rotation et mise à l'échelle), $\mathbf{b} \in \mathbb{R}^3$ est le vecteur de translation, et $\mathbf{f}(\mathbf{x})$ désigne la déformation non linéaire à estimer.

Les TPS généralisent ce cadre pour interpoler les déformations à partir d'un ensemble de points de contrôle $\{(\mathbf{x}_i, \mathbf{y}_i, \mathbf{z}_i)\}_{i=1}^N$ définis dans $\mathbb{R}^3$ (Bookstein, 2002). La transformation TPS s'écrit alors :

$$\mathbf{f}(\mathbf{x}) = \mathbf{W}^\top \mathbf{U}(\mathbf{x}) + \mathbf{Ax} + \mathbf{b}, \quad (1.2)$$

avec

$$\mathbf{U}(\mathbf{x}) = \begin{bmatrix} U(\|\mathbf{x} - \mathbf{x}_1\|) \\ \vdots \\ U(\|\mathbf{x} - \mathbf{x}_N\|) \end{bmatrix}, \quad (1.3)$$

et la fonction de base radiale pour le cas tridimensionnel :

$$U(r) = -r, \quad \text{où } r = \|\mathbf{x} - \mathbf{x}_i\|. \quad (1.4)$$

Les coefficients $\mathbf{W} \in \mathbb{R}^{N \times 3}$, $\mathbf{A}$ et $\mathbf{b}$ sont obtenus en minimisant l'énergie de courbure tridimensionnelle :

$$E(f) = \iiint_{\mathbb{R}^3} \left[\left(\frac{\partial^2 f}{\partial x^2} \right)^2 + \left(\frac{\partial^2 f}{\partial y^2} \right)^2 + \left(\frac{\partial^2 f}{\partial z^2} \right)^2 + 2 \left(\left(\frac{\partial^2 f}{\partial x \partial y} \right)^2 + \left(\frac{\partial^2 f}{\partial x \partial z} \right)^2 + \left(\frac{\partial^2 f}{\partial y \partial z} \right)^2 \right) \right] dx dy dz. \quad (1.5)$$

La minimisation de $E(f)$ conduit au système linéaire couplant les coefficients de pondération $\mathbf{w}$ et les paramètres affines $\mathbf{a}$:

$$\begin{bmatrix} \mathbf{K} & \mathbf{P} \\ \mathbf{P}^\top & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{w} \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} \mathbf{v} \\ \mathbf{0} \end{bmatrix}, \quad (1.6)$$

où

$$\mathbf{P} = \begin{bmatrix} 1 & p_{1x} & p_{1y} & p_{1z} \\ 1 & p_{2x} & p_{2y} & p_{2z} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & p_{Nx} & p_{Ny} & p_{Nz} \end{bmatrix}, \quad K_{ij} = \phi(\|p_i - p_j\|) = U(\|p_i - p_j\|).$$

Les coefficients $\mathbf{w}$ et $\mathbf{a}$ sont ensuite déterminés en résolvant le système (1.6) par inversion matricielle, puis remplacés dans l'équation de déformation (équation 1.7) .

Ainsi, la fonction de déformation tridimensionnelle s'écrit :

$$f(x, y, z) = a_1 + a_2x + a_3y + a_4z + \sum_{i=1}^N w_i U(\|P_i - (x, y, z)\|), \quad (1.7)$$

avec $U(r) = -r$.

Cette formulation garantit une déformation continue et globalement cohérente, tout en permettant une variabilité locale contrôlée. Dans le contexte de l'ajustement d'un masque respiratoire, ce modèle reproduit fidèlement les déformations des tissus faciaux.

Les TPS offrent une interpolation lisse adaptée aux tissus mous, mais leur coût de calcul est élevé et leurs paramètres dépendent fortement de la morphologie faciale. Ces déformations sont essentielles pour le recalage et l'analyse de formes 3D complexes, là où les modèles rigides montrent leurs limites (Deng, Yao, Dyke & Zhang, 2022) .

1.5.3.2 Réseaux de neurones graphiques (GNN)

Un graphe $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ est une structure mathématique composée d'un ensemble de nœuds $\mathcal{V}$ et d'un ensemble d'arêtes $\mathcal{E}$ décrivant les relations entre ces nœuds. Dans le cadre de la modélisation tridimensionnelle du visage, chaque nœud représente un point de la surface faciale défini par ses coordonnées (x, y, z) ou par un descripteur géométrique tandis que les arêtes traduisent les relations de voisinage, généralement établies à l'aide d'un algorithme des k -plus proches voisins (k -NN) (Bronstein, Bruna, LeCun, Szlam & Vandergheynst, 2017).

Dans l'étude de Wang et al., le maillage 3D est modélisé comme un graphe non orienté $G = (V, E)$, où chaque sommet $v_i \in V$ correspond à un point du maillage et chaque arête $(v_i, v_j) \in E$ exprime une relation géométrique de proximité. Chaque nœud est associé à un vecteur de caractéristiques $h_i^{(l)} \in \mathbb{R}^d$ à la couche l du réseau (Wang & Chang, 2019).

La convolution sur graphe généralise la convolution euclidienne classique en agrégeant les informations locales selon la connectivité du graphe. Elle peut être formulée comme suit :

$$h_i^{(l+1)} = \sigma \left(\sum_{j \in \mathcal{N}(i) \cup \{i\}} \frac{1}{\sqrt{d_i d_j}} \mathbf{W}^{(l)} h_j^{(l)} \right), \quad (1.8)$$

où $\mathcal{N}(i)$ désigne le voisinage du nœud v_i , d_i et d_j représentent les degrés des sommets correspondants, $\mathbf{W}^{(l)}$ est la matrice de poids apprise à la couche l , et $\sigma(\cdot)$ est une fonction d'activation non linéaire. Cette opération permet à chaque nœud de propager et d'agréger les informations issues de ses voisins selon la topologie locale, assurant ainsi la capture des dépendances spatiales à la fois locales et globales dans la géométrie du maillage.

L'architecture proposée repose sur un schéma encodeur-décodeur avec connexions de saut, inspiré de l'architecture U-Net (Wang & Chang, 2019). Elle apprend à déformer un maillage d'entrée grossier en un maillage raffiné, comme illustré à la Figure 1.10. Les fonctions de perte de Chanfrein et de Laplacien sont utilisées respectivement pour assurer la précision géométrique et la régularité de la surface.




Figure 1.10 Architecture de prédiction de déformation de maillage 3D à l'aide d'un réseau de convolution graphique
Tirée de (Wang & Chang, 2019)

Bien que ce cadre permette une prédiction tridimensionnelle, fidèle et topologiquement cohérente, il présente des limites notables. En effet, le modèle repose sur une modélisation purement géométrique : il apprend à ajuster la position des sommets d'un maillage en minimisant des distances géométriques avec la perte de Chanfrein et des critères de régularité de surface avec la perte de Laplacien, sans intégrer explicitement les lois biomécaniques régissant les interactions entre le masque et les tissus mous du visage (Wang & Chang, 2019) .

Ainsi, les forces de contact appliquées sur la peau, la rigidité élastique des différentes régions faciales et les contraintes de continuité mécanique ne sont pas modélisées. Le réseau apprend des correspondances géométriques entre les formes avant et après déformation, mais ne capture ni la relation de causalité entre la force appliquée et la déformation observée ni la propagation mécanique à travers les structures anatomiques sous-jacentes.

Ces limitations soulignent la nécessité d'intégrer des contraintes physiques dans les architectures de GNN afin d'améliorer la fidélité biomécanique des prédictions, en particulier dans le contexte de l'ajustement personnalisé des masques respiratoires.

1.5.3.3 Autoencodeurs variationnels graphiques

Les autoencodeurs variationnels graphiques (VGAE) combinent les principes de l'apprentissage variationnel et des réseaux de neurones graphiques (GCN) afin de produire des représentations latentes probabilistes des graphes (Kipf & Welling, 2016; Zhou *et al.*, 2020). Leur objectif est d'apprendre une distribution latente $q_\phi(\mathbf{Z} \mid \mathbf{X}, \mathbf{A})$ sur l'espace des graphes, où $\mathbf{X}$ représente les caractéristiques des nœuds et $\mathbf{A}$ la matrice d'adjacence décrivant la topologie du maillage.

Contrairement aux autoencodeurs classiques, le VGAE n'encode pas une représentation déterministe, mais approxime une distribution latente gaussienne définie par un vecteur de moyennes $\boldsymbol{\mu}$ et d'écart types $\boldsymbol{\sigma}$:

$$q_\phi(\mathbf{Z} \mid \mathbf{X}, \mathbf{A}) = \prod_{i=1}^N \mathcal{N}(\mathbf{z}_i \mid \boldsymbol{\mu}_i, \text{diag}(\boldsymbol{\sigma}_i^2)), \quad (1.9)$$

où chaque $\mathbf{z}_i$ correspond à la variable latente associée au nœud v_i . Le décodeur reconstruit ensuite les liens topologiques du graphe ou les caractéristiques spatiales des sommets à partir de ces variables latentes, selon une distribution $p_\theta(\mathbf{A} \mid \mathbf{Z})$ ou $p_\theta(\mathbf{X} \mid \mathbf{Z})$.

L'apprentissage du modèle repose sur la maximisation de la borne inférieure de vraisemblance qui combine un terme de reconstruction et un terme de régularisation par divergence de (KL) entre la distribution postérieure q_ϕ et la distribution a priori $p(\mathbf{Z})$:

$$\mathcal{L} = \mathbb{E}_{q_\phi(\mathbf{Z} \mid \mathbf{X}, \mathbf{A})} [\log p_\theta(\mathbf{A} \mid \mathbf{Z})] - \text{KL}(q_\phi(\mathbf{Z} \mid \mathbf{X}, \mathbf{A}) \parallel p(\mathbf{Z})). \quad (1.10)$$

Cette régularisation par divergence KL contraint l'espace latent à demeurer continu, compact et régulier, favorisant une interpolation fluide entre différentes configurations du graphe. Dans un

cadre biomécanique, cette propriété est particulièrement intéressante : elle permet de modéliser la variabilité des déformations faciales en fonction de paramètres physiques (forces de serrage, rigidité tissulaire, morphologie locale) et de générer des scénarios plausibles de déformation en interpolant entre plusieurs états physiologiques. Le VGAE offre ainsi un cadre probabiliste apte à représenter les incertitudes et la diversité des comportements faciaux sous contrainte mécanique.

Malgré son potentiel, le VGAE présente plusieurs limites. Premièrement, la distribution latente gaussienne adoptée dans la formulation classique s'avère souvent trop restrictive pour capturer la non-linéarité des relations entre les forces appliquées, les pressions résultantes, les contraintes internes et les déformations tissulaires. Deuxièmement, le modèle demeure essentiellement géométrique et ne prend pas en compte les lois de contact entre surfaces, ce qui compromet la cohérence physique des prédictions. Troisièmement, la régularisation par divergence KL, bien qu'indispensable pour garantir la continuité de l'espace latent, tend à surlisser les représentations et à réduire la sensibilité du modèle aux zones de forte déformation.

Enfin, le VGAE ne tient pas explicitement compte des forces de contact externes ni des interactions entre deux surfaces masque et visage, ce qui limite sa capacité à prédire des déformations mécaniquement plausibles dans des conditions de port prolongé.

1.5.3.4 Intégration des contraintes physiques

Les développements récents des réseaux de neurones sur graphes encodés physiquement constituent une avancée notable dans la modélisation des déformations tridimensionnelles. Ces approches se distinguent par l'intégration explicite des lois physiques au sein de la structure même du graphe en incorporant directement les forces, les contraintes et les paramètres mécaniques locaux dans les nœuds et les arêtes. Contrairement aux GNN purement géométriques, cette intégration vise à produire des prédictions conformes aux principes fondamentaux de la mécanique des milieux continus (Saleh, Sommersperger, Navab & Tombari, 2024).

Dans ce cadre, chaque nœud v_i du graphe est enrichi d'un vecteur d'état physique :

$$\mathbf{h}_i = [\mathbf{x}_i, \mathbf{f}_i, \boldsymbol{\sigma}_i, \mathbf{n}_i], \quad (1.11)$$

où $\mathbf{x}_i$ représente la position du sommet, $\mathbf{f}_i$ la force locale appliquée, $\boldsymbol{\sigma}_i$ le tenseur de contrainte estimé, et $\mathbf{n}_i$ la normale de surface. Les arêtes (v_i, v_j) sont quant à elles associées à des attributs décrivant la rigidité relative ou les interactions mécaniques entre régions voisines, telles que la raideur k_{ij} ou le coefficient de friction μ_{ij} .

La propagation des messages à travers le graphe s'effectue selon une fonction de mise à jour qui combine les informations géométriques et physiques :

$$\mathbf{h}_i^{(l+1)} = \phi_\theta \left(\mathbf{h}_i^{(l)}, \sum_{j \in \mathcal{N}(i)} \psi_\theta \left(\mathbf{h}_i^{(l)}, \mathbf{h}_j^{(l)}, \mathbf{e}_{ij} \right) \right), \quad (1.12)$$

où ϕ_θ et ψ_θ sont des réseaux de neurones paramétriques assurant respectivement la mise à jour du nœud et la propagation des interactions physiques entre voisins.

Une autre innovation majeure de cette approche réside dans l'introduction de mécanismes d'attention croisée entre graphes hétérogènes (rigide et déformable). Cette attention multitête permet de modéliser de manière différenciable les interactions entre un objet rigide et une structure souple. Chaque sommet du graphe déformable reçoit des messages pondérés provenant du graphe rigide selon la proximité géométrique et l'intensité des forces de contact, permettant ainsi au modèle d'apprendre la dynamique complexe du couplage rigide et mou. Cette approche améliore la cohérence mécanique et réduit les artefacts non physiques, tout en favorisant une généralisation robuste à divers scénarios de contact.

Le cadre proposé présente un potentiel notable pour la modélisation biomécanique, l'intégration explicite des forces et des contraintes dans la structure du graphe permettant d'obtenir des prédictions plus conformes à la réalité physique et des déformations mécaniquement plausibles (Saleh *et al.*, 2024).

Néanmoins, cette approche demeure fondée sur une supervision explicite des paramètres physiques, nécessitant l'accès à des données d'entraînement riche en mesure de force, de contrainte et de déformation, souvent issues de simulations par éléments finis (FEM) ou de capteurs spécialisés. Dans notre contexte, où les données de pression faciale ne sont que partiellement disponibles, un tel modèle serait difficile à entraîner pour prédire les déformations.

1.6 Sommaire de la revue de littérature

L'analyse critique des approches existantes met en évidence plusieurs lacunes majeures détaillées au tableau II-1 dans l'Annexe II. D'une part, les méthodes physiques comme la Finite Element Analysis (FEA) offre une modélisation détaillée des interactions mécaniques entre le masque et le visage, permettant d'obtenir des cartes de pression précises et réalistes. Cependant, leur coût computationnel très élevé les rend inadaptées aux applications nécessitant des prédictions rapides ou interactives. En pratique, une seule simulation FEA nécessite environ 30 minutes, ce qui empêche toute intégration dans un processus de personnalisation immédiate.

Or, l'objectif du présent travail est de développer un modèle capable de fournir en temps réel les cartes de pression et les déformations faciales, afin que le client ou le professionnel puisse générer et imprimer le masque optimal correspondant à la morphologie spécifique du visage en quelques instants seulement après la numérisation 3D.

À l'inverse, les modèles classiques d'apprentissage automatique tels que le Random Forest ou l'Elastic Net offrent une rapidité d'exécution et une implémentation simple, mais ils ne tiennent pas compte de la dynamique spatiale des déformations. Chaque point du visage y est traité de manière indépendante, sans interaction avec ses voisins, entraînant une perte de cohérence géométrique et des erreurs localisées dans les zones souples et fortement déformables (menton, cou). Les architectures basées sur les nuages de points, comme PointNet et PointNet++, marquent une avancée en permettant de traiter directement des données 3D. Toutefois, si PointNet++ capture mieux les structures locales, ces approches restent purement géométriques et ne modélisent pas les contraintes physiques gouvernant les interactions masque visage. Leur généralisation demeure limitée lorsque les données proviennent de capteurs mobiles tels

qu'ARKit, souvent partiellement incomplets. Les modèles de graphe (GCN, VGAE) constituent un progrès conceptuel majeur en introduisant une structuration spatiale explicite des points du visage. Grâce au message passing, ils préservent les relations topologiques et permettent de mieux représenter la continuité des déformations. Cependant, la plupart des variantes existantes restent purement géométriques, sans intégration explicite des lois biomécaniques de contact ou d'élasticité. Enfin, les approches récentes de graph neural networks informés par la physique (Physics-Encoded GNN, PINNs) montrent qu'il est possible de concilier rapidité d'inférence et cohérence mécanique en intégrant des termes de perte inspirés des lois de la mécanique du contact de Hertz. Néanmoins, ces méthodes nécessitent encore un volume important de données annotées et une régulation géométrique supplémentaire pour garantir la stabilité dans les régions hautement déformables. En résumé, l'analyse des avantages et limites de ces approches conduit à privilégier une architecture hybride combinant les forces de chacune :

- un modèle graphique semi-supervisé, pour exploiter simultanément les visages annotés et non annotés et les relations entre un point et ses voisins.
- une intégration de contraintes physiques légères, inspirées de la théorie du contact hertzien, afin de renforcer la plausibilité biomécanique.
- un mécanisme d'attention géométrique pour pondérer les régions les plus sensibles aux déformations.

Cette combinaison apparaît comme une solution prometteuse permettant de concilier rapidité d'inférence, cohérence biomécanique et adaptabilité morphologique. Le chapitre suivant présente en détail la méthodologie proposée, incluant l'architecture du modèle, les mécanismes d'apprentissage semi-supervisé, l'intégration des contraintes biomécaniques et les résultats obtenus sous la forme d'un article scientifique.

CHAPITRE 2

PREDICTING FACIAL DEFORMATION DURING RESPIRATORY MASK FITTING WITH SEMI-SUPERVISED GRAPH NEURAL NETWORKS

Eya MLIKA¹, Bahe HACHEM², Yamen AL HABASH², Loic DEGUELDRE², Luc DUONG¹

¹ Département de logiciel et technologie de l'information, École de Technologie Supérieure,
1100 Notre-Dame Ouest, Montréal, Québec, Canada H3C 1K3

² Numalogics,
200 Boul. Saint-Laurent, Montréal, Québec, Canada H2W 2R2

Article soumis à la revue « Medical Engineering & Physics » en Octobre 2025.

2.1 Introduction

In the healthcare, industrial, and emergency response sectors, where employees are exposed to airborne pollutants such as particulate matter, toxic aerosols, and pathogenic microbes, respiratory protection equipment is crucial to occupational safety. The COVID-19 pandemic highlighted the importance of effective respiratory protection, with N95 and equivalent respirators becoming frontline defenses against viral transmission through their ability to filter 95% of particles in the most penetrating size range of 0.1–0.3 μm (Qian, Willeke, Grinshpun, Donnelly & Coffey, 1998; Rengasamy & Eimer, 2012; for Disease Control & Prevention, 2020).

Despite their proven effectiveness, widespread use of these masks has revealed a major challenge which is the trade-off between protection and comfort. Healthcare professionals frequently report pressure injuries from prolonged use particularly on the bridge of the nose and cheekbones (Martelly *et al.*, 2025). This discomfort directly impairs protective performance as adjustments or premature removal of masks can reduce their filtration effectiveness (Ardon-Dryer *et al.*, 2021). In addition, significant inter-individual variability in facial geometry contrasts with standardized mask designs which are based on population averages and often fail to achieve an optimal fit (Gakhal, Bakshi, Gu & Khambay, 2024).

From a technical standpoint, achieving optimal contact between the mask and the face is a very complex problem. The human face has irregular curvature and heterogeneous rigidity, combining rigid bone structures and deformable soft tissues (Kähler *et al.*, 2003). The application of a mask generates non-rigid three-dimensional deformations governed by both normal and tangential forces, resulting in heterogeneous contact pressure distributions. These distributions must both ensure effective sealing and remain below thresholds that could cause tissue damage. Recent research has explored computational and data-driven approaches to address these challenges. FEA allows for detailed simulations of mask-face interactions, but remains computationally demanding and limited to small cohorts due to the high costs of generating labeled data (Taeckens *et al.*, 2022). Machine learning approaches, including tree-based regressors and thin-plate spline neural networks (TPS-Net), have shown promise in predicting deformation and pressure fields (Al Habash *et al.*, 2024; Mlika, Hachem, Alhabash, Degueldre & Duong, 2024). However, these methods remain limited by data scarcity, restricted generalization, and insufficient integration of contact mechanics principles. The remainder of this manuscript is organized as follows. Section 2 reviews related work; Section 3 details the proposed methodology; Section 4 presents and analyzes the experimental results; Section 5 examines the conclusions and limitations; and Section 6 concludes the study.

2.2 Related work

Recent advances in deep learning have led to the development of methods that are particularly well suited to the problem of contact between the mask and the face. Graph neural networks (GNNs), when applied to facial meshes, allow for the explicit encoding of spatial and mechanical relationships between anatomical regions (Park, Florence, Straub, Newcombe & Lovegrove, 2019). Unlike point- or voxel-based approaches, GNNs naturally preserve facial topology, allowing for accurate modeling of local deformations around critical areas such as the nasal bridge and cheeks, while capturing overall morphological variability (Lampen *et al.*, 2025; Salehi & Giannacopoulos, 2022). In the context of personalized mask fitting, this property is essential, as pressure concentrations often result from subtle geometric variations in localized

regions. One of the main obstacles to personalized mask fitting is the scarcity of labeled datasets, as obtaining reference deformation and pressure fields requires costly and time-consuming finite element simulations (Martelly *et al.*, 2025). Semi-supervised graph learning offers a practical solution by allowing the model to learn not only from a small set of annotated faces, but also from a much larger set of unlabeled scans. In this framework, structural similarities between facial geometries are exploited so that the deformation-pressure relationships inferred from labeled subjects can be generalized to unlabeled subjects. This mechanism effectively propagates information across the dataset, reducing the dependence on exhaustive simulations.

The fundamental work of Kipf and Welling (Kipf & Welling, 2017) demonstrated that convolutional graph networks can propagate labeling information across a graph using a localized first-order approximation of spectral convolutions. Their model showed how node features and graph connectivity can be combined to accurately infer labels for unlabeled nodes. Building on this idea, Hamilton et al. (Hamilton, Ying & Leskovec, 2017) introduced GraphSAGE, an inductive framework capable of generating node integrations for unseen graphs by sampling and aggregating neighborhood information. These approaches are particularly relevant to our application : in our case, labeled nodes correspond to facial regions where responses to deformation and pressure are known, while unlabeled nodes represent face geometries for which no reference measurements exist. By leveraging neighborhood aggregation and label propagation mechanisms, the model can infer plausible deformation and pressure distributions on unlabeled facial meshes, enabling predictive generalization far beyond the limited annotated dataset. Beyond purely data-driven approaches, recent work has emphasized the importance of integrating physical laws directly into learning frameworks. At the same time, physics informed neural networks (PINNs) have demonstrated the direct integration of physical laws into the learning process, ensuring that predictions remain consistent with mechanical principles rather than relying solely on data. Raissi et al. (Raissi, Perdikaris & Karniadakis, 2019) introduced the PINN framework, in which partial differential equations are integrated into the loss function, providing accurate solutions even in regimes where training data is limited. Karniadakis et al.

(Karniadakis *et al.*, 2021) extended this concept to a wide range of physical systems, highlighting how physics-guided losses improve both generalization and stability in highly nonlinear problems.

Recent studies have shown how physics-informed neural networks (PINNs) can directly incorporate classical principles during training. Sahin et al. (Sahin, von Danwitz & Popp, 2024) addressed the forward and inverse problems by applying Karush-Kuhn-Tucker (KKT) conditions in the loss function, thereby ensuring that two key rules are always satisfied : surfaces cannot interpenetrate, and contact pressure only develops in the case of deformation. To achieve this, they used the Fischer-Burmeister formulation, which provides a fluid and rigorous way to handle these complementarity conditions.

This approach is naturally related to Hertzian contact theory (Johnson, 1987), which describes elastic contact between curved solids. Hertz demonstrated that the contact area is not a point, but a finite area, circular or elliptical in shape. Within this finite area, the contact pressure is not evenly distributed. Instead, it follows a characteristic pattern where the pressure is highest at the center of the contact zone and gradually decreases toward the edges, vanishing at the boundary. This parabolic-like distribution is a hallmark of Hertzian mechanics and reflects the way elastic surfaces deform under load. A central contribution of Hertz's theory is the establishment of a direct link between three quantities : the external force applied to press the bodies together, the depth of the local deformation of the surface (indentation), and the resulting pressure distribution in the contact area. This relationship provides a rigorous physical explanation for why concentrated stresses appear in small but critical facial areas, such as the nasal bridge or cheekbones, when a respirator mask is tightened.

By capturing this interaction between force, deformation, and pressure, Hertzian contact theory continues to serve as a reference framework. In modern approaches, such as physics-informed neural networks, these principles are incorporated into the training so that models not only fit the data but also respect the well-established mechanical laws that govern contact behavior.

2.3 Materials and Methods

This section describes the dataset, graph construction, and learning framework used to predict facial deformation and contact pressure during respiratory mask fitting.

2.3.1 Dataset

The dataset used in this study comprised two groups. The first group included 45 adult participants who were experimentally scanned during the controlled application of a respiratory mask. For each subject, facial geometry was acquired using an iPhone equipped with the ARKit framework and converted into a 3D mesh suitable for simulation. This cohort provided two complementary sources of labeled data. First, finite element analysis (FEA) was performed on the reconstructed facial meshes, in which the same geometries were subjected to tightening forces of 5 N, 13 N, and 20 N to compute deformation fields and pressure distributions. The applied forces were measured experimentally using an instrumented mask equipped with calibrated springs mounted on the straps; spring elongation, read on a graduated scale, directly provided the applied force based on the known spring stiffness. Second, experimental measurements were collected using capacitive pressure sensors placed at predefined anatomical landmarks. These sensors recorded local soft-tissue compression under load, providing empirical deformation and pressure data. Together, the FEA outputs and the sensor measurements formed paired simulation-based and experimental ground truth used for model validation. Taeckens *et al.* (2022). To increase morphological diversity and strengthen the generalization capability of the model, a second group of 120 unlabeled faces was incorporated from the public FLAME (*Faces Learned with an Articulated Model and Expressions*) dataset Zheng *et al.* (2023). The facial points in this dataset were generated directly from the FLAME parametric head model, which provides meshes with dense and consistent point-to-point correspondence across individuals. For this study, we sampled facial geometries from FLAME by varying its shape parameters across two primary categories (male and female) and by selecting a small-scale configuration to approximate child morphology. Systematic variation of the FLAME latent shape parameters enabled the synthesis of a wide range of facial shapes while preserving uniform mesh topology. These complete and

anatomically coherent 3D facial meshes, which do not include pressure measurements and deformation, were used exclusively for semi-supervised learning of structural representations.

2.3.1.0.1 Geometric representation and notation

Each face was represented as a set of N surface landmarks discretizing the external facial morphology. For each landmark $i \in \mathcal{V} = \{1, \dots, N\}$, the undeformed (pre-mask) coordinate was denoted $\mathbf{A}_i = [X_i, Y_i, Z_i]^\top$, and the deformed (post-mask) coordinate was denoted $\mathbf{A}'_i = [\text{Pos}X_i, \text{Pos}Y_i, \text{Pos}Z_i]^\top$. The local deformation vector was therefore $\delta_i = \mathbf{A}'_i - \mathbf{A}_i$, while the local contact pressure was recorded as $\mathbf{p}_i \in \mathbb{R}_+$. Each experimental condition also included the applied clamping force $F \in \mathbb{R}_+$ associated with mask tightening.

For model development, the labeled dataset of 45 faces was divided into training, validation, and test sets per subject. A 70%/ 15%/ 15% split was applied by subject, ensuring that all scans from a given participant resided in a single fold. In addition, grouped K -fold cross-validation was employed to confirm robustness. The unlabeled cohort of 120 faces was used exclusively in the unsupervised pretraining stage and was never mixed into the validation or test sets.

2.3.2 Graph Construction

In order to capture the complex geometry of the human face and its interaction with the respiratory mask, each sample was represented as a graph $\mathcal{G} = (\mathcal{V}, \mathcal{E})$. In this formulation, the vertices $\mathcal{V}$ correspond to facial landmarks distributed across the surface, and the edges $\mathcal{E}$ describe their spatial and mechanical relationships. This representation allowed the model to encode not only the absolute positions of the points, but also the dependencies between neighboring regions that collectively determine the deformation and pressure under the application of the mask as shown in the figure 2.1.




Figure 2.1 Pipeline for Graph Construction and Feature Extraction in Face Mask Interaction Modeling

Graph connectivity was established using a k -nearest neighbors procedure, ensuring that each vertex was linked to its closest neighbors in Euclidean space, thereby preserving the local anatomical topology. Each vertex $i \in \mathcal{V}$ was associated with an 18-dimensional feature vector $\mathcal{V}_i$ integrating four complementary categories of information.

Spatial Features : The raw 3D coordinates $[X_i, Y_i, Z_i]$ were used to capture the overall facial morphology. To encode the local context, relative position vectors $[X_{\text{component},i}, Y_{\text{component},i}, Z_{\text{component},i}]$ were calculated as the displacement of each point relative to the centroid of its neighborhood, while local variances $[\text{Var}X_i, \text{Var}Y_i, \text{Var}Z_i]$ quantified the dispersion of neighbors along each axis. These measurements made it possible to distinguish flat regions from curved or irregular surfaces, which are more likely to accumulate pressure. The estimated local deformation $\hat{\delta}_i$ and the local density of points, defined as the average distance to neighbors, were also included. Dense regions typically corresponded to rigid skeletal areas, whereas sparse regions reflected softer tissues. These differences were critical for predicting localized discomfort and contact

pressure hotspots.

Geometric Shape Descriptors : The neighborhood covariance matrices were analyzed to extract indicators of local morphology based on eigenvalues. From these, $\lambda_1 \geq \lambda_2 \geq \lambda_3$, we calculate three normalized indicators :

$$L_i = \frac{\lambda_1 - \lambda_2}{\lambda_1}, \quad P_i = \frac{\lambda_2 - \lambda_3}{\lambda_1}, \quad S_i = \frac{\lambda_3}{\lambda_1}.$$

Here, L_i measures linearity (edges or ridges), P_i measures planarity (flat surfaces), and S_i measures sphericity (rounded structures). Together, these descriptors enabled the model to differentiate between sharp edges (the nasal bridge), flat areas (the cheeks), and rounded areas (the chin), all of which strongly influence mask fit and pressure distribution.

Force Features : The force context was coded using the external force F_i applied to tighten the mask on the face.

Pressure Features : For each node, three complementary features were computed : the measured contact pressure P_i , the theoretical Hertzian pressure $P_{\text{theory},i}$, and the deviation of pressure. The theoretical pressure was modelled using Hertz's law :

$$P_{\text{theory},i} = C \hat{\delta}_i^{1.5}, \quad (2.1)$$

where $\hat{\delta}_i$ denotes the local deformation. The proportionality constant C was expressed as

$$C = \frac{4E^*}{3\pi R}, \quad E^* = \frac{E}{1 - \nu^2}, \quad (2.2)$$

with E and ν the Young's modulus and Poisson's ratio of the skin, and R the local radius of curvature estimated by quadratic fitting around the neighborhood of each vertex ($E = 0.05$ MPa,

$\nu = 0.48$).

To quantify deviations of pressure, we defined a normalized discrepancy term :

$$\Delta P_i = \frac{P_i - P_{\text{theory},i}}{P_{\text{theory},i} + \varepsilon}, \quad (2.3)$$

where ε is a small stabilization constant to avoid division by zero. This relative error acted as a correction feature, penalizing predictions that diverged from Hertzian theory while allowing for measurement uncertainty.

Edge Weights : Edges between vertices were weighted according to both spatial and mechanical affinity. Spatial affinity was inversely proportional to Euclidean distance, while mechanical similarity favored nodes experiencing similar deformations. The final edge weight was defined as the product of these two measures, ensuring that adjacent regions deformed consistently under mask tightening.

2.3.3 Model Architecture

The proposed architecture follows a two-step processing pipeline, as illustrated in Figure 2.2. First, a deformation zone classification module identifies the subset of facial landmarks likely to undergo displacement when the mask is applied. This step reduces computational cost and allows for greater focus on areas of interest. Second, an improved variational graphic autoencoder (VGAE) predicts both deformation fields and contact pressure distributions while integrating concepts of deformation and mechanical contact.




Figure 2.2 Overall architecture of the proposed two-stage model. Stage 1 : XGBoost-based deformation zone classification. Stage 2 : enhanced VGAE integrating force and physics modules for joint prediction of deformation and pressure

2.3.4 Deformation Zone Classification Module

Before predicting detailed facial reactions, the model identifies the points most likely to deform due to the tightness of the mask. Since only areas in direct contact with the mask undergo significant displacement, this pre-classification allows the network to focus its capacity on the relevant regions.

We used gradient boosting, specifically the XGBoost algorithm (Chen & Guestrin, 2016), which is well suited to nonlinear classification tasks with limited training data. Each point was described by a compact four-dimensional feature vector combining its spatial coordinates and the applied force :

$$\mathbf{f}_{\text{cls},i} = [X_i, Y_i, Z_i, F_i]^T \in \mathbb{R}^4. \quad (2.4)$$

The classifier learned the mapping :

$$\hat{m}_i = \text{XGBoost}(\mathbf{f}_{\text{cls},i}) \in \{0, 1\}, \quad (2.5)$$

where $\hat{m}_i = 1$ denotes a point predicted to deform. Training was performed using the 45 faces labeled under 12 levels of force, resulting in 540 training instances covering a wide range of facial morphologies under different tightening force values. The output of the Stage 1 XGBoost classifier is integrated directly into Stage 2 of the VGAE through a graph contraction mechanism. For each face, the classifier produces a binary deformation mask $\hat{m}_i \in \{0, 1\}$ indicating whether node i is predicted to undergo deformation under the applied tightening force. This mask is then used to prune the graph by retaining only nodes with $\hat{m}_i = 1$ and the edges connecting them, thereby producing a contracted subgraph that focuses the VGAE on mechanically relevant regions. Importantly, the predicted mask is not appended to the node feature vector; instead, it serves as a topological filter that removes non-deforming regions before VGAE processing.

2.3.5 Enhanced Variational Graph Autoencoder Framework

The second stage of the pipeline relies on an improved variational graphical autoencoder (VGAE)(Kipf & Welling, 2016) that captures rich representations of facial geometry while incorporating pressure and deformation constraints. The architecture combines three complementary components : an enhanced encoder, a physics-based decoder, and a multi-task predictor. The encoder is built on a convolutional graph structure with residual connections and multi-head attention, enabling the extraction of latent features that reflect both local facial geometry and mechanical interactions between neighboring regions. The decoder incorporates deformation and pressure principles for reconstruction. In addition, a multi-task prediction head jointly produces the three-dimensional deformation vectors $(\delta_x, \delta_y, \delta_z)$ and the contact pressure P , thus imposing coupled learning of geometric and mechanical responses. To further enhance prediction, two specialized modules are integrated into the VGAE : a force processing module, which incorporates the applied clamping force into the latent representation in order to adapt predictions to varying load conditions, and a pressure processing module, which incorporates the a priori assumptions of Hertzian contact mechanics (Johnson, 1987). By combining these components, the latent space of the VGAE is enriched with both data-driven and physics-informed

information. The enhanced latent representation is expressed as :

$$\boldsymbol{\mu}_{\text{enhanced}} = \boldsymbol{\mu} + \alpha_f \mathbf{f}_{\text{latent}} + \alpha_p \mathbf{p}_{\text{latent}}, \quad (2.6)$$

where : $\mathbf{f}_{\text{latent}}$ encodes the influence of the applied mechanical force on facial deformation, obtained by passing the input force through a force processing module (MLP) that maps it into latent space. $\mathbf{p}_{\text{latent}}$ captures the pressure priors derived from Hertzian contact mechanics, calculated using a pressure processing module that encodes the theoretical pressure distributions into latent features. α_f and α_p are trainable weights that control the contribution of force and physics related features.

2.3.6 Loss Functions

The design of the loss functions aimed to jointly preserve geometric fidelity, reproduce contact pressures and stabilize the latent space. The final objective integrates five complementary terms : reconstruction, pressure consistency, variational regularization, mechanics constraints, and spatial smoothness.

Reconstruction loss The primary objective is to ensure that the predicted deformation vectors $(\hat{\delta}_x, \hat{\delta}_y, \hat{\delta}_z)$ match the observed ground truth $(\delta_x, \delta_y, \delta_z)$. Since normal displacements (along the Z axis) dominate under mask application, an axis-specific weighting $(\alpha_x, \alpha_y, \alpha_z)$ is applied :

$$L_{\text{reconstruction}} = \frac{1}{N} \sum_{i=1}^N [\alpha_x (\hat{\delta}_{x,i} - \delta_{x,i})^2 + \alpha_y (\hat{\delta}_{y,i} - \delta_{y,i})^2 + \alpha_z (\hat{\delta}_{z,i} - \delta_{z,i})^2]. \quad (2.7)$$

This term guarantees that the predicted geometry remains close to the experimentally observed deformations.

Pressure loss A second objective is to ensure that the predicted contact pressure $\hat{P}_i$ matches the measured pressure P_i . Since some regions, such as the nose bridge, are more critical for comfort

and sealing, adaptive weights w_i are used to give them higher importance :

$$L_{\text{pressure}} = \frac{1}{N} \sum_{i=1}^N w_i (\hat{P}_i - P_i)^2, \quad w_i = 1 + \frac{|P_i|}{P_{\max}}. \quad (2.8)$$

This weighting improves the accuracy of pressure prediction in sensitive areas, helping to avoid discomfort and leakage.

KL divergence To stabilize the variational latent space of the VGAE, a Kullback–Leibler divergence term is applied, constraining the learned distribution toward a unit Gaussian prior :

$$L_{\text{KL}} = -\frac{1}{2M} \sum_{j=1}^M \left(1 + \log(\sigma_j^2) - \mu_j^2 - \sigma_j^2 \right). \quad (2.9)$$

This regularization reduces overfitting and improves generalization under limited labeled data (Kipf & Welling, 2016).

Mechanical constraints To embed biomechanical validity, three physics-inspired penalties are integrated :

$$L_{\text{Hertz}} = \frac{1}{N} \sum_{i=1}^N (\hat{P}_i - C \|\delta_i\|^{3/2})^2. \quad (2.10)$$

Here, L_{Hertz} enforces the Hertzian contact law linking pressure and deformation (Johnson, 1987). It provides an analytical relationship between the local strain and the theoretical contact pressure.

Smoothness loss A graph-based smoothness penalty enforces local continuity across adjacent mesh nodes :

$$L_{\text{smoothness}} = \frac{1}{|E|} \sum_{(i,j) \in E} \|\delta_i - \delta_j\|^2. \quad (2.11)$$

This prevents unrealistic discontinuities in the deformation field, ensuring physiologically plausible transitions across neighboring regions (Kipf & Welling, 2017).

Total objective The total training objective integrates all components with adjustable weights λ_i :

$$L_{\text{total}} = \lambda_1 L_{\text{reconstruction}} + \lambda_2 L_{\text{pressure}} + \lambda_3 L_{\text{KL}} + \lambda_4 L_{\text{Hertz}} + \lambda_5 L_{\text{smoothness}}. \quad (2.12)$$

This multi-term formulation ensures that the network jointly optimizes for geometric accuracy, pressure fidelity, biomechanical realism, and smooth spatial consistency.

2.3.7 Semi-Supervised Training and Implementation Details

The proposed architecture was trained under a semi-supervised setup to address the scarcity of labeled data. The strategy followed a two-step procedure consisting of pre-training on unlabeled faces, followed by fine-tuning on the labeled cohort.

Step 1 : Pre-training on unlabeled data. In the first stage, the model was trained using the 120 unlabeled faces from the FLAME repository. The objective was to learn the underlying distribution of facial morphology without requiring deformation or pressure annotations. This step allowed the network to build a morphology-sensitive latent space capable of capturing structural variability across diverse geometries.

Step 2 : Fine-tuning on labeled data. In the second stage, the pre-trained model was fine-tuned on the 45 experimentally labeled faces, which included paired deformation and pressure fields under different tightening levels. Supervised reconstruction and pressure losses were applied, supplemented by regularization terms based on mechanical concepts to ensure biomechanical consistency. This step enriched the latent space with explicit biomechanical knowledge and enabled accurate prediction of interactions between deformation and pressure.

Importantly, no part of the architecture was frozen or replaced during this process. All components : graph convolutional layers, latent-space transformations, and prediction heads were updated jointly throughout both phases. This end-to-end optimization ensures that the latent

space learned from synthetic geometric variability adapts seamlessly to the real biomechanical relationships governing deformation and pressure.

2.4 Results

The performance of the proposed framework is evaluated quantitatively and qualitatively, followed by sensitivity, benchmarking, and ablation analyses.

2.4.1 Key Performance Indicators

All reported performance metrics, were computed on a single held-out 15% test set obtained from a subject-level 70%/15%/15% train/validation/test split of the faces. Five-fold cross-validation was used separately to assess model robustness and did not contribute to the reported test results. Quantitatively, the model achieves an overall coefficient of determination of $R^2 = 0.9896$, a root mean square error (RMSE) of 0.164 mm, and a mean absolute percentage error (MAPE) of 4.95%, confirming sub-millimeter precision. The mean absolute error (MAE) of 0.0615 mm further highlights the robustness of the predictions across diverse facial morphologies and clamping conditions (Table 2.1). In addition, the framework shows high accuracy in estimating contact pressure, with $R^2 = 0.9517$ and an RMSE of 0.0492 kPa. To ensure that the deformation zone classifier did not overfit the training identities, the model was trained and validated using strict face-level splits, guaranteeing that no points from a given subject appeared in both sets. Under this setup, the classifier exhibited stable and consistent behavior, with only a minimal gap between training and validation performance. The regularized variant further demonstrated nearly identical outcomes across both sets, confirming robust generalization to unseen facial geometries.

Tableau 2.1 Primary Performance Metrics for the Proposed Model

Metric	Value
R^2 (Overall deformation)	0.9896
R^2 (X-component)	0.9266
R^2 (Y-component)	0.7744
R^2 (Z-component)	0.9747
RMSE (mm)	0.164
MAE (mm)	0.0615
MAPE (%)	4.95%
R^2 (Pressure)	0.9517
RMSE (Pressure, kPa)	0.0492

Figures 2.3 and 2.4 present heat maps of per-node prediction errors for deformation and pressure under a mask tightening force of 11 N, providing a qualitative assessment that corroborates the quantitative results. For the deformation fields (Figure 2.3), the colormap encodes the absolute Euclidean error $|\hat{\delta} - \delta|$ in millimeters. Residual deviations are concentrated in areas of high curvature, particularly the nasal bridge, cheeks, and chin, which correspond to the areas of contact with the mask.



Figure 2.3 Heat map of deformation errors per point (mm) under a mask tightening of 11 N. The colors encode the absolute Euclidean error $\|\hat{\delta} - \delta\|$ (in mm). The largest deviations are concentrated in areas of high curvature (chin); the color bar is indicated in mm




Figure 2.4 Heat map of pressure errors per point (kPa) under a mask tightening of 11 N. Colors encode the absolute error $|\hat{P} - P|$ (in kPa). The largest deviations occur near bony protrusions where pressure gradients are significant; the color bar is expressed in kPa

To complement the qualitative visualization of local errors, three comparative box plots were generated in figures 2.6 and 2.5.

For facial deformation, the predicted and ground-truth distributions exhibit a strong overlap across the full deformation range, indicating accurate reconstruction of both low- and high-magnitude deformations over the facial surface. This agreement is quantitatively supported by a high coefficient of determination ($R^2 = 0.989$) and a low RMSE = 0.16 mm, confirming sub-millimetric prediction accuracy and explaining nearly all variance observed in the reference data.




Figure 2.5 Histogram of Facial Deformation Distribution and Prediction Error under Mask Tightening (Force = 11 N)

For contact pressure, the predicted and measured distributions remain closely aligned over the observed range (approximately 0.4–1.6 kPa), with a strong correlation ($R^2 = 0.95$). The absolute error distribution is tightly concentrated near zero, yielding an RMSE = 0.05 kPa, which indicates accurate pressure estimation at the node level. The few larger residuals are primarily associated with regions of high curvature and pressure gradients, such as the nasal bridge and chin, consistent with established facial contact mechanics.




Figure 2.6 Histogram of Predicted and Measured Pressure Ranges with Error under Mask Tightening (Force = 11 N)

2.4.2 Hyperparameter Sensitivity Analysis

Hyperparameter optimization highlights the influence of graph connectivity and learning rate on prediction stability and accuracy. These results provide important guidelines for reproducible deployment of the proposed framework.

Graph connectivity optimization : The choice of neighborhood size (k -neighbors) directly affects graph construction and error distribution. As illustrated in Figures 2.7 lower values ($k = 6$) preserve local smoothness but fail to capture finer geometric variations, while higher values ($k = 10$) introduce noisy connections and amplify errors in regions of complex curvature. An intermediate value ($k = 8$) achieves the best trade-off, with lower overall RMSE (0.00360) and more uniform error distribution across the face surface. These observations confirm the importance of selecting an appropriate neighborhood size to balance local detail preservation and numerical stability.




Figure 2.7 Impact of Graph Connectivity ($k = 6, 8, 10$) on Deformation Error. Optimal performance is achieved at $k = 8$, which provides a balanced trade-off between geometric smoothness and sensitivity to local structural variations

Learning Rate Sensitivity : The learning rate strongly influences convergence stability and predictive accuracy. As shown in Figure 2.8, very low rates ($< 10^{-4}$) fail to achieve sufficient convergence within practical training times, while excessively high rates ($\geq 10^{-3}$) destabilize optimization due to conflicting gradients from deformation and pressure objectives. The optimal learning rate is found at 2×10^{-3} , yielding the lowest validation loss (0.0048) and ensuring a stable trade-off between convergence speed and accuracy.




Figure 2.8 Validation loss across learning rate values (log scale). The optimal setting (2×10^{-3}) minimizes error while preserving convergence stability

2.4.3 Benchmarking Analysis

This section presents a comparative evaluation of our solution against state-of-the-art methods. We systematically evaluate performance against existing approaches

2.4.3.1 Quantitative Benchmarking Analysis

Traditional Machine Learning Benchmarks The Random Forest benchmark, representing traditional machine learning approaches for deformation prediction, achieves an RMSE of 1.875 mm with $R^2 = 0.65$ and MAPE = 16.2%.

Geometric Deep Learning Methods PointNet++ as a leading point cloud processing method achieves RMSE of 0.768 mm ($R^2 = 0.785$, MAPE = 12.5%) with significant computational

requirements (training time : 8.2 hours).

Specialized facial modeling methods TPS-Net, designed explicitly for non-rigid facial deformation, reports an RMSE of 0.79 mm ($R^2 = 0.89$, MAPE = 6.53 %) with a 1.8-hour training time.

The proposed approach achieves a 10.01 % in terms of R^2 improvement over TPS-Net, combining semi-supervised learning with physics-informed regularization.

The table 2 presents a comprehensive multidimensional evaluation of the proposed semi-supervised, graph neural network framework for fitting of respiratory mask compared to three established reference methods : Random Forest, PointNet++, and TPS-Net.

Tableau 2.2 Quantitative Benchmarking of Deformation Models for 3D Facial Deformation Prediction

Method	RMSE [mm]	R^2	MAPE [%]	Training Time
Proposed Framework	0.164	0.989	4.95	3.2h
Random Forest	1.875	0.65	16.2	45 min
PointNet++	0.768	0.785	12.5	8.2 h
TPS-Net	0.79	0.89	6.53	1.8 h

2.4.3.2 Qualitative Benchmarking Analysis

In addition to quantitative metrics, Figure 2.9 presents qualitative error heatmaps for Face 1 under a tightening force of 13 N, comparing the proposed framework with Random Forest, PointNet++, and TPS-Net.

The proposed framework shows minimal error distribution, with errors primarily concentrated around the nasal bridge and cheekbone regions where pressure gradients are highest as shown in figure 2.9. Random Forest exhibits a uniform but exaggerated error across the entire facial surface, indicating its inability to preserve local geometric structures. PointNet++ partially captures facial geometry but produces scattered localized artifacts due to the lack of explicit

physics priors. TPS-Net better aligns with facial deformation patterns compared to PointNet++.




Figure 2.9 Qualitative error heatmaps of deformation prediction for Face 1 under 13 N tightening force. The proposed framework shows minimal errors compared to Random Forest, PointNet++, and TPS-Net

2.4.4 Ablation Study

To further interpret the high predictive accuracy reported above ($R^2 = 0.9896$, RMSE = 0.164 mm), an ablation study was conducted to quantify the individual contribution of architectural, physical, and feature-related components to overall model performance.

Tableau 2.3 Summary of Ablation Study Results : Quantitative impact of each component on deformation (RMSE, mm). Relative degradation (%) is measured against the full semi-supervised graph neural network model

Ablated Component	Deformation RMSE (mm)	Performance Degradation (%)
Fully Supervised (No Unlabeled Data)	0.289	43.25
No Graph-Based Label Propagation	0.215	23.72
No Physics Constraints (All Removed)	0.267	38.11
– No Hertzian Contact Theory	0.201	18.00
– No Force–Deformation Consistency	0.192	13.86
Separate Networks (No Multitask Head)	0.218	25.25
GNN → MLP Encoder	0.342	51.76
No Multi-Head Attention	0.187	11.35
No Residual Connections	0.198	18.00
Deterministic Encoder (No Variational)	0.179	8.88
Unified Axis Branch (No Axis-Specific)	0.208	27.11
Raw Coordinates Only (No Features)	0.398	58.79
No Local Geometric Descriptors	0.231	53.14
No Shape Characteristics (Flatness, Sphericity)	0.194	18.00
No Pressure-Related Features	0.209	25.40
No Force Information	0.256	48.75
Full Model (Ours)	0.164	–

Fully Supervised Baseline (No Unlabeled Data) : Removing all unlabeled data and training only on the 45 labeled faces results in RMSE of 0.289 mm, representing 43.25% performance degradation compared to the full semi-supervised framework. This highlights the critical importance of exploiting unlabeled geometric variability for robust generalization.

Graph-Based Label Propagation : Eliminating the semi-supervised mechanism and relying exclusively on reconstruction loss during pre-training on unlabeled faces increases the RMSE to 0.215 mm, corresponding to a 23.72% degradation. This result highlights the importance of the graphical structure of each face : convolution on the graphs allows the model to learn meaningful geometric patterns from unlabeled data during pre-training.

Architectural Component Analysis Replacing the GNN encoder with a plain multilayer

perceptron results in severe performance loss (RMSE = 0.342 mm, 51.76%), confirming that graph structures are essential to encode spatial interactions between facial landmarks. Removing multi-head attention leads to a 11.35% loss (RMSE = 0.187 mm), emphasizing its importance for focusing on mechanically salient regions. Eliminating residual connections increases RMSE to 0.198 mm (18%), showing their contribution to stable optimization and deep model expressiveness. Substituting the variational encoder with a deterministic version worsens RMSE (0.179 mm; 8.88%), underlining the value of uncertainty quantification. Finally, merging axis-specific deformation branches into a single predictor raises RMSE to 0.208 mm (+27.11%), proving that deformation patterns along different axes require specialized modeling.

Feature Engineering Contribution Analysis The removal of features further highlights the role of descriptors that take biomechanics into account. The exclusive use of raw 3D coordinates gives an RMSE = 0.398 mm ($R^2 = 0.894$; 58.79%), confirming that overall geometry alone is insufficient. Removing local geometric descriptors increases the RMSE to 0.231 mm (53.14%), demonstrating their role in capturing the variability of the surrounding surface. Eliminating shape characteristics (linearity, flatness, sphericity) results in an 18% degradation (RMSE = 0.194 mm), proving their necessity for localized biomechanical modeling. The absence of pressure features that take physical principles into account results in an RMSE = 0.209 mm (+25.4%), highlighting their importance in integrating the principles of contact mechanics. More importantly, the removal of information on the applied forces significantly degrades performance (RMSE = 0.256 mm, 48.75%), proving that the applied forces cannot be deduced from geometry alone and constitute essential data for realistic deformation modeling.

Training convergence analysis The training dynamics follow three phases as shown in figure 2.10 : (i) rapid reduction of physics-based losses (0 to 20 epochs) ensuring biomechanical validity, (ii) balanced optimization of pressure, KL divergence, and fluidity (20 to 40 epochs), and (iii) refinement of reconstruction accuracy (40 to 100 epochs) with stable physical consistency. Importantly, adding physics-inspired losses does not increase the number of training iterations required. Instead, these constraints accelerate convergence by reducing the search space and guiding the optimizer toward mechanically valid regions of the solution manifold, resulting in faster stabilization of all loss components.




Figure 2.10 Training dynamics of the losses. Early epochs prioritize physics consistency, followed by balanced optimization of deformation reconstruction and pressure prediction, converging to a stable compromise across objectives

The ablation study complements this dynamic by quantifying the influence of different loss weightings on final accuracy (RMSE) as shown in Figure 2.11 . Removing or underweighting critical components such as pressure or KL divergence leads to a noticeable degradation in performance. On the other hand, combining reconstruction and regularity (0.1*reconstruction loss + 0.3 regularity loss) or integrating several terms produces the lowest RMSE, confirming the importance of multi-objective optimization ($\lambda_1 = 1.0, \lambda_2 = 0.1, \lambda_3 = 0.01, \lambda_4 = 0.5, \lambda_5 = 0.3$). These results show that the model learns better when the different losses are combined. By balancing the reconstruction, pressure, and physics-based terms, the architecture becomes more accurate, achieving an optimal compromise between mechanical validity and geometric accuracy, resulting in an optimal balance ($R^2 = 0.9896, RMSE = 0.197$ mm).




Figure 2.11 Impact of loss weighting on predictive accuracy. Ablation reveals that excluding or underweighting key components degrades performance, while balanced multi-loss integration achieves optimal accuracy

2.5 Discussion

This section discusses the quantitative and qualitative results in the context of biomechanical theory and existing literature.

2.5.1 Interpretation of Key Results

The proposed semi-supervised GNN framework achieved sub-millimeter precision in predicting facial deformation and contact pressure. These improvements can be attributed to the integration of graph topology, Hertzian contact constraints, and semi-supervised optimization. The combination of geometric and physical priors allows the model to capture both global morphological patterns and local mechanical behaviors. This finding aligns with recent works on physics-guided graph learning (Karniadakis *et al.*, 2021; Salehi & Giannacopoulos, 2022), which emphasize that embedding physical laws improves predictive stability and generalization.

2.5.2 Comparison with Existing Methods

The proposed framework clearly offers better accuracy and efficiency compared to all reference methods. Unlike Random Forest, which cannot capture spatial dependencies, and PointNet++, which ignores mesh topology and requires significant computing resources, the proposed model integrates graph-based spatial encoding and physics-guided learning. While TPS-Net offers a solid geometric foundation, it lacks physical interpretability and semi-supervised adaptability. By combining graph connectivity, contact mechanics constraints, and semi-supervised optimization, the proposed approach achieves optimal convergence in 3.2 hours, slightly faster than other models such as Random Forest and TPS-Net, and provides a model that is both more accurate and more physically consistent than existing methods.

2.5.3 Biomechanical Interpretation

The model's adherence to Hertzian contact theory ensures that predicted pressure distributions remain physically consistent, with maximal values localized near bony prominences and gradual decay along softer regions. This pattern mirrors empirical pressure measurements reported in Martelly et al. (2025) (Martelly *et al.*, 2025) and Taeckens et al. (2022) (Taeckens *et al.*, 2022), confirming that the learned representations capture the underlying contact mechanics of mask–face interactions. By enforcing physics-based losses, the network respects the complementarity conditions typical of soft tissue mechanics (Sahin *et al.*, 2024).

2.5.4 Limitations and future work

Despite the promising results obtained, this study also has some limitations. First, current biomechanical modeling assumes homogeneous and isotropic skin properties ($E = 0.05\text{MPa}$, $\nu = 0.48$), whereas actual facial tissue exhibits regional heterogeneity, anisotropy, and inter-individual variability. The integration of spatially varying stiffness maps derived from elastography or MRI data could improve deformation prediction. Furthermore, simulations and the learning framework operate under quasi-static conditions, neglecting temporal variations related to

breathing, speech, or facial movements. Future work should extend the approach to dynamic, time-dependent deformation modeling by coupling the network with viscoelastic constitutive laws or temporal graph architectures.

2.6 Conclusion

This work introduces a semi-supervised graph neural network framework for predicting three-dimensional facial deformation and contact pressure during respiratory mask application. By combining graph-based spatial encoding with physics constraints, the proposed model captures both geometric and mechanical responses with enhanced realism and adaptability. The proposed approach provides a foundation for real-time and cost-efficient customization of respiratory masks, with potential extensions toward dynamic, patient-specific modeling.

CHAPITRE 3

DISCUSSION

Les résultats discutés mettent en évidence une solution permettant de personnaliser l'ajustement des masques respiratoires de manière à la fois précise, biomécaniquement cohérente et compatible avec des contraintes de temps réel. Ils contribuent à l'élaboration d'un cadre efficace de conception personnalisée de masques respiratoires permettant d'améliorer le confort, la sécurité et l'ajustement en milieux médical et industriel. Ces résultats sont présentés dans deux articles scientifiques. Le premier article, intitulé *Personalized Fitting of Respiratory Mask Using Deep Learning and 3D Facial Modeling* a été présenté à la conférence internationale *3DBODY.TECH 2024*. Il propose une approche intégrée combinant la reconstruction de maillages faciaux complets à partir d'acquisitions 3D à l'aide d'algorithmes d'alignement et de transformation non rigide avec des techniques d'apprentissage profond pour la prédiction des déformations faciales.

L'une des contributions majeures de cette étude réside dans la constitution d'une base de données structurée et complète de visages 3D obtenue par l'intégration du modèle FLAME et l'application conjointe des algorithmes ICP et TPS. Cette combinaison a permis de générer des maillages cohérents à partir de données partielles assurant une représentation fidèle des morphologies faciales individuelles. Sur cette base, un modèle d'apprentissage profond, nommé TPS-Net, a été développé afin de prédire les déformations non rigides du visage lors du port du masque. En apprenant des transformations géométriques continues et lisses entre les nuages de points avant et après contact, ce réseau a permis de modéliser avec précision les variations locales de la géométrie faciale induites par les contraintes mécaniques. Les résultats expérimentaux ont démontré la supériorité de TPS-Net par rapport aux méthodes de référence, telles que CPD-Net et les réseaux point à point, avec une RMSE de 0,0005 mm, une MAE de 0,0002 mm et une distance de Chamfer de 0,022 mm, illustrant la stabilité et la précision de la méthode proposée.

Cependant, certaines limites doivent être soulignées. L'approche demeure centrée sur la prédiction géométrique et ne prend pas explicitement en compte les propriétés biomécaniques des tissus

cutanés ni la variabilité interindividuelle de leur comportement mécanique. De plus, la taille relativement restreinte de l'échantillon (45 visages) peut limiter la capacité de généralisation du modèle à des populations plus diversifiées.

Le second article approfondit ces travaux en introduisant un modèle de réseau de neurones graphiques semi-supervisé capable de prédire simultanément la déformation faciale et la distribution des pressions de contact avec une précision submillimétrique. Les performances de ce modèle reposent sur trois composantes essentielles : (i) un encodage spatial fondé sur la topologie du graphe permettant de préserver la connectivité et la continuité géométrique du visage ; (ii) l'intégration explicite de contraintes de contact hertzien garantissant la cohérence biomécanique des prédictions ; et (iii) une stratégie d'apprentissage semi-supervisé exploitant efficacement les visages non annotés afin d'améliorer la généralisation du modèle. L'intégration conjointe de contraintes géométriques et physiques dans le processus d'apprentissage constitue un levier fondamental pour renforcer la cohérence des prédictions. Les contraintes géométriques assurent la préservation des relations spatiales locales entre les points du visage et la continuité des déformations tandis que les contraintes physiques, inspirées des lois de la mécanique du contact de Hertz guident l'apprentissage vers des prédictions biomécaniquement plausibles respectant la relation entre charge appliquée et déformation locale. Ces résultats s'inscrivent dans la continuité des travaux récents sur les réseaux de neurones informés par la physique confirmant que l'intégration explicite de lois biomécaniques dans les architectures d'apprentissage profond améliore la stabilité et la fiabilité prédictive (Karniadakis *et al.*, 2021; Salehi & Giannacopoulos, 2022).

Notre modèle se distingue par une précision accrue, une meilleure cohérence physique et une efficacité computationnelle supérieure. Contrairement à la méthode Random Forest, qui ne capture pas la dynamique spatiale des déformations, ou à PointNet++ qui ignore la structure de connectivité entre les sommets et requiert d'importantes ressources de calcul le modèle graphique exploite explicitement la topologie du maillage afin d'encoder la continuité géométrique et biomécanique des surfaces faciales. De même, bien que TPS-Net se montre efficace pour la

modélisation géométrique des transformations lisses son absence d'interprétabilité physique et son incapacité à tirer parti de données non annotées dans un cadre semi-supervisé limitent sa portée. En combinant la connectivité du graphe, les contraintes mécaniques de contact et un apprentissage semi-supervisé le modèle atteint un compromis optimal entre précision et efficacité computationnelle offrant une solution physiquement cohérente et économe en données pour la modélisation des déformations non rigides.

D'un point de vue biomécanique, le respect de la théorie du contact de Hertz assure la cohérence physique des pressions prédites par le modèle. Cette théorie décrit la relation entre la charge appliquée et la déformation au point de contact expliquant que les pressions maximales se concentrent sur les zones rigides du visage (nez, pommettes) tandis que les régions plus souples présentent des pressions plus faibles en raison de leur capacité de déformation. Les résultats obtenus montrent que les zones de contact rigides supportent la majorité des charges, tandis que les régions plus souples absorbent et redistribuent la pression. Cette concordance valide la faisabilité biomécanique du modèle proposé et confirme que l'intégration des contraintes physiques dans le processus d'apprentissage contribue à améliorer la fidélité des champs de pression prédits (Martelly *et al.*, 2025; Taeckens *et al.*, 2022).

Malgré ces résultats encourageants, plusieurs limites doivent être discutées afin de cerner la portée réelle du modèle proposé. Tout d'abord, la modélisation repose sur des hypothèses simplificatrices, notamment l'homogénéité et l'isotropie des tissus faciaux ($E = 0,05$ MPa et $\nu = 0,48$), alors que ces derniers présentent une anisotropie et une hétérogénéité marquées (Delalleau, Josse, Lagarde, Zahouani & Bergheau, 2006). L'intégration de cartes de rigidité spatiale issues de l'élastographie ou de l'imagerie par résonance magnétique (IRM) permettrait d'introduire une variabilité anatomique plus réaliste et d'améliorer la précision des prédictions.

De plus, l'approche actuelle demeure statique et ne prend pas en compte les effets temporels liés à la respiration, aux micromouvements musculaires ou à la déformation progressive des tissus lors d'un port prolongé du masque. Une extension vers une modélisation dynamique fondée sur des graphes temporels et des lois viscoélastiques dépendantes du temps permettrait de mieux représenter les phénomènes de déformation évolutive et d'accroître la cohérence biomécanique du modèle.

Le modèle a également été entraîné principalement sur des données simulées, ce qui présente à la fois des avantages et des limites par rapport à un apprentissage fondé sur des données expérimentales. Les données simulées offrent un contrôle total des conditions d'acquisition, une cohérence géométrique élevée et l'absence de bruit, ce qui facilite l'apprentissage dans un environnement stable et reproductible. Toutefois, elles ne reproduisent pas fidèlement la variabilité biologique et les phénomènes physiologiques réels tels que l'élasticité anisotrope de la peau, les micromouvements musculaires ou les effets de l'humidité et de la transpiration sur l'ajustement du masque. À l'inverse, les données expérimentales, bien que plus réalistes, sont souvent bruitées, coûteuses à acquérir et difficiles à annoter avec précision. Ce contraste souligne la pertinence d'une approche hybride combinant l'apprentissage sur données simulées pour la stabilité et la reproductibilité avec une validation et une calibration sur données expérimentales afin d'assurer la fiabilité et l'applicabilité réelle du modèle.

Une autre limite concerne la gestion computationnelle de l'apprentissage semi-supervisé. Bien que l'ajout de données non annotées permette théoriquement d'améliorer la généralisation du modèle, cette expansion se heurte à des contraintes de ressources importantes. L'augmentation du volume de données accroît le nombre de nœuds et d'arêtes dans les graphes, ce qui allonge les temps d'entraînement, augmente la consommation de mémoire GPU et complexifie la propagation des messages. Cette contrainte limite la capacité à exploiter pleinement le potentiel des données non annotées. Des solutions telles que l'utilisation d'architectures plus légères ou la

parallélisation du calcul pourraient être envisagées afin d'atténuer ces limitations.

CONCLUSION ET RECOMMANDATIONS

Ce mémoire a proposé une approche intégrée combinant apprentissage profond, modélisation géométrique et principes biomécaniques pour la personnalisation de l'ajustement des masques respiratoires. Fondée sur des réseaux de neurones graphiques semi-supervisés enrichis par des contraintes mécaniques inspirées de la théorie du contact de Hertz l'approche développée permet la prédiction conjointe des champs de déformation faciale et des pressions de contact avec une précision compatible avec les exigences biomédicales tout en réduisant le recours aux simulations numériques coûteuses par éléments finis.

Les résultats obtenus confirment l'intérêt d'une intégration étroite entre intelligence artificielle et modélisation mécanique et mettent en évidence la pertinence du cadre semi-supervisé pour faire face à la rareté et au coût élevé des données biomécaniques annotées. Au-delà des performances quantitatives, ce travail contribue à une meilleure compréhension des interactions mécaniques entre le masque et la morphologie faciale en proposant un outil prédictif exploitable pour l'évaluation du confort de la sécurité et de l'ajustement personnalisé.

Dans la continuité de ces travaux, plusieurs perspectives de recherche peuvent être envisagées. L'enrichissement de la modélisation biomécanique par l'intégration de propriétés mécaniques hétérogènes et anisotropes des tissus faciaux issues par exemple de l'élastographie ou de l'imagerie par résonance magnétique permettrait de mieux refléter la variabilité anatomique individuelle. Par ailleurs, des optimisations computationnelles, telles que la réduction adaptative des graphes ou l'utilisation d'architectures plus légères, pourraient faciliter le passage à l'échelle et renforcer la compatibilité avec des applications en temps réel. Enfin, l'extension vers des modèles graphiques dynamiques intégrant des lois viscoélastiques dépendantes du temps offrirait une meilleure représentation des effets liés à la respiration, aux micromouvements musculaires et au port prolongé du masque. L'adoption d'une stratégie d'apprentissage hybride combinant

données simulées et données expérimentales constitue également une voie prometteuse pour renforcer la validité clinique du modèle tout en conservant la stabilité de l'apprentissage.

Enfin, cette recherche ouvre la voie à la conception et à la fabrication rapide de dispositifs respiratoires personnalisés à partir d'une simple acquisition 3D avec un potentiel d'extension vers d'autres dispositifs biomédicaux nécessitant un ajustement morphologique précis, tels que les orthèses, les prothèses ou les casques sportifs.

ANNEXE I

PERSONALIZED FITTING OF RESPIRATORY MASK USING DEEP LEARNING AND 3D FACIAL MODELLING

Eya MLIKA¹ , Bahe HACHEM² , Yamen AL HABASH² , Loic DEGUELDRE² , Luc DUONG¹

¹ Département de logiciel et technologie de l'information, École de Technologie Supérieure,
1100 Notre-Dame Ouest, Montréal, Québec, Canada H3C 1K3

² Numalogics,
200 Boul. Saint-Laurent, Montréal, Québec, Canada H2W 2R2

Article publié dans la revue « 3DBODY.TECH Journal » en octobre 2024.

Abstract

Respiratory masks are highly used in healthcare and industrial environments to protect individuals from airborne contaminants and infectious pathogens. However, conventional respiratory masks are often one-sized, making it challenging to fit diverse facial morphologies. If loosely fitted, the mask may not adequately safeguard the wearer, while excessive tightness can cause discomfort or even pressure wounds during prolonged use.

This project aims to propose an artificial intelligence approach for the design and customization of respiratory masks, emphasizing personalized products that better conform to the diversity of human facial morphology. The proposed approach begins with the creation of facial geometries using 3D facial data obtained through the ARKit framework. ARKit enables the acquisition of structured and complete meshes of subjects' faces despite incomplete or noisy input data. Each facial scan captures 5,023 three-dimensional points, providing a detailed representation of individual facial features. The resulting dataset, composed of 45 distinct facial scans, forms the foundation of our machine learning algorithm. This algorithm is designed to improve mask customization and fit, thereby enhancing both safety and comfort for the wearer.

Building upon this facial modeling, a deep learning model was developed to predict mask deformations when fitted to the face. The model identifies potential areas of pressure and mask

misfit, allowing problems to be detected before they become critical. Furthermore, a predictive model was introduced to simulate the interaction between the facial structure and the mask as accurately as possible. By combining scanning technologies with predictive modeling, the framework enables the detection of gaps and pressure points and facilitates preventive design adjustments. Through a deep understanding of these interactions, the proposed model suggests modifications to mask geometry to better match the unique contours of each face, ultimately improving the seal and comfort of the mask.

This research contributes to improving mask fitting, addressing key health protection challenges, and accelerating compliance with safety regulations. Ultimately, enhanced fitting of respiratory masks may have a significant impact on the design and production of personalized protective equipment.

Keywords : Respiratory masks, Customization, Artificial Intelligence, 3D Face Reconstruction, Mesh Generation, Non-rigid Deformation, ARKit, Deep Learning, Personal Protective Equipment, Safety, Health Care Safety, Industrial Safety, Facial Structure Interaction, Thin Plate Spline, TPSNet.

2. Introduction

Respiratory masks play a crucial role in protecting against hazardous airborne contaminants in both healthcare and industrial environments. These devices are essential for preventing infections caused by pathogens in medical environments, and for protecting workers from chemical pollutants posing various health risks in industrial settings (Suen, Guo, Ho, Au-Yeung & Lam, 2020; Radonovich *et al.*, 2019). Although occupational health and safety regulations require personal protective equipment, including respiratory masks, to follow safety standards, the conventional “one size fits all” design of these masks does not consider the different facial morphologies of users, compromising their effectiveness and comfort, particularly during prolonged wear (Shiya, Usman, Mohanad & Zihao, 2021; Cloet, Griffin, Yu & Durfee, 2022).

Faced with this problem, our study proposes an innovative approach using artificial intelligence to personalize respiratory masks. By combining 3D facial scanning, finite element analysis and deep learning, we develop customized masks that fit perfectly to the unique contours of each face. Our research aims to set up a method capable of predicting facial deformation under the mask and providing these results in real time when ordering a mask via a mobile application.

This article is structured as follows : the first section presents a review of related work. The second section details our project's method, including the generation and processing of facial mesh data and the development of our deep-learning model. The third section presents the results obtained, highlighting the accuracy of our dataset and the effectiveness of our prediction model. Finally, the conclusion summarizes the main contributions of our work and discusses future implications for the design of personalized protective equipment

3. Related work

In our earlier work, our team developed a personalized mask adapted to the morphology of the user's face. This customization was made possible by a mobile application that scanned the face and created the mask geometry. Their study combined 3D scanning with finite element analysis to assess the mask's performance, while confirming the numerical results through experimental measurements of pressure and spacing (Taeckens *et al.*, 2022). Machine learning models were applied to predict pressures at the mask-face interface and adjust mesh points according to the degree of clamping. Among these models, the Random Forest Regressor showed superior accuracy compared with the Decision Tree Regressor and Elastic Net models. However, these approaches met challenges, notably the integration of facial morphology into model training and the management of protection gaps due to incomplete data.




Figure-A I-1 Protocol for Mask Fit Simulation

The advancement in transforming unstructured and incomplete 3D point clouds into detailed meshes is significantly driven by the development of 3D morphable models (3DMMs) (Lattas *et al.*, 2020; Moschoglou, Ploumpis, Nicolaou, Papaioannou & Zafeiriou, 2020; Chan *et al.*, 2022; Li, Bolkart, Black, Li & Romero, 2017). These models allow for the creation of precise and adaptable shapes. By employing adjustable and morphable reference models, researchers can keep consistency and enhance the integration of scanning technologies with advanced mesh generation techniques. 3DMMs facilitate the filling of gaps in scanned data, helping to generate detailed and exact three-dimensional representations.

A main drawback from earlier work is that most studies assure a rigid fit and very little work focus on non-rigid deformation in shape transformation learning. Graph Convolution Networks (GCN) (Wang & Chang, 2019) and CDPNet have been proposed for learning non-rigid shape transformations (Khani *et al.*, 2023). GCN processes relational data within a graph structure, ideal for analysing non-rigid deformations. CDPNet predicts post-deformation transformations of 3D objects, maintaining structural integrity under various conditions. P2P-NET (Yang, Huang, Cohen-Or & Zhang, 2018) offers a generalized approach to learning various shape transformation tasks, while its derivative, P2MAT-Net (Yang, Yang, Wang & Li, 2020), transforms point clouds

into sets of medial spheres, although it requires further refinement to understand global shape properties.

4. Methodology

4.1 Creation of Structured and Complete Facial Mesh Databases from ARKit scan

The ARKit framework has significantly advanced the capability to capture 3D scans of human faces. However, despite efforts to minimize noise and address incomplete data, challenges remain in creating structured and complete facial meshes (Borduas *et al.*, 2020). To address this issue, we propose a method that integrates the average face from the FLAME database as a reference to enhance the ARKit scan data (Zheng *et al.*, 2023). The FLAME database is a statistical 3D model of the human face that captures a wide range of facial shapes, expressions, and poses. It is constructed by learning from a large dataset of 3D scans and is designed to stand for facial geometry using a low-dimensional parameter space. Integrating the average face from the FLAME database as a reference in this method provides a robust and consistent template that can significantly improve the quality of ARKit scan data. This method involves the extraction of facial landmarks, mesh alignment, and transformation techniques to generate a structured and complete facial mesh

4.2 Landmarks extraction

The first step involves extracting 100 facial landmarks from the ARKit scan. We start by manually selecting 68 reference landmarks of the face. However, these first 68 landmarks do not accurately capture the full facial morphology. To address this, we employ the Geodesic Ensemble Surface Sampling Algorithm (GESSA) to add more landmarks. GESSA begins by randomly sampling points across the facial surface and then improves their distribution to achieve uniformity. This optimization process maximizes the entropy in the landmark distribution, ensuring a detailed capture of the morphological variability (Tsagkrasoulis, Hysi, Spector & Montana, 2017).




Figure-A I-2
Landmarks from ARKit
scan

4.2.1 Mesh Alignment

Once the landmarks are identified, the next step is aligning the ARKit landmarks with the reference face using the Iterative Closest Point (ICP) algorithm. This process begins with proving initial landmark and reference face vertices correspondences. The ICP algorithm then iteratively refines the alignment by repeatedly matching corresponding points between the two meshes, estimating the best transformation (rotation and translation) to minimize the distance between these points, and applying this transformation to the ARKit mesh. This procedure iterates until the algorithm converges by reaching the best transformation (Zhang & Chen, 2001).

4.2.2 Mesh Generation

Following the alignment, the landmarks on the reference face are selected using the nearest neighbour algorithm. The transformation between the ARKit landmarks and the reference landmarks is computed using the Thin Plate Spline (TPS) algorithm. The TPS algorithm is particularly suited for capturing non rigid deformation, since it works by modeling the transformation needed to bend a thin plate spline from one shape into another, adhering to certain fixed points. It minimizes the energy needed to achieve this bending, ensuring a smooth and

continuous transformation (Lee & Yang, 2005). This computed transformation is then applied to the entire reference face, resulting in a complete and structured mesh that accurately stands for the morphology of the scanned face. This transformation ensures that the final mesh captures the unique facial features of each user, which is particularly crucial for applications such as the customization of respiratory masks. The proposed method yields precise and structured facial meshes that will be used to train a deep learning model to predict the deformation of the face after wearing the mask.

4.3 Deep learning model for Respiratory Mask Fitting

TPS-Net was developed to optimize the customization and fitting of respiratory masks by accurately predicting facial structure deformations upon mask application. This network is specifically designed to manage non-rigid transformations between 3D facial meshes, both pre- and post-mask application. By learning smooth and continuous geometric transformations, TPS-Net utilizes a neural network to precisely map facial points to their new positions after mask wear. The model is trained using a combination of Chamfer distance, which evaluates alignment accuracy, and a regularization term that ensures smooth transformations. This approach is particularly effective for accurately aligning source and target points, essential for fitting masks to diverse facial morphologies. To validate TPS-Net's performance, various evaluation metrics are employed, including Chamfer Distance, Mean Squared Error (MSE), and Mean Absolute Error (MAE). These metrics ensure that the model achieves precise and smooth transformations, with lower Chamfer distances showing better alignment and MSE, MAE providing additional measures of alignment accuracy.

5. Results and discussions

5.1 Creation of Structured and Complete Facial Mesh Databases from ARKit scan

The generation of the facial mesh from ARKit scan landmarks with the reference face from the FLAME database was performed using various algorithms to figure out the most effective

approach for this task. In this study, the ARKit face scan, captured with high precision, served as the reference comparator against which the performance of each method was evaluated. The performance of each method was evaluated using metrics such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Standard Deviation of Errors (STD), and Hausdorff Distance of Errors (HDE) -a measure of the maximum distance between points in one set and the nearest points in another set, reflecting the maximum possible error. The results, summarized in the table below, prove the effectiveness of each method :

Tableau-A I-1 Comparison of the four facial mesh generation algorithms

Method	RMSE (mm)	MAE (mm)	STD (mm)	HDE (mm)
ICP	0.037	0.022	0.030	0.183
TPS	0.037	0.021	0.030	0.184
ICP + TPS	0.033	0.019	0.027	0.165
FLAME	1.610	1.510	0.565	0.181

Figure 5 provides visual comparisons of the generation results for ICP, TPS, and the combined ICP+TPS approach. The images clearly illustrate that TPS and ICP+TPS methods provide more exact generations compared to ICP and Flame. The TPS method shows superior performance in aligning the landmarks closely with minimal gaps. With the ICP, TPS and Flame, we notice the significant gaps between the points in certain regions, showing poor representation of morphological variations. But with ICP+TPS, the points are more closely aligned, showing a better fit and more exact representation of the facial morphology. The TPS method captures non-rigid deformations effectively, which is crucial for accurately representing facial morphology. In contrast, the ICP method, being a rigid transformation, does not adequately account for morphological variations, leading to larger gaps between point sets in certain regions. The FLAME model, however, produced poor results due to suboptimal parameter optimization and its limited use of only 100 landmarks, which is insufficient to accurately capture the detailed features and variations in facial morphology. The high RMSE and MAE values observed for the FLAME model reflect this limitation.




Figure-A I-3 Comparative Analysis of Mesh Generation technique

5.2 Thin Plate Spline Networks TPS-NET for Respiratory Mask Fitting

In our study, the dataset was distributed with 80 % used for training, 10 % for validation, and the remaining 10 % dedicated to testing. This distribution aligns with established practices commonly referenced in literature. To provide a comprehensive evaluation of our model's performance, we conducted a comparative analysis with Coherence Point Drift Network (CPD-Net), a well-recognized point-to-point network.

Tableau-A I-2 Performance Comparison of Facial Deformation Prediction Models in millimeters (mm)

Model	RMSE (mm)	MAE (mm)	Chamfer Distance (mm)
TPS-Net	0.0005	0.0002	0.022
Point-to-Point Network	0.0017	0.0003	0.033
CPD-Net	0.0706	0.0582	0.046

Table 2 presents the averaged results for all models tested. We report the root mean square error (RSME), mean absolute error (MAE), and Chamfer distance a metric that quantifies the

similarity between two-point clouds by averaging the nearest point distances between sets. The TPS-NET model achieved the lowest error across all metrics, showing its superior performance in predicting facial deformations. The Point-to-point network also performed well but showed higher errors compared to TPS-NET. The CPDNET model had the highest errors, suggesting less effectiveness for this specific application. Adding a learning rate decay strategy provided more flexibility to the networks by reducing the learning rate by 50% after every 50 epochs, enhancing the convergence characteristics in the later stages of training. The rigorous training and testing regimen ensured robust evaluation of each model. Comparing the results, TPS-NET significantly outperformed the other models, achieving an RSME of 0.0005 mm, an MAE of 0.0002 mm, and a Chamfer distance of 0.022 mm. These values show the model's ability to accurately predict facial deformations, crucial for applications where precise geometric adjustments are necessary.

6. Conclusion and Future Work

The goal of this study was to propose and to evaluate a new fitting algorithm, designed for respiratory masks. This has important implications for health and safety in both medical and industrial settings, potentially reducing the risks associated with prolonged mask usage and ensuring better compliance with safety regulations. Future work will focus on further refining the models and expanding the dataset to include a wider variety of facial morphologies, thereby enhancing the generalizability and robustness of the proposed solutions.

ANNEXE II

COMPARAISON CRITIQUE DES APPROCHES EXISTANTES POUR LA MODÉLISATION DES DÉFORMATIONS FACIALES

Tableau-A II-1 Comparaison critique des principales approches pour la prédiction des pressions et déformations faciales

Approche	Principe	Avantages	Limites
FEA	Simulation mécanique fondée sur la physique des matériaux (tissus hyperélastiques, masque rigide).	Haute précision physique ; validation expérimentale possible ; cartes de pression détaillées.	Très coûteux en calcul ; non adapté au temps réel ; nécessite un maillage et des paramètres précis.
RF (Al Habash <i>et al.</i> , 2024)	Apprentissage supervisé sur données géométriques et forces mesurées.	Simple, rapide à entraîner, bon compromis précision-temps.	Ne capture pas les dépendances spatiales ; pas de cohérence physique ; sensible au bruit.
PointNet (Qi <i>et al.</i> , 2017a)	Traitement direct du nuage de points 3D (MLP partagé + agrégation globale).	Manipule données brutes ; architecture simple et rapide.	Ne modélise pas les relations locales ; perd l'information topologique.

(suite à la page suivante)

Tableau-A II-1 Comparaison critique des principales approches pour la prédiction des pressions et déformations faciales (suite).

Approche	Principe	Avantages	Limites
PointNet++ (Qi <i>et al.</i> , 2017b)	Extension hiérarchique multi-échelle de PointNet (k -NN local).	Capture formes locales et globales; plus robuste aux structures complexes.	Sensible aux données bruitées et partielles; ne considère pas la physique.
CPD-Net (Wang <i>et al.</i> , 2019)	Apprentissage non supervisé d'un champ de déplacement continu (Coherent Point Drift).	Préserve la continuité topologique; ne nécessite pas d'annotation.	Dépend fortement des correspondances; sensible au bruit et aux données incomplètes.
CDP-Net (Khani <i>et al.</i> , 2023)	Extension clinique avec repères anatomiques et métadonnées (âge, sexe, IMC).	Prédictions personnalisées; cohérence morphologique.	Requiert repères anatomiques denses; dépend de la qualité clinique des données.
GNN (Wang & Chang, 2019)	Convolution sur graphes : message passing entre sommets connectés.	Capture relations locales (nez-joues); préserve topologie du maillage.	Purement géométrique; pas de prise en compte des forces; sensible aux changements topologiques.

(suite à la page suivante)

Tableau-A II-1 Comparaison critique des principales approches pour la prédiction des pressions et déformations faciales (suite).

Approche	Principe	Avantages	Limites
VGAE (Kipf & Welling, 2016; Zhou <i>et al.</i> , 2020)	Encodeur GCN + espace latent probabiliste régularisé (KL) + décodeur.	Représentations latentes continues ; interpolation fluide ; capture de la variabilité morphologique.	Distribution gaussienne restrictive ; sur-lissage ; absence de contraintes mécaniques.
Physics-Encoded GNN (Saleh <i>et al.</i> , 2024)	Intègre forces et contraintes dans nœuds/arêtes ; attention croisée rigide-déformable.	Cohérence physique ; modélise interactions masque-visage ; meilleure stabilité.	Fort besoin en données annotées (forces, contraintes) ; coût élevé ; généralisation limitée.

BIBLIOGRAPHIE

- Agostini, A., Castonguay-Henri, A., Viens, S.-P., Borduas, J. & Duong, L. (2022). Reliability and accuracy of mobile 3D scanning technologies for the customization of respiratory face masks.
- Al Habash, Y., Hachem, B., Taeckens, H., Degueldre, L. & Duong, L. (2024). Pressure Prediction for the Personalized and Automatic Fitting of Respiratory Masks. *2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 1–5.
- Ardon-Dryer, K., Warzywoda, J., Tekin, R., Biros, J., Almodovar, S., Weeks, B. L., Hope-Weeks, L. J. & Sacco Jr, A. (2021). Mask Material Filtration Efficiency and Mask Fitting at the Crossroads : Implications During Pandemic Times. *Aerosol and Air Quality Research*, 21(7), 200571.
- Bai, J., Lin, Z., Wang, Y., Wen, J., Liu, Y., Rabczuk, T., Gu, Y. & Feng, X.-Q. (2025). Energy-Based Physics-Informed Neural Network for Frictionless Contact Problems under Large Deformation. *Computer Methods in Applied Mechanics and Engineering*, 437, 117787.
- Barwey, S., Balin, R., Lusch, B., Patel, S., Balakrishnan, R., Pal, P., Maulik, R. & Vishwanath, V. (2024). Scalable and Consistent Graph Neural Networks for Distributed Mesh-Based Data-Driven Modeling. *SC24-W : Workshops of the International Conference for High Performance Computing, Networking, Storage and Analysis*, pp. 1058–1070.
- Bassier, M., Vergauwen, M. & Poux, F. (2020). Point Cloud vs. Mesh Features for Building Interior Classification. *Remote Sensing*, 12(14), 2224.
- Besl, P. J. & McKay, N. D. (1992). Method for registration of 3-D shapes. *Sensor fusion IV : control paradigms and data structures*, 1611, 586–606.
- Boluk, B. [Accessed : 2025-10-06]. (2021). Problem Solving for Discomfort When Wearing a Mask for a Long Time. Repéré à https://www.furtherium.com/2021/08/11/problem_solving_for_discomfort_when_wearing_mask_for_long_time/.
- Bookstein, F. L. (2002). Principal warps : Thin-plate splines and the decomposition of deformations. *IEEE Transactions on pattern analysis and machine intelligence*, 11(6), 567–585.
- Borduas, J., Castonguay, A., Laurin, P. & Beland, D. (2020). Reliability of Mobile 3D Scanning Technologies for the Customization of Respiratory Face Masks. *Proc. 11th Int. Conf. Exhib. 3D Body Scanning Processing Technology*, pp. 1–8.

- Bronstein, M. M., Bruna, J., LeCun, Y., Szlam, A. & Vandergheynst, P. (2017). Geometric Deep Learning : Going Beyond Euclidean Data. *IEEE Signal Processing Magazine*, 34(4), 18–42.
- Bustos, B., Keim, D. A., Saupe, D., Schreck, T. & Vranić, D. V. (2005). Feature-Based Similarity Search in 3D Object Databases. *ACM Computing Surveys*, 37(4), 345–387.
- Bytyqi, Q., Wolpert, N. & Schömer, E. (2020). Local-area-learning network : Meaningful local areas for efficient point cloud analysis.
- Chan, E. R., Lin, C. Z., Chan, M. A., Nagano, K., Pan, B., De Mello, S., Gallo, O., Guibas, L. J., Tremblay, J., Khamis, S. et al. (2022). Efficient Geometry-Aware 3D Generative Adversarial Networks. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 16123–16133.
- Chen, T. & Guestrin, C. (2016). XGBoost : A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785–794.
- Chui, H. & Rangarajan, A. (2003). A New Point Matching Algorithm for Non-Rigid Registration. *Computer Vision and Image Understanding*, 89(2-3), 114–141.
- Cloet, A., Griffin, L., Yu, M. & Durfee, W. (2022). Design considerations for protective mask development : A remote mask usability evaluation. *Applied Ergonomics*, 102, 103751.
- Coyer, F., Cook, J.-L., Doubrovsky, A., Vann, A. & McNamara, G. (2022). Exploring Medical Device-Related Pressure Injuries in a Single Intensive Care Setting : A Longitudinal Point Prevalence Study. *Intensive and Critical Care Nursing*, 68, 103155.
- Davis, M. H., Khotanzad, A., Flamig, D. P. & Harms, S. E. (2002). A Physics-Based Coordinate Transformation for 3-D Image Matching. *IEEE Transactions on Medical Imaging*, 16(3), 317–328.
- Delalleau, A., Josse, G., Lagarde, J.-M., Zahouani, H. & Bergheau, J.-M. (2006). Characterization of the Mechanical Properties of Skin by Inverse Analysis Combined with the Indentation Test. *Journal of Biomechanics*, 39(9), 1603–1610.
- Deng, B., Yao, Y., Dyke, R. M. & Zhang, J. (2022). A Survey of Non-Rigid 3D Registration. *Computer Graphics Forum*, 41(2), 559–589.

- des normes de l'équité de la santé et de la sécurité du travail (CNESST), C. [Page consultée le 9 octobre 2025]. (2021). Appareils de protection respiratoire. Repéré à <https://www.cnesst.gouv.qc.ca/fr/prevention-securite/identifier-corriger-risques/liste-informations-prevention/appareils-protection-respiratoire>.
- Fang, S.-Y. & Fang, J.-J. (2011). Automatic Head and Facial Feature Extraction Based on Geometry Variations. *Computer-Aided Design*, 43(12), 1729–1739.
- Faroughi, S. A., Pawar, N. M., Fernandes, C., Raissi, M., Das, S., Kalantari, N. K. & Mahjour, S. K. (2024). Physics-Guided, Physics-Informed, and Physics-Encoded Neural Networks and Operators in Scientific Computing : Fluid and Solid Mechanics. *Journal of Computing and Information Science in Engineering*, 24(4), 040802.
- for Disease Control, C. & Prevention. [Consulté le 2022-08-19]. (2020). Proper N95 Respirator Use for Respiratory Protection Preparedness. Repéré à <https://blogs.cdc.gov/niosh-science-blog/2020/03/16/n95-preparedness/>.
- Gakhal, M. K., Bakshi, A., Gu, M. & Khambay, B. S. (2024). A Study to Determine the Three-Dimensional (3D) Facial Shape Characteristics for a Successful FFP3 Mask Fit. *Scientific Reports*, 14(1), 28683.
- Gao, M., Ruan, N., Shi, J. & Zhou, W. (2022). Deep Neural Network for 3D Shape Classification Based on Mesh Feature. *Sensors*, 22(18), 7040.
- Hamilton, W., Ying, Z. & Leskovec, J. (2017). Inductive representation learning on large graphs. *Advances in neural information processing systems*, 30, 1025 - 1035.
- Hancock, P. A. & Hutchinson, M. F. (2006). Spatial Interpolation of Large Climate Data Sets Using Bivariate Thin Plate Smoothing Splines. *Environmental Modelling & Software*, 21(12), 1684–1694.
- Institut National de Recherche et de Sécurité. [Consulté le 1er juin 2025]. (2024). Masques de protection respiratoire et risques biologiques : foire aux questions. Repéré à <https://www.inrs.fr/risques/biologiques/faq-masque-protection-respiratoire.html>.
- Ippolito, M., Vitale, F., Accurso, G., Iozzo, P., Gregoretti, C., Giarratano, A. & Cortegiani, A. (2020). Medical Masks and Respirators for the Protection of Healthcare Workers from SARS-CoV-2 and Other Viruses. *Pulmonology*, 26(4), 204–212.
- Jin, W., Derr, T., Liu, H., Wang, Y., Wang, S., Liu, Z. & Tang, J. (2020). Self-Supervised Learning on Graphs : Deep Insights and New Direction.
- Johnson, K. L. (1987). *Contact Mechanics*. Cambridge University Press.

- Kähler, K., Haber, J. & Seidel, H.-P. (2003). Reanimating the Dead : Reconstruction of Expressive Faces from Skull Data. *ACM Transactions on Graphics (TOG)*, 22(3), 554–561.
- Karniadakis, G. E., Kevrekidis, I. G., Lu, L., Perdikaris, P., Wang, S. & Yang, L. (2021). Physics-Informed Machine Learning. *Nature Reviews Physics*, 3(6), 422–440.
- Khani, M., Debanné, P., Labelle, H., Parent, S. & Cheriet, F. (2023). Prediction of Postoperative 3D Spine Shape Using Controlled Point Deformation Network (CPDNet). *Medical Imaging 2023 : Image Processing*, 12464, 681–687.
- Kipf, T. N. & Welling, M. (2016). Variational Graph Auto-Encoders.
- Kipf, T. N. & Welling, M. (2017). Semi-Supervised Classification with Graph Convolutional Networks. *Proceedings of the 5th International Conference on Learning Representations (ICLR)*.
- Lampen, N., Kim, D., Xu, X., Fang, X., Lee, J., Kuang, T., Deng, H. H., Liebschner, M. A. K., Gateno, J. & Yan, P. (2025). Learning Soft Tissue Deformation from Incremental Simulations. *Medical Physics*, 52(3), 1914–1925.
- Lattas, A., Moschoglou, S., Gecer, B., Ploumpis, S., Triantafyllou, V., Ghosh, A. & Zafeiriou, S. (2020). AvatarMe : Realistically Renderable 3D Facial Reconstruction “in-the-wild”. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 760–769.
- Lee, J. & Yang, M.-H. (2005). A Direct Method for Modeling Non-Rigid Motion with Thin Plate Spline. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. doi : 10.1109/CVPR.2005.24.
- Lee, W., Lee, B., Yang, X. & You, H. (2022). A Method for Generation of a Sizing System and Representative Models for a Facial Mask Design. *Applied Sciences*, 12(23), 12387.
- Lewis, J. R., Michael, S. S. & Mary, T. B. (2019). N95 Respirators vs Medical Masks for Preventing Influenza Among Health Care Personnel. *JAMA Network*, 322(9), 824–833. doi : 10.1001/jama.2019.11645.
- Li, T., Bolkart, T., Black, M. J., Li, H. & Romero, J. (2017). Learning a Model of Facial Shape and Expression from 4D Scans. *ACM Transactions on Graphics*, 36(6), 194 :1–194 :17.
- Liu, M., Liang, L. & Sun, W. (2020). A Generic Physics-Informed Neural Network-Based Constitutive Model for Soft Biological Tissues. *Computer Methods in Applied Mechanics and Engineering*, 372, 113402.

- Liu, W., Piao, Z., Min, J., Luo, W., Ma, L. & Gao, S. (2019). Liquid Warping GAN : A Unified Framework for Human Motion Imitation, Appearance Transfer and Novel View Synthesis. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 5904–5913.
- Martelly, E., Rana, S. & Shimada, K. (2025). Method for Evaluating the Fit of Custom-Fit Continuous Positive Airway Pressure Masks Using Finite Element Analysis. *Computer Methods in Biomechanics and Biomedical Engineering*, 28(11), 1800–1817.
- Maturana, D. & Scherer, S. (2015). VoxNet : A 3D Convolutional Neural Network for Real-Time Object Recognition. *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 922–928.
- Maurizi, M., Gao, C. & Berto, F. (2022). Predicting Stress, Strain and Deformation Fields in Materials and Structures with Graph Neural Networks. *Scientific Reports*, 12(1), 21834.
- Mlika, E., Hachem, B., Alhabash, Y., Degueldre, L. & Duong, L. (2024). Personalized Fitting of Respiratory Mask Using Deep Learning and 3D Facial Modeling.
- Moschoglou, S., Ploumpis, S., Nicolaou, M. A., Papaioannou, A. & Zafeiriou, S. (2020). 3dfacegan : Adversarial nets for 3d face representation, generation, and translation. *International Journal of Computer Vision*, 128(10), 2534–2551.
- Occupational Safety and Health Administration (OSHA). [Accessed : 2025-10-06]. (2024). Respiratory Protection — Overview. Repéré à <https://www.osha.gov/respiratory-protection>.
- Park, H. & Lee, D. (2019). Comparison Between Point Cloud and Mesh Models Using Images from an Unmanned Aerial Vehicle. *Measurement*, 138, 461–466.
- Park, J. J., Florence, P., Straub, J., Newcombe, R. & Lovegrove, S. (2019). DeepSDF : Learning Continuous Signed Distance Functions for Shape Representation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 165–174.
- Pauly, M., Keiser, R. & Gross, M. (2003). Multi-Scale Feature Extraction on Point-Sampled Surfaces. *Computer Graphics Forum*, 22(3), 281–289.
- Pelissier, U., Parret-Fréaud, A., Bordeu, F. & Mesri, Y. (2024). Graph Neural Networks for Mesh Generation and Adaptation in Structural and Fluid Mechanics. *Mathematics*, 12(18), 2933.

- Peng, S., Jiang, C., Liao, Y., Niemeyer, M., Pollefeys, M. & Geiger, A. (2021). Shape as Points : A Differentiable Poisson Solver. *Advances in Neural Information Processing Systems*, 34, 13032–13044.
- Qi, C. R., Su, H., Mo, K. & Guibas, L. J. (2017a). PointNet : Deep Learning on Point Sets for 3D Classification and Segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 652–660.
- Qi, C. R., Yi, L., Su, H. & Guibas, L. J. (2017b). Pointnet++ : Deep hierarchical feature learning on point sets in a metric space. *Advances in neural information processing systems*, 30, 5105 - 5114.
- Qian, Y., Willeke, K., Grinshpun, S. A., Donnelly, J. & Coffey, C. C. (1998). Performance of N95 Respirators : Filtration Efficiency for Airborne Microbial and Inert Particles. *American Industrial Hygiene Association Journal*, 59(2), 128–132.
- Radonovich, L. J., Simberkoff, M. S., Bessesen, M. T., Brown, A. C., Cummings, D. A., Gaydos, C. A., Los, J. G., Krosche, A. E., Gibert, C. L., Gorse, G. J. et al. (2019). N95 respirators vs medical masks for preventing influenza among health care personnel : a randomized clinical trial. *Jama*, 322(9), 824–833.
- Raissi, M., Perdikaris, P. & Karniadakis, G. E. (2019). Physics-Informed Neural Networks : A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. *Journal of Computational Physics*, 378, 686–707.
- Rengasamy, S. & Eimer, B. C. (2012). Nanoparticle Penetration Through Filter Media and Leakage Through Face Seal Interface of N95 Filtering Facepiece Respirators. *Annals of Occupational Hygiene*, 56(5), 568–580.
- Rohr, K., Stiehl, H. S., Sprengel, R., Buzug, T. M., Weese, J. & Kuhn, M. (2002). Landmark-based elastic registration using approximating thin-plate splines. *IEEE Transactions on medical imaging*, 20(6), 526–534.
- Sahin, T., von Danwitz, M. & Popp, A. (2024). Solving Forward and Inverse Problems of Contact Mechanics Using Physics-Informed Neural Networks. *Advanced Modeling and Simulation in Engineering Sciences*, 11(1), 11.
- Saleh, M., Sommersperger, M., Navab, N. & Tombari, F. (2024). Physics-Encoded Graph Neural Networks for Deformation Prediction under Contact. *2024 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 17160–17166.

- Salehi, Y. & Giannacopoulos, D. (2022). PhysGNN : A Physics-Driven Graph Neural Network Based Model for Predicting Soft Tissue Deformation in Image-Guided Neurosurgery. *Advances in Neural Information Processing Systems*, 35, 37282–37296.
- Sanchez-Gonzalez, A., Godwin, J., Pfaff, T., Ying, R., Leskovec, J. & Battaglia, P. (2020). Learning to Simulate Complex Physics with Graph Networks. *Proceedings of the International Conference on Machine Learning (ICML)*, pp. 8459–8468.
- Scott, A. R., Hu, J., Gan, C., Morris, J. A., Meacham, K. W. & Ballard, D. H. (2020). Safety Concerns for Facial Topography Customized 3D-Printed N95 Filtering Face-Piece Respirator Produced for the COVID-19 Pandemic : Initial Step Is Respiratory Fit Testing. *International Journal of Oral and Maxillofacial Surgery*, 49(12), 1660.
- Shikama, M., Nakagami, G., Noguchi, H., Mori, T. & Sanada, H. (2018). Development of Personalized Fitting Device with 3-Dimensional Solution for Prevention of NIV Oronasal Mask-Related Pressure Ulcers. *Respiratory Care*, 63(8), 1024–1032.
- Shiya, L., Usman, W., Mohanad, B. & Zihao, W. L. (2021). A scalable mass customization design process for 3D-printed respirator mask to combat COVID-19. *Rapid Prototyping Journal*, 27(7), 1302–1317. doi : 10.1108/RPJ-10-2020-0231.
- Sinthanayothin, C. & Bholsithi, W. (2009). 3D Facial Deformable Using Cubic Spline and Thin Plate Spline. *2009 6th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, 2, 668–671.
- Suen, L. K. P., Guo, Y. P., Ho, S. S., Au-Yeung, C. H. & Lam, S. C. (2020). Comparing mask fit and usability of traditional and nanofibre N95 filtering facepiece respirators before and after nursing procedures. *Journal of Hospital Infection*, 104(3), 336–343. doi : 10.1016/j.jhin.2019.09.014.
- Swennen, G. R. J., Pottel, L. & Haers, P. E. (2020). Custom-Made 3D-Printed Face Masks in Case of Pandemic Crisis Situations with a Lack of Commercially Available FFP2/3 Masks. *International Journal of Oral and Maxillofacial Surgery*, 49(5), 673–677.
- Taeckens, H., Agostini, A., Degueldre, L., Hachem, B., Viens, S.-P., Castonguay, A., Borduas, J. & Duong, L. (2022). Personalized Fitting of Respiratory Mask Using 3D Numerical Simulation and Finite Element Analysis. *Proceedings of 3DBODY.TECH 2022—13th International Conference and Exhibition on 3D Body Scanning and Processing Technologies*, pp. 25–26.
- Taylor, Z. A., Cheng, M. & Ourselin, S. (2008). High-Speed Nonlinear Finite Element Analysis for Surgical Simulation Using Graphics Processing Units. *IEEE Transactions on Medical Imaging*, 27(5), 650–663.

- Tcharkhtchi, A., Abbasnezhad, N., Seydani, M. Z., Zirak, N., Farzaneh, S. & Shirinbayan, M. (2021). An Overview of Filtration Efficiency Through the Masks : Mechanisms of Aerosol Penetration. *Bioactive Materials*, 6(1), 106–122.
- Tsagkrasoulis, D., Hysi, P., Spector, T. & Montana, G. (2017). Heritability Maps of Human Face Morphology Through Large-Scale Automated Three-Dimensional Phenotyping. *Scientific Reports*, 7(1), 45885.
- Verberne, J. W. R., Worsley, P. R. & Bader, D. L. (2021). A 3D Registration Methodology to Evaluate the Goodness of Fit at the Individual-Respiratory Mask Interface. *Computer Methods in Biomechanics and Biomedical Engineering*, 24(7), 728–739.
- Wang, L., Li, X., Chen, J. & Fang, Y. (2019). Coherent point drift networks : Unsupervised learning of non-rigid point set registration.
- Wang, Z. & Chang, H. (2019). 3D Mesh Deformation Using Graph Convolution Network. *2019 IEEE 4th International Conference on Computer and Communication Systems (ICCCS)*, pp. 375–378.
- World Health Organization (WHO). (2022). Occupational health : health workers [Fact sheet]. Repéré à <https://www.who.int/news-room/fact-sheets/detail/occupational-health--health-workers>.
- Xie, Y., Xu, Z., Zhang, J., Wang, Z. & Ji, S. (2022). Self-Supervised Learning of Graph Neural Networks : A Unified Review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(2), 2412–2429.
- Xu, H., Zhao, Z., Cao, Y., Chen, C., Ge, H. & Liu, Z. (2024). 3D Face Reconstruction Using a Spectral-Based Graph Convolution Encoder. *Companion Proceedings of the ACM Web Conference 2024*, pp. 633–636.
- Yang, B., Yang, J., Wang, X. & Li, X. (2020). P2MAT-NET : Learning Medial Axis Transform from Sparse Point Clouds. *Computer Aided Geometric Design*, 80, 101874. doi : 10.1016/j.cagd.2020.101874.
- Yang, J. (2011). The Thin Plate Spline Robust Point Matching (TPS-RPM) Algorithm : A Revisit. *Pattern Recognition Letters*, 32(7), 910–918.
- Yang, K., Huang, H., Cohen-Or, D. & Zhang, H. (2018). P2P-NET : Bidirectional Point Displacement Net for Shape Transform. *ACM Transactions on Graphics*, 37(4), 1–13. doi : 10.1145/3197517.3201288.

- Yu, M., Griffin, L., Durfee, W. K. & Arnold, S. (2024). Face Anthropometry for Filtering Facepiece Respirators : Analysis of the Association Between Facial Dimensions and Respirator Fit. *Annals of Work Exposures and Health*, 68(3), 312–324.
- Zhang, C. & Chen, T. (2001). Efficient Feature Extraction for 2D/3D Objects in Mesh Representation. *Proceedings 2001 International Conference on Image Processing (Cat. No. 01CH37205)*, 3, 935–938.
- Zhao, J. & Zhang, H. (2022). Thin-Plate Spline Motion Model for Image Animation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 3657–3666.
- Zheng, W., Zhao, J., Liu, X., Pan, Y., Gan, Z., Han, H. & Liu, N. (2023). FLAME-Based Multi-View 3D Face Reconstruction. *Computer Graphics International Conference*, pp. 327–339.
- Zhou, J., Cui, G., Hu, S., Zhang, Z., Yang, C., Liu, Z., Wang, L., Li, C. & Sun, M. (2020). Graph Neural Networks : A Review of Methods and Applications. *AI Open*, 1, 57–81.
- Zhu, J. H., Lee, S. J., Wang, D. Y. & Lee, H. P. (2014). Effects of Long-Duration Wearing of N95 Respirator and Surgical Facemask : A Pilot Study [Journal Article]. Repéré à <https://doi.org/10.15406/jlpr.2014.01.00021>.