

SPIM

Thèse de Doctorat



école doctorale sciences pour l'ingénieur et microtechniques
UNIVERSITÉ DE BOURGOGNE

Reconnaissance et correspondance de formes 3D pour des systèmes intelligents de vision par ordinateur

■ SEIF EDDINE NAFFOUTI



SPIM

Thèse de Doctorat



école doctorale sciences pour l'ingénieur et microtechniques
UNIVERSITÉ DE BOURGOGNE

THÈSE présentée par

SEIF EDDINE NAFFOUTI

pour obtenir le

Grade de Docteur de

l'Université de Bourgogne¹

et de

l'Ecole Nationale d'Ingénieurs de Monastir²

Spécialité : ¹ **Instrumentation et Informatique de l'Image**

² **Génie Electrique**

Reconnaissance et correspondance de formes 3D pour des systèmes intelligents de vision par ordinateur

Unité de Recherche :

¹ Laboratoire Électronique, Informatique et Image - LE2I FRE2005, CNRS, Arts et Métiers

² Etudes des Systèmes Industriels et des Energies Renouvelables - ESIER

Soutenue publiquement le 19 Octobre 2018 devant le Jury composé de :

NAJOUA ESSOUKRI BEN AMARA	Président	Professeur, Univ. Sousse, Tunisie
CÉDRIC DEMONCEAUX	Examineur	Professeur, Univ. Bourgogne, France
GILLES GESQUIERE	Rapporteur	Professeur, Univ. Lyon, France
ALI DOUIK	Rapporteur	Professeur, Univ. Sousse, Tunisie
FABRICE MÉRIAUDEAU	Co-directeur de thèse	Professeur, Univ. Bourgogne, France
ANIS SAKLY	Co-directeur de thèse	Professeur, Univ. Monastir, Tunisie
YOHAN FOUGEROLLE	Encadrant de thèse	Maître de Conférences, Univ. Bourgogne, France

AVANT-PROPOS

Le travail présenté dans ce mémoire a été effectué en cotutelle entre l'Université de Bourgogne au sein du Laboratoire d'Electronique, Informatique et Image (LE2I¹), site Le Creusot, d'une part, et l'Université de Monastir au sein du département Génie Electrique à l'unité de recherche des Etudes des Systèmes Industriels et des Energies Renouvelables (ESIER) à l'Ecole Nationale d'Ingénieurs de Monastir (ENIM²), d'autre part; et s'inscrit dans la thématique de recherche *Instrumentation et Informatique de l'Image*. Cette thèse a été supportée par le parrainage du programme européen Vision Image et Robotiques (VIBOT³) (Erasmus Mundus).



1. LE2I : www.le2i.cnrs.fr
2. ENIM : www.enim.rnu.tn
3. VIBOT : www.vibot.org

REMERCIEMENTS

Exercice d'apparence banal, mais pourtant si difficile... Une thèse apporte son lot d'émotions, de joies, de doutes, de fatigues, comment n'oublier personne parmi celles et ceux qui d'une discussion, d'un regard ou d'un geste, parviennent toujours à vous faire naviguer sur les flots ? C'est à eux tous que je souhaite adresser ces remerciements, eux qui m'ont tant apporté.

A l'issue de ce travail, je remercie, en premier lieu, le bon Dieu de m'avoir donné la force de le mener à terme. Il m'est agréable de m'acquitter d'une dette de reconnaissance auprès de toutes les personnes dont l'intervention au cours de cette thèse, a bien favorisé son aboutissement.

Mes seconds remerciements vont à Fabrice MERIAUDEAU, le directeur de cette thèse, de m'avoir accueilli au sein du laboratoire *le2i* et d'avoir accepté de diriger mes travaux de thèse, mais également au co-encadrant et au co-directeur de cette thèse, respectivement, Yohan FOUGEROLLE et Anis SAKLY, non par tradition, mais pour le rôle déterminant qu'ils ont su jouer tout au long de ces cinq années de thèse. Je leurs exprime toute ma gratitude d'avoir su instaurer entre nous un climat d'amitié, ce qui a rendu cette expérience très agréable. Ce travail doit beaucoup à leur dynamisme et à leur rigueur scientifique. Merci pour leurs précieux conseils, leur complicité, leur soutien constant, leur habileté à me faire comprendre lorsque je m'égarais -souvent- et leur enthousiasme. De plus, il semble impossible de ne pas souligner leurs qualités scientifiques mais également humaines ainsi que leur humour respectif.

Je remercie l'ensemble des membres du jury pour l'intérêt qu'ils ont manifesté à évaluer et juger mon travail de recherche. Je remercie mes rapporteurs Messieurs Gilles GESQUIERT professeur à l'université de Lyon, et Ali DOUIK professeur à l'université de Sousse pour l'honneur qu'ils m'ont fait en acceptant de rapporter mes travaux. Je remercie également Monsieur Cédric DEMONCEAUX professeur à l'université de Bourgogne pour avoir accepté de faire partie de mon jury de soutenance et Madame Najoua ES-SOUKRI BEN AMARA professeur à l'université de Sousse pour sa précieuse présence durant ma soutenance en tant qu'examineur et président du jury.

Je dédie ces lignes à tous ceux qui ont cru en moi et qui m'ont toujours aidé et soutenu. Je pense à ma femme Ferida qui a su être mon refuge dans les moments difficiles et qui m'est chère par le cœur et le sang. Je pense à ma chère mère et à mon cher père qui, avec leur tendresse, me font oublier mes soucis et pour l'incroyable liste de tout ce que je leur dois depuis 30 ans, qu'ils trouvent dans ce modeste travail le fruit de leurs efforts et leurs sacrifices. Je pense à mon frère Bader Eddine et à mes sœurs Chourouk et Rabeb qui n'ont pas cessé de m'encourager.

Que ceux qui ont participé de près ou de loin à la réalisation de ce travail trouvent ici le témoignage de ma reconnaissance.

Enfin, merci à l'ensemble de mes proches en Tunisie et en France pour le soutien qu'ils m'ont apporté durant cette thèse.

SOMMAIRE

Avant-propos	v
Remerciements	vii
Liste des acronymes	xiii
1 Introduction	1
1.1 Définition du problème et motivation	2
1.2 Organisation du document et contributions	4
1.3 Publications de l'auteur	5
2 Géométrie et signatures spectrales de formes	7
2.1 Introduction	7
2.2 Géométrie différentielle et spectrale de formes	8
2.2.1 Maillage triangulaire : notations	8
2.2.2 Opérateur de Laplace sur une surface	9
2.2.2.1 Opérateur de Laplace-Beltrami	9
2.2.2.2 Propriétés de l'opérateur de Laplace-Beltrami	10
2.3 Représentation différentielle d'une surface	11
2.3.1 Discrétisation de l'opérateur de Laplace-Beltrami	11
2.3.2 Analyse spectrale	13
2.4 Signatures spectrales de formes	16
2.4.1 ShapeDNA	17
2.4.2 Signature de point globale	17
2.4.3 Signature du noyau de chaleur	18
2.4.4 Signature de chaleur moyenne	19
2.4.5 Descripteur de distribution de température	20
2.4.6 Signature du noyau d'onde	21
2.5 Autres méthodes spectrales	22
2.6 Conclusion	23

3	Signature de point globale avancée (AGPS)	25
3.1	Introduction	25
3.1.1	Travaux antérieurs	26
3.1.2	Contributions	29
3.2	L'approche proposée	30
3.3	Classification et recherche de formes	33
3.3.1	Détection de points d'intérêts	34
3.3.2	AGPS pour la recherche de forme	35
3.4	Expériences et résultats	36
3.4.1	Réglage des paramètres et temps de calcul	37
3.4.2	Classification des caractéristiques	39
3.4.3	Consistance d'AGPS face au changement topologique	40
3.4.4	Appariement et la recherche globale de formes	40
3.4.4.1	Expériences sur SHREC-2012 et SHREC-2015	41
3.4.4.2	Expériences sur la base de données McGill	44
3.4.5	Évaluation de la détection de points saillants par AGPS	46
3.5	Conclusions	48
4	Signature optimisée du noyau d'onde (OWKS)	49
4.1	Introduction	49
4.1.1	Travaux antérieurs	50
4.1.2	Contributions	52
4.2	Préliminaires théoriques	54
4.2.1	Signature du noyau d'onde revisitée	54
4.2.2	Introduction à SPSO et MPSO	54
4.3	Reconnaissance de formes basée sur OWKS	56
4.4	Expériences et résultats	58
4.4.1	Réglage des paramètres et temps de calcul	58
4.4.2	Classification des caractéristiques	59
4.4.3	Classification de formes	61
4.4.4	Appariement et recherche de formes	62
4.4.4.1	Performance d'appariement	62
4.4.4.2	Résultats de l'évaluation de récupération	63
4.5	Conclusions	65
5	Conclusions et travaux futurs	67

5.1	Contributions de la thèse	67
5.1.1	Reconnaissance et recherche de formes 3D utilisant une signature de point globale avancée	67
5.1.2	Appariement et la récupération de formes 3D déformables à travers un descripteur du noyau d'onde optimisé	68
5.2	Orientations des travaux futurs	68
5.2.1	Amélioration de la recherche de formes 3D en utilisant l'apprentissage profond	68
5.2.2	Analyse spectrale de formes médicales	69
5.2.3	Tatouage de formes 3D	70
5.2.4	Conception d'autres noyaux spectraux	70
5.2.5	Vers une approche robuste de la segmentation de formes	70
	Bibliographie	81
	Liste des figures	86
	Liste des tableaux	88

LISTE DES ACRONYMES

Pour la plupart des acronymes employés, nous avons utilisé la dénomination la plus courante, qui est de fait en langue anglaise.

3D	Tri-dimensionnel – Three-dimensional
ACP	Analyse en composantes principales – Principal component analysis
AGPS	Signature de point globale avancée – Advanced global point signature
MDS	Mise à l'échelle multi-dimensionnelle – Multi-dimensional scaling
DCG	Gain cumulatif réduit – Discounted cumulative gain
E	E mesure – E-measure
EVD	Descripteur de valeurs propres – Eigenvalue descriptor
FNE	Erreur de faux négatifs – False negative error
FPE	Erreur de faux positifs – False positive error
FT	Premier niveau – First-tier
GPS	Signature de point globale – Global point signature
HKS	Signature du noyau de chaleur – Heat kernel signature
HMS	Signature moyenne de chaleur – Heat mean signature
LB	Laplace-Beltrami
MPSO	Optimisation par essaim de particules modifiée – Modified particle swarm optimization
MSE	Erreur quadratique moyenne – Mean squared error
NN	Voisin le plus proche – Nearest neighbor
OWKS	Signature du noyau d'onde optimisée – Optimized wave kernel signature
P/R	Précision/Rappel – Precision/Recall
PSO	Optimisation par essaim de particules – Particle swarm optimization
SPSO	Optimisation par essaim de particules standard – Standard particle swarm optimization
ST	Deuxième niveau – Second-tier
WKS	Signature du noyau d'onde – Wave kernel signature

INTRODUCTION

L'analyse de formes a suscité l'intérêt de nombreux chercheurs dans les communautés de la vision par ordinateur et de la reconnaissance de formes au cours des dernières années. En effet, les modèles tridimensionnels (3D) deviennent plus utilisés et apparaissent plus souvent dans de nombreux types d'applications. Ces modèles peuvent être acquis de nombreuses façons différentes en utilisant des scanners ou des caméras, cependant ils peuvent être capturés même à partir d'utilisateurs non experts dans ce domaine. Ils peuvent également être créés ou édités par des logiciels de modélisation 3D possédant une faible courbe d'apprentissage. Ceci s'explique par les progrès récents dans l'imagerie et le traitement 3D, le matériel graphique et les réseaux d'internets qui conduisent à un nombre gigantesque de modèles disponibles gratuitement ou commercialement sur Internet.

L'analyse de forme constitue l'examen et la description de la forme des modèles géométriques de sorte que les ordinateurs puissent détecter les similarités entre les objets d'une base de données. La tâche de mesurer efficacement la similarité d'objets 3D pour trouver et rechercher des objets pertinents à partir d'une requête donnée est devenue primordiale dans de nombreuses applications comme par exemple : la recherche de déformations du même objet [1, 2, 3], la recherche d'objets de mêmes catégories [4], trouver des correspondances et faire correspondre des parties des formes [5], la segmentation [6], comprendre les modifications de forme à des fins médicales [7] ou encore la reconnaissance faciale [8, 9]. Le problème est que les formes sont représentées dans l'espace tridimensionnel sans standardisation de taille, d'orientation ou de discrétisation. Par conséquent, le principal défi des algorithmes de recherche et d'appariement d'objets 3D est de calculer un descripteur de forme très robuste (peu variable) qui code correctement la géométrie de la surface et qui capte efficacement les propriétés géométriques et topologiques d'une forme.

La notion de descripteur de caractéristiques est fondamentale dans l'analyse de formes. Un descripteur de caractéristiques, notamment le plus dense, attribue à chaque point de la forme un vecteur dans un espace de caractéristiques multidimensionnel unique représentant les propriétés géométriques locales et globales pertinentes pour une tâche spécifique. Cette information est ensuite utilisée dans des tâches de niveau supérieur : par exemple, les descripteurs de correspondance de formes, d'une part, sont utilisés pour établir un ensemble initial de points potentiellement correspondants [10, 11]; dans la recherche de formes, un descripteur de forme global est construit comme un sac de "mots géométriques" exprimés en termes de descripteurs de caractéristiques locales [12, 13]; les algorithmes de segmentation, de l'autre part, reposent sur la similarité ou la dissemblance de descripteurs de caractéristiques pour partitionner la forme en parties

stables et significatives [14, 15].

Une forme 3D est généralement représentée par un volume ou une surface/un maillage. Les algorithmes de reconnaissance et d'appariement de formes basés sur la comparaison des propriétés de la forme sont compliqués par le fait que de nombreux objets 3D démontrent une variabilité riche, dont l'invariance de différentes classes de transformations et de variations de forme est souvent requise. L'un des critères les plus difficiles est le cas des formes non rigides (ou déformables), dans lequel les formes subissent des changements qui peuvent être approchés par des isométries intrinsèques, c'est-à-dire des déformations qui préservent par exemple les distances géodésiques¹ entre toutes les paires de points. Cette classe de déformations est beaucoup plus riche que les transformations rigides. Récemment, diverses méthodes ont été proposées pour traiter le problème de reconnaissance de forme 3D non rigide, en particulier avec la représentation isométrique invariante. Ces méthodes peuvent être classées en trois catégories principales : structurelles et topologiques, par prise de vues et géométriques qui sont respectivement basées sur la représentation par graphes [16, 17], par silhouettes [18, 19] et par surfaces [20, 21, 22].

Au cours de la dernière décennie, il y a de nombreuses activités de recherche sur la reconnaissance surfaciques, principalement en faveur de deux motivations clés. Premièrement, les modèles 3D basés sur la surface sont plus populaires en raison de leur capacité de représentation efficace et le fait qu'ils nécessitent moins d'espace de stockage. Deuxièmement, les êtres humains apprennent essentiellement à différencier les objets grâce aux caractéristiques de la surface où dans de nombreuses applications de reconnaissance de formes seule la surface présente un intérêt. Un descripteur de formes permet donc de caractériser, de décrire et de reconnaître les objets en tenant compte de ses apparences extérieures. C'est l'outil principal sur lequel s'appuient les méthodes d'appariement et de recherche par forme clef. Par conséquent, dans ce mémoire, nous nous concentrons sur la reconnaissance de forme basée sur la surface avec des descripteurs de sommets locaux. Les efforts de recherche sur l'analyse de forme spectrale ont récemment abouti à de nombreux descripteurs [23, 20, 15, 21, 22, 24, 25], qui sont principalement basés sur l'opérateur de Laplace-Beltrami (LB) [26, 27].

1.1/ DÉFINITION DU PROBLÈME ET MOTIVATION

Traditionnellement, on compare des objets numériques en utilisant une signature, également appelée empreinte digitale (le nom a été utilisé pour la première fois par Reuter *et al.* [28]), ou une représentation qui contient les informations les plus importantes sur la forme. Comme le problème de reconnaissance de forme est particulièrement difficile, il est souhaitable que cette signature soit robuste contre les déformations non-rigides et les transformations rigides. Les signatures de formes traduisent généralement les caractéristiques locales de forme associées à leurs sommets. Elles capturent, généralement, des informations sur le voisinage d'un sommet. Ainsi, elles peuvent être directement utilisées et appliquées dans certaines tâches importantes telles que la correspondance et la segmentation de forme. L'un des plus grands défis dans la reconnaissance et la comparaison de formes non-rigides, est la conception d'un descripteur de formes robuste qui resterait invariant sous une large classe de transformations. Il existe plusieurs façons de résoudre

1. La distance géodésique est la longueur du plus court chemin, soit à l'intérieur de la forme 2D, soit sur la surface de la forme 3D, entre deux points donnés.

le problème de la représentation des propriétés locales des surfaces. Les méthodes les plus connues utilisent différentes variantes de la transformée de caractéristique invariante à l'échelle (SIFT, *Scale Invariant Feature Transform*) [29] ou de l'opérateur LB.

Une autre contrainte, qui vient de la façon dont les données sont enregistrées, est la façon dont les formes sont stockées en mémoire. Les méthodes les plus communes utilisent des nuages de points ou des maillages. Le problème est que les méthodes conçues pour calculer des descripteurs dépendent de la façon dont les formes sont décrites. C'est un problème puisque les nuages de points sont moins informatifs que les maillages quand les deux sont également denses. Pour le calcul de l'opérateur LB, il existe des méthodes pour traiter les deux représentations, bien que les méthodes existantes ne soient que des approximations discrètes de l'opérateur LB continu. Les plus connues sont le schéma cotangent [30] ou le schéma demi-tangent [31] pour les maillages, et le PCD de Laplace (*Point-Cloud Data Laplace*) [32] pour les nuages de points.

D'un autre côté, les descripteurs locaux ne peuvent pas être immédiatement appliqués au problème de la recherche de forme, car cette tâche n'est pas traitée par la comparaison de descripteurs, mais par la comparaison de signatures globales. Dans cette thèse, nous nous référons aux signatures comme représentation de forme globale et aux descripteurs comme représentation de forme locale couplée à des sommets. Créer des signatures n'est pas une tâche simple, car les formes peuvent avoir un nombre arbitraire de sommets, d'arêtes et de facettes. Pour créer une représentation générique idéale d'une forme, toutes les caractéristiques importantes doivent être préservées pendant le processus de codage. Or, pour être réellement efficace, cette représentation doit être de taille inférieure aux données, ce qui implique un nécessaire aspect compressif. Il y a donc un compromis à trouver entre exhaustivité (ou précision) et globalité de la représentation.

Dans notre cas, il est nécessaire de calculer différents descripteurs locaux qui traitent des déformations importantes d'une manière spécifique. Par exemple, pour le problème de recherche de forme non rigide, les descripteurs doivent être invariants lorsque des mouvements articulaires se produisent.

Il est communément admis que les qualités d'un descripteur, pour la reconnaissance et la récupération de forme, sont construites autour d'un compromis entre les cinq critères suivants [33] :

- *Localisation* : Un petit déplacement d'un point sur la variété (ou surface) devrait grandement affecter le descripteur.
- *Sensibilité* : Lorsqu'un point sur une forme est examiné vis à vis une autre forme similaire, un petit ensemble de meilleures correspondances du descripteur doit contenir une correspondance correcte avec une probabilité élevée.
- *Invariance* : Le descripteur doit être invariant ou au moins peu sensible à certaines classes de transformations.
- *Efficacité* : Le descripteur doit capter autant d'informations que possible dans un nombre de dimensions aussi réduit que possible.
- *Puissance de discrimination* : Le descripteur doit être capable de permettre la distinction de formes appartenant à des classes différentes.

Les propriétés de localisation et de sensibilité sont importantes pour les tâches de correspondance, tandis que le descripteur doit avoir la propriété de discrimination pour être utiles dans les tâches de recherche de formes. Par ailleurs, la discrimination est dépendante des données : un descripteur peut être discriminant sur un ensemble d'objets

donné, alors qu'il n'est pas discriminant sur d'autres. Cette contrainte est prise en compte pour garantir la performance de la reconnaissance de formes.

Par conséquent, lors de la construction ou du choix d'un descripteur de caractéristiques, il est impératif de pouvoir se positionner par rapport aux questions fondamentales suivantes :

- Quelles propriétés de la forme le descripteur doit-il capter et à quelles transformations doit-il rester invariant ?
- Quels procédés doit-on mettre en œuvre pour extraire une description unique et robuste de la forme géométrique des objets ?
- Comment peut-on tirer parti de l'existant pour innover et/ou améliorer les méthodes et les représentations ?
- Est-il possible d'obtenir une recherche de formes efficace en utilisant uniquement des composants spectraux ? Si non, quels sont les outils dont nous avons besoin pour augmenter la performance d'appariement de recherche de formes ?

Parmi les méthodes qui permettent de répondre aux questions précédemment posées, l'opérateur LB présente de nombreux atouts. En effet, l'utilisation réussie du spectre (à savoir les valeurs propres et les fonctions propres) de l'opérateur LB dans l'analyse de forme est largement attribuée à leur invariance d'isométrie et à leur robustesse au bruit. Cependant, d'autres propriétés d'invariance sont généralement difficiles à réaliser et encore plus difficiles à modéliser pour des transformations réalistes. L'objectif principal de cette thèse est donc de développer des techniques robustes et efficaces de reconnaissance et de correspondance de formes 3D. Autrement dit, notre contribution consiste à implanter au moins un descripteur original pour analyser, représenter, et ensuite reconnaître et distinguer les formes. Le descripteur est construit à la base de l'analyse spectrale de l'opérateur de LB sur les maillages triangulaires tridimensionnels.

1.2/ ORGANISATION DU DOCUMENT ET CONTRIBUTIONS

Chapitre 1 : Introduction Ce chapitre contient un aperçu général des principales méthodes et catégories dans le domaine de vision par ordinateur pour traiter de problèmes d'appariements et de reconnaissances de formes 3D. Ce chapitre présente également la problématique et la motivation de cette thèse.

Chapitre 2 : Géométrie différentielle et signatures spectrales de formes Ce chapitre contient une brève revue de la littérature et les définitions essentielles auxquelles nous nous référons. Étant donné que certains descripteurs sont utilisés pour développer nos contributions, ainsi que certaines autres méthodes existantes utilisées dans les comparaisons, utilisent la géométrie de diffusion et la théorie spectrale des graphes, un aperçu sur la théorie spectrale des graphes et ses concepts est présenté dans ce chapitre. Nous présentons une revue et une analyse de descripteurs de formes spectraux récents. Plus spécifiquement, nous révisons les derniers descripteurs spectraux basés sur l'opérateur de Laplace-Beltrami, y compris shapeDNA, la signature de point globale, la signature du noyau de chaleur, la signature de chaleur moyenne, le descripteur de distribution de température et la signature du noyau d'onde.

Chapitre 3 : Signature de point globale avancée (AGPS) Un premier objectif consiste à rechercher un descripteur de formes construit à partir du spectre de l'opérateur de Laplace-Beltrami. Nous présentons une signature de point globale avancée AGPS (*Advanced Global Point Signature*) pour la reconnaissance et la recherche de formes 3D [34]. Le descripteur AGPS permet de capter à la fois la géométrie globale et locale de l'objet. En effet, les caractéristiques locales de formes sont obtenues et évaluées en utilisant un algorithme de détection de points d'intérêt basés sur leurs valeurs AGPS, puis seront projetées dans un plan 2D afin d'être classées. Le descripteur AGPS décrit les objets 3D sous forme de distributions de valeurs calculées en chaque sommet de l'objet. L'ensemble de valeurs calculées sur chaque point du maillage permet d'avoir une distribution pour décrire efficacement la géométrie globale de la forme entière. Des résultats expérimentaux étendus, qui sont menées sur trois bases de données de formes 3D non rigides, illustrent la performance de l'algorithme proposé par rapport aux méthodes existantes.

Chapitre 4 : Signature du noyau d'onde optimisée (OWKS) S'il existe désormais des travaux sur la définition de stratégies de correspondance et de recouvrement pour les objets, moins d'études se sont concentrées sur le perfectionnement de descripteurs basés sur la méthode d'analyse spectrale. Généralement, la performance de descripteurs standards est considérée faible lors de son évaluation, sous des formes définies à l'aide d'un modèle numérique personnel ou des benchmarks téléchargeables, par rapport aux descripteurs récents ou améliorés. Pour cette raison, nous présentons un descripteur du noyau d'onde optimisé OWKS (*Optimized Wave Kernel Signature*) pour l'appariement et la recherche de formes 3D déformables [35, 36]. Notre cadre OWKS proposé invoque une méthode heuristique d'optimisation par essaim de particules modifié (MPSO) dans la construction de la signature du noyau d'onde dont la finalité est de capter plus d'informations géométriques et, par conséquent, d'améliorer sa capacité discriminative. Ensuite, afin d'obtenir une meilleure précision d'appariement et de récupération d'objets 3D, la sélection du premier vecteur de l'OWKS construit à sa première échelle d'énergie est une étape primordiale. En outre, le choix spécial de ce vecteur est de renforcer fortement la stabilité de la méthode d'extraction des points saillants des maillages 3D. Finalement, des résultats expérimentaux sur une base de données standard montrent la supériorité du cadre OWKS proposé par rapport aux autres méthodes de l'état de l'art.

Chapitre 5 : Conclusions et travaux futurs Ce dernier chapitre est présenté sous forme de discussion résumant les principales contributions de cette thèse et propose quelques perspectives pour les travaux futurs.

1.3/ PUBLICATIONS DE L'AUTEUR

Les travaux effectués dans le cadre de cette thèse ont donné lieu à de plusieurs publications :

Revue internationale :

1. Seif Eddine NAFFOUTI, Yohan FOUGEROLLE, Ichraf AOUISSAOUI, Anis SAKLY, Fabrice MERIAUDEAU, "Heuristic optimization-based wave kernel descriptor for deformable 3D shape matching and retrieval", *Signal, Image and Video Processing* 12 (2018), 915–923.
2. Seif Eddine NAFFOUTI, Yohan FOUGEROLLE, Anis SAKLY, Fabrice MERIAUDEAU, "An advanced global point signature for 3D shape recognition and retrieval", *Signal Processing : Image Communication* 58 (2017), 228–239.

Conférences internationales :

1. Seif Eddine NAFFOUTI, Ichraf AOUISSAOUI, Yohan FOUGEROLLE, Anis SAKLY, Fabrice MERIAUDEAU, "Enhancement and assessment of WKS variance parameter for intelligent 3D shape recognition and matching based on MPSO", *2016 4th International Conference on Control Engineering & Information Technology (CEIT)* (2016), IEEE, pp. 1–6.
2. Seif Eddine NAFFOUTI, Yohan FOUGEROLLE, Anis SAKLY, Fabrice MERIAUDEAU, "A more distinctive representation for 3D shape descriptors using principal component analysis", *2015 16th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)* (2015), IEEE, pp. 410–416.

GÉOMÉTRIE ET SIGNATURES SPECTRALES DE FORMES

2.1/ INTRODUCTION

Dans la littérature, de nombreux travaux s'intéressent à la théorie spectrale des graphes. Les premiers travaux de recherche ont porté sur des matrices telles que la matrice d'adjacence, la matrice Laplacienne ou la matrice Laplacienne normalisée des graphes associés [37, 38, 39]. Ces travaux ont été menés, en particulier, sur les valeurs et les vecteurs propres des matrices Laplacienne du graphe [40, 41]. Ainsi, d'autres travaux et efforts significatifs ont permis une meilleure compréhension et utilisation des parcours aléatoires sur les graphes et l'analyse spectrale des matrices Laplaciennes [27, 42]. La description globale ne considère que les caractéristiques de forme entières d'un modèle 3D, et les premiers travaux représentatifs comprennent la distribution de distance euclidienne [43] et le descripteur d'harmoniques sphériques [44]. Il convient de souligner que les harmoniques sphériques ne sont rien d'autre que les fonctions propres de l'opérateur Laplace-Beltrami (LB) sur la sphère.

La récente vague d'intérêt pour l'analyse spectrale de l'opérateur LB a abouti à un nombre considérable de signatures de formes spectrales qui ont été appliquées avec succès à un large éventail de domaines, notamment l'apprentissage multiple [45], la reconnaissance d'objets et l'analyse de formes déformables [13, 23, 24, 46, 47, 48], l'imagerie médicale [49], la protection de multimédia [50] et la classification de formes [51]. La nature diversifiée de ces applications est un puissant témoignage de l'utilisation pratique des signatures de formes spectrales, qui sont généralement définies comme des vecteurs représentant les caractéristiques locales et/ou globales de la forme. Des descripteurs locaux (également appelés signatures de points) sont définis sur chaque point de la forme et représentent souvent la structure locale de la forme autour de ce point, tandis que les descripteurs globaux sont généralement définis sur la forme entière.

De nombreux exemples de descripteurs de formes locaux permettent de décrire localement les objets. Rustamov [23] a proposé un descripteur de caractéristique locale appelé signature de point globale GPS (*Global Point Signature*), qui est un vecteur dont les composantes sont des fonctions propres mises à l'échelle de l'opérateur LB évaluées à chaque point de la surface. La signature GPS est invariante sous des déformations isométriques de la forme, mais elle souffre du problème de la commutation des fonctions propres lorsque les valeurs propres associées sont proches les unes des autres. Ce problème a été récemment traité par la signature du noyau de chaleur HKS (*Heat Kernel*

Signature) [20], qui est un descripteur temporel défini comme une combinaison pondérée exponentiellement des fonctions propres de l'opérateur LB. HKS est un descripteur de forme local qui possède plusieurs propriétés souhaitables, notamment la robustesse aux petites perturbations de la forme, l'efficacité et l'invariance face aux transformations isométriques. La signature HKS a été aussi proposée indépendamment par Gėbal *et al.* [52] pour la squelettisation et la segmentation de formes 3D sous le nom de fonction de diffusion automatique ADF (*Auto Diffusion Function*). L'analyse de Fourier montre que HKS est fortement dominée par l'information des basses fréquences, qui correspondent aux propriétés macroscopiques d'une forme. Pour donner lieu à un appariement sensiblement plus précis que HKS, la signature du noyau d'onde WKS (*Wave Kernel Signature*) [21] a été proposée comme alternative pour permettre l'accès à l'information de haute fréquence. Fang *et al.* [15] ont introduit la signature de chaleur moyenne HMS (*Heat Mean Signature*). La HMS suit le principe similaire de la signature de noyau de chaleur, mais interprète les caractéristiques cachées de la structure de maillage d'une manière différente. Les auteurs adoptent une approche basée sur la physique en utilisant une analogie de transfert de chaleur. Par la suite, ils ont défini un descripteur de distribution de température TD (*Temperature Distribution*) [53], basé sur l'évaluation de la distribution de la température après l'application d'une unité de chaleur en chaque sommet de la surface.

D'un autre côté, de nombreux descripteurs globaux peuvent être construits à partir de signatures de points en intégrant la totalité de la forme. L'une des signatures de formes spectrales les plus simples est ShapeDNA [24], qui est un descripteur global invariant à l'isométrie défini comme une séquence tronquée des valeurs propres de l'opérateur LB disposées dans un ordre croissant. Gao *et al.* [51] ont développé une variante de ShapeDNA, appelée ShapeDNA compact (*cShapeDNA*), qui est une signature isométrique invariante résultant de l'application de la transformée de Fourier discrète aux valeurs propres normalisées de l'opérateur LB. Chaudhari *et al.* [49] ont présenté une version légèrement modifiée de la signature GPS en réglant les fonctions propres de l'opérateur LB sur l'unité. Cette signature, appelée plongement GPS (*GPS embedding*), est définie comme une séquence tronquée de racines carrées inverses des valeurs propres normalisées de surface de l'opérateur LB. Une liste complète des descripteurs spectraux globaux peut être trouvée dans [54, 55].

2.2/ GÉOMÉTRIE DIFFÉRENTIELLE ET SPECTRALE DE FORMES

La géométrie spectrale est une branche de la géométrie différentielle et de la théorie spectrale de l'opérateur de Laplace-Beltrami (LB) sur une variété Riemannienne compacte. Plus précisément, il consiste à établir des relations entre le spectre des valeurs propres de l'opérateur LB et la structure géométrique de cette variété.

2.2.1/ MAILLAGE TRIANGULAIRE : NOTATIONS

Une forme 3D est habituellement modélisée sous la forme d'un maillage triangulaire \mathcal{M} dont les n sommets sont échantillonnés à partir d'une variété Riemannienne. Un maillage triangulaire \mathcal{M} peut être défini comme un graphe $\mathcal{G} = (\mathcal{S}, \mathcal{E}, \mathcal{T})$, où $\mathcal{S} = \{s_1, \dots, s_n\}$ est l'ensemble des sommets, $\mathcal{E} = \{e_{ij}\}$ est l'ensemble des arêtes, et $\mathcal{T} = \{t_1, \dots, t_n\}$ est l'ensemble des triangles (ou facettes), tels que représentés dans la vue agrandie de

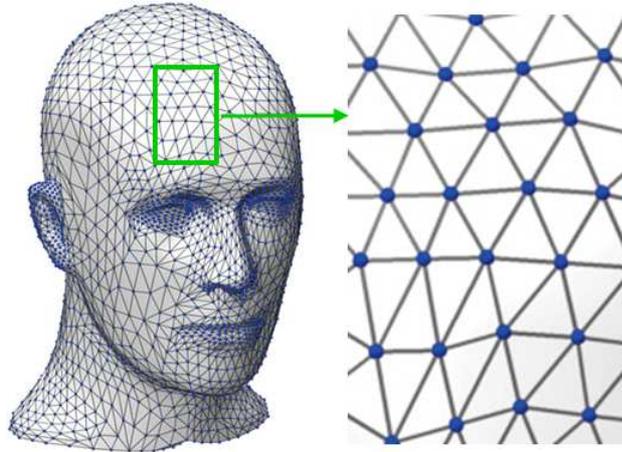


FIGURE 2.1 – Représentation d'un maillage triangulaire.

la Figure 2.1. Chaque sommet $s_i \in \mathcal{M}$ est représenté de manière conventionnelle en utilisant les coordonnées cartésiennes absolues telles que $s_i = (x_i, y_i, z_i)$. Ainsi, chaque arête $e_{ij} = [s_i, s_j]$ connecte une paire de sommets $\{s_i, s_j\}$. Deux sommets distincts $s_i, s_j \in \mathcal{S}$ sont adjacents (désigné par $s_i \sim s_j$ ou simplement $i \sim j$) si ils sont connectés par une arête, c'est-à-dire $e_{ij} \in \mathcal{E}$. A chaque arête $[s_i, s_j] \in \mathcal{E}$ est associé un poids, ou coût $\omega(s_i, s_j) = \omega(s_j, s_i)$. Le coût entre deux sommets non reliés est égal à zéro.

Dans tous les chapitres qui suivent, les vecteurs sont désignés par des lettres minuscules en gras (par exemple ϕ), et les matrices sont indiquées par des lettres majuscules (par exemple L). L'intersection entre le i ème et le j ème élément dans une matrice L est une valeur notée comme L_{ij} .

2.2.2/ OPÉRATEUR DE LAPLACE SUR UNE SURFACE

Dans cette section, nous présentons la définition de l'opérateur de Laplace-Beltrami et mentionnons certaines de ses propriétés.

2.2.2.1/ OPÉRATEUR DE LAPLACE-BELTRAMI

L'opérateur de Laplace-Beltrami est une extension de l'opérateur de Laplace sur une variété de Riemann (voir [56] pour plus de détails).

Soit f une fonction réelle deux fois différentiable et définie sur une variété Riemannienne \mathcal{M} telle que $f \in C^2, f : \mathcal{M} \rightarrow \mathbb{R}$, l'opérateur de Laplace-Beltrami (LB) est défini comme :

$$\Delta_{\mathcal{M}} f := \operatorname{div}(\nabla_{\mathcal{M}} f), \quad (2.1)$$

où $\nabla_{\mathcal{M}} f$ est le gradient de f et div est la divergence d'un champs de vecteur sur une variété. La divergence est un opérateur qui mesure la magnitude de la source d'un champ de vecteurs à un point donné. En d'autres termes, le Laplacien est le vecteur de variation qui sert à identifier les formes tridimensionnelles en particulierisant l'irrégularité locale

d'une fonction ; autrement dit, il mesure la différence entre la valeur de la fonction en un point et sa moyenne autour de ce point. L'opérateur LB est un opérateur différentiel linéaire et peut être calculé en utilisant une paramétrisation locale, c'est-à-dire, le plan tangent. Compte tenu du tenseur métrique g de \mathcal{M} , l'opérateur LB sur \mathcal{M} s'écrit comme :

$$\Delta_{\mathcal{M}}f = \frac{1}{\sqrt{\|g\|}} \sum_{i,j} \partial_i (g_{ij}^{-1} \sqrt{\|g\|} \partial_j f), \quad (2.2)$$

où $\|g\|$ est le déterminant de g , ∂_i et ∂_j sont les vecteurs de base du plan tangent. Dans le cas où $\mathcal{M} \subset \mathbb{R}^2$, le tenseur métrique g correspond à l'identité et l'opérateur LB réduit à l'opérateur Laplacien dans \mathbb{R} est :

$$\Delta f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}. \quad (2.3)$$

Le spectre du Laplacien est l'ensemble des fonctions propres et des valeurs propres associées qui résolvent l'équation de Helmholtz :

$$\Delta_{\mathcal{M}}\phi = \lambda\phi, \quad (2.4)$$

où λ sont appelées valeurs propres de $\Delta_{\mathcal{M}}$; les solutions ϕ sont appelées fonctions propres de $\Delta_{\mathcal{M}}$ associées aux scalaires λ . Pour chaque valeur propre λ_i correspond une fonction propre normalisée ϕ_i . Dans le cas d'une surface fermée sans bord, la première valeur propre λ_0 est toujours égale à zéro et la fonction propre associée ϕ_0 est une fonction constante sur toute la surface.

2.2.2.2/ PROPRIÉTÉS DE L'OPÉRATEUR DE LAPLACE-BELTRAMI

Quelques propriétés de l'opérateur de Laplace-Beltrami sont mentionnées dans [24]. Citons, sans être exhaustif :

- Son spectre dépend uniquement du tenseur métrique et est invariant sous les mappings isométriques.
- Le spectre de l'opérateur de Laplace-Beltrami des variétés de dimension d à différentes échelles peut être comparé en normalisant les valeurs propres de manière appropriée.
- Un changement continu de la forme de la surface entraîne un changement continu du spectre.
- Le spectre ne caractérise pas complètement la forme, car il existe certaines variétés non isométriques avec le même spectre. Néanmoins, ces cas semblent être très rares.
- Une quantité importante d'informations géométriques et topologiques doit être connue pour être contenue dans le spectre. En raison de la forte dimensionnalité du spectre propre, le recadrage du spectre est inévitable et induit, par conséquent, une perte d'information. Néanmoins, les premières valeurs propres contiennent des informations importantes. A titre indicatif, la première fonction propre ϕ_1 permet de fournir un ordre naturel pour ordonner les sommets d'un maillage. La section 2.3.2 donne plus de détails sur cet aspect.
- Les racines carrées des valeurs propres $\sqrt{\lambda_i}$ peuvent être considérées comme les fréquences propres d'une membrane (d'une surface), tandis que les fonctions propres $\phi_i(s)$ sont les amplitudes correspondantes au point s .

2.3/ REPRÉSENTATION DIFFÉRENTIELLE D'UNE SURFACE

Dans cette section, nous introduisons brièvement la définition des coordonnées différentielles (coordonnées δ), les poids (coûts) d'arêtes d'un maillage triangulaire et la matrice Laplacienne discrète associée.

2.3.1/ DISCRÉTISATION DE L'OPÉRATEUR DE LAPLACE-BELTRAMI

Il est parfois difficile d'effectuer des opérations sur les maillages en utilisant les coordonnées cartésiennes pour décrire la géométrie de la surface. Dans certains cas, il est indispensable de garder une trace sur la structure des sommets du maillage, lorsque certaines transformations (par exemple des déformations) sont effectuées sur le maillage.

En effet, nous utilisons les coordonnées différentielles [57] (δ -*coordinates*) qui représentent une alternative aux coordonnées cartésiennes pour représenter la géométrie du maillage, et stocker la structure de ce dernier.

Le différentiel ou les coordonnées δ d'un sommet s_i est défini comme étant la différence entre les coordonnées cartésiennes de s_i et les coordonnées du centre de gravité de ses voisins dans le maillage.

$$\delta_i = (\delta_i^{(x)}, \delta_i^{(y)}, \delta_i^{(z)}) = s_i - \frac{1}{d_i} \sum_{j \in N(i)} s_j,$$

où $N(i) = \{j \mid (i, j) \in \mathcal{E}\}$ et $d_i = |N(i)|$ est le nombre de voisins (le degré ou valence du point s_i).

La transformation du vecteur de coordonnées cartésiennes absolues en vecteur de coordonnées δ peut être représentée sous forme matricielle. La matrice d'adjacence (connectivité) A du graphe \mathcal{G} , non orienté, est une matrice symétrique de taille $n \times n$, telle que :

$$A_{ij} = \begin{cases} 1 & \text{si } (i, j) \in \mathcal{E} \\ 0 & \text{sinon} \end{cases}$$

La matrice des degrés $D_{ii} = d_i$ est une matrice diagonale, dont les éléments de la diagonale sont les degrés $\deg(s_i)$ de chaque sommet s_i dans le graphe.

$$D_{ij} = \begin{cases} \deg(s_i) & \text{si } i = j \\ 0 & \text{sinon} \end{cases}$$

Ensuite, la matrice transformant les coordonnées absolues en coordonnées relatives est $L = I - D^{-1}A$. Il est souvent plus commode de considérer la version symétrique de la matrice L , définie par $L_s = DL = D - A$ dont sa représentation matricielle est :

$$(L_s)_{ij} = \begin{cases} d_i & \text{si } i = j \\ -1 & \text{si } (i, j) \in \mathcal{E} \\ 0 & \text{sinon} \end{cases}$$

D'un point de vue de géométrie différentielle, les coordonnées δ peuvent être considérées comme étant une discrétisation de la version continue de l'opérateur LB, si nous

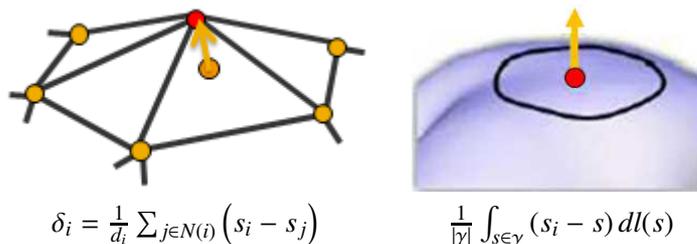


FIGURE 2.2 – Le vecteur de coordonnées différentielles au niveau d'un sommet se rapproche de : la direction normale et la courbure moyenne [57].

supposons que le maillage \mathcal{M} est une approximation linéaire par morceaux d'une surface. Nous pouvons écrire le vecteur de la coordonnée différentielle pour un sommet s_i comme :

$$\delta_i = \frac{1}{d_i} \sum_{j \in N(i)} (s_i - s_j). \quad (2.5)$$

La somme mentionnée dans l'équation (2.5), est une discrétisation de l'intégrale curviligne suivante : $\frac{1}{|\gamma|} \int_{s \in \gamma} (s_i - s) dl(s)$, où γ est une courbe de surface simple et fermée autour de s , et $|\gamma|$ est la longueur de γ .

La direction du vecteur de coordonnées différentielles se rapproche de la direction normale locale et l'amplitude se rapproche d'une quantité proportionnelle à la courbure moyenne locale [58] (la normale mise à l'échelle par la courbure moyenne est appelée la normale à la courbure moyenne). Intuitivement, cela signifie que les coordonnées δ encapsulent la forme de la surface locale (voir la Figure 2.2).

La discrétisation de l'opérateur de Laplace-Beltrami dépend de la modélisation géométrique de la forme. Plusieurs discrétisations de l'opérateur LB sont disponibles dans la littérature [24, 59, 60, 61, 30]. A titre d'exemple pour les formes représentées comme des nuages de points, l'opérateur de Laplace-Beltrami peut être approximé en utilisant [32]. Pour les surfaces maillées, on peut appliquer les méthodes proposées dans [24, 60, 30]. Nous utilisons l'approche développée dans [31], puisque cette dernière discrétisation géométrique se rapproche davantage de l'opérateur de Laplace-Beltrami continu [57]. Par conséquent, la valeur de $\Delta_{\mathcal{M}} f$ en un sommet s_i peut être approximée en utilisant le poids de pondération demi-tangent (ou poids convexe) comme suit :

$$\Delta_{\mathcal{M}} f(s_i) \approx \frac{1}{|\Omega_i|} \sum_{j \in N(i)} \frac{\tan(\theta_{ij}^1/2) + \tan(\theta_{ij}^2/2)}{\|s_i - s_j\|} [f(s_i) - f(s_j)], \quad (2.6)$$

où θ_{ij}^1 et θ_{ij}^2 sont les angles $\angle(s_j, s_i, s_k)$ et $\angle(s_j, s_i, s_l)$ de deux facettes $t^{\theta^1} = (s_i, s_j, s_k)$ et $t^{\theta^2} = (s_i, s_j, s_l)$ qui sont adjacents à l'arête $[i, j]$, et $|\Omega_i|$ est la région de la cellule de Voronoï (la région contourée par une ligne bleue) autour du sommet i , comme le montre la Figure 2.3.

Contrairement aux poids cotangents qui peuvent être négatifs et problématiques à définir pour des angles proches de π [57], il convient de souligner que le schéma de poids demi-tangent est numériquement cohérent et préserve plusieurs propriétés importantes de l'opérateur LB continu, y compris la symétrie et la définition positive.

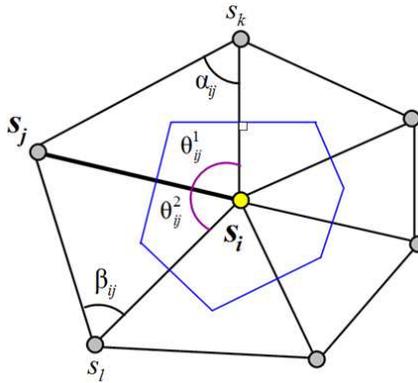


FIGURE 2.3 – Illustration des angles cotangents (α_{ij} et β_{ij}) et demi-tangents (θ_{ij}^1 et θ_{ij}^2), région de Voronoï Ω_i du sommet s_i .

La fonction du poids demi-tangent (aussi appelé coordonnées de valeur moyenne) $\omega : \mathcal{S} \times \mathcal{S} \rightarrow \mathbb{R}$ est définie telle que :

$$\omega_{ij} = \begin{cases} \frac{\tan(\theta_{ij}^1/2) + \tan(\theta_{ij}^2/2)}{\|s_i - s_j\|} & \text{si } i \sim j \\ 0 & \text{sinon} \end{cases} \quad (2.7)$$

Ensuite, pour une fonction $f : \mathcal{S} \rightarrow \mathbb{R}$ qui attribue à chaque sommet $s_i \in \mathcal{S}$ une valeur réelle $f(s_i)$ (nous pouvons voir f comme un vecteur colonne de longueur n), nous pouvons écrire l'opérateur LB donné par l'équation (2.6) comme :

$$Lf(s_i) = \sum_{j \in N(i)} \omega_{ij} (f(s_i) - f(s_j)), \quad (2.8)$$

dont la matrice Laplacienne L est une matrice creuse de taille $n \times n$ et donnée par :

$$L_{ij} = \begin{cases} d_i/|\Omega_i| & \text{si } i = j \\ -\omega_{ij}/|\Omega_i| & \text{si } (i, j) \in \mathcal{E} \\ 0 & \text{sinon} \end{cases} \quad (2.9)$$

et $d_i = \sum_{j=1}^n \omega_{ij}$ est le degré pondéré du sommet s_i . La Figure 2.4 montre un modèle d'éléphant et sa matrice Laplacienne associée en utilisant le poids de pondération demi-tangent. Rappelons que le schéma de la représentation matricielle $L = (L_{ij})$ est l'ensemble des indices ij avec $L_{ij} \neq 0$.

2.3.2/ ANALYSE SPECTRALE

Des progrès récents dans la discrétisation du spectre propre du Laplacien apportent des outils de calculs numériques efficaces et robustes. Pour l'analyse de forme, certains chercheurs modélisent la surface comme une membrane vibrante homogène basée sur la théorie spectrale [23, 49, 62], et son comportement harmonique est donc régi par l'équation de Helmholtz [63] présentée auparavant dans l'équation (2.4). Les méthodes spectrales [64] sont des méthodes puissantes utilisées pour la résolution d'équations différentielles. Elles ont donc une importance cruciale pour la représentation des formes, grâce à leur invariance de pose induite par les propriétés de l'opérateur de Laplace-Beltrami.

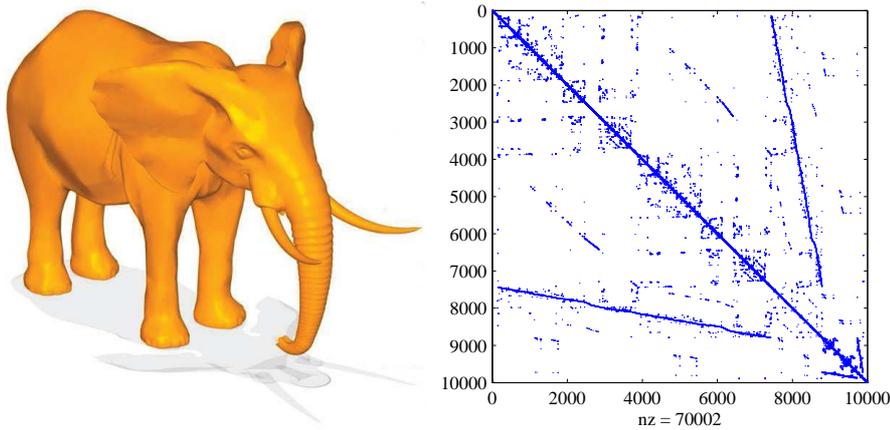


FIGURE 2.4 – Un modèle d'Éléphant et sa matrice Laplacienne creuse associée en utilisant le poids demi-tangent. Les éléments non nuls de la matrice sont représentés en bleu.

Le spectre propre, d'autre part, permet de décrire la forme à travers des représentations spectrales. Cette représentation fournit une nouvelle façon de mesurer quantitativement les différences de surface, puis d'effectuer une analyse détaillée de la forme.

La décomposition spectrale des graphes est une branche de la théorie algébrique des graphes. Elle s'intéresse à l'étude des valeurs propres et des vecteurs propres des matrices associées aux graphes.

Une matrice symétrique L , définie semi-positive, est décomposable et peut être exprimée en terme de ses valeurs propres λ , et de leurs fonctions propres ϕ correspondantes (c'est-à-dire, vecteurs propres qui peuvent être considérés comme des fonctions sur les sommets du maillage), tels que :

$$L\phi = \lambda\phi \quad (2.10)$$

Pour calculer les valeurs propres λ_i et les vecteurs propres ϕ_i nous considérons le système d'équations $L_i\phi_i = \lambda_i\phi_i$, qui peut être résolu efficacement en utilisant la méthode Arnoldi de ARPACK¹.

Étant donnée Φ une matrice dont les colonnes contiennent les vecteurs propres ϕ_i , et Λ une matrice diagonale dont les éléments diagonaux sont les valeurs propres λ_i , l'équation (2.10) peut être écrite comme suit :

$$L\Phi = \Phi\Lambda \quad (2.11)$$

En utilisant les valeurs et les vecteurs propres de la matrice L , et en multipliant à droite par Φ^T , la matrice Laplacienne peut être reconstruite comme suit :

$$L = L\Phi\Phi^T = \Phi\Lambda\Phi^T = \sum_{k=0}^{\infty} \lambda_k \phi_{ik} \phi_{ik}^T \quad (2.12)$$

où $i = \{1, 2, \dots, n\}$ représente les indices des sommets et ϕ_{ik} la valeur d'une fonction propre ϕ_k à l'indice i .

1. ARPACK (ARnoldi PACKage) est une bibliothèque MATLAB pour le calcul des valeurs propres et des vecteurs propres des grandes matrices.



FIGURE 2.5 – Visualisation des quatre premières fonctions propres (non triviales) de l'opérateur LB. De gauche à droite : un modèle de grenouille 3D codé en couleur par les valeurs des première, deuxième, troisième et quatrième fonctions propres.

Les valeurs propres sont des valeurs réelles positives et triées par ordre croissant telles que : $\lambda_0 = 0 < \lambda_1 < \lambda_2 < \dots < \lambda_{n-1}$. Les fonction propres $\Phi_n = \{\phi_0, \phi_1, \phi_2, \dots, \phi_{n-1}\}$ forment une base orthogonale dans \mathbb{R}^n , c'est-à-dire, $\langle \phi_i, \phi_j \rangle = 0$. Chaque vecteur propre est un tableau de n éléments, dont les éléments représentent les valeurs d'une fonction propre en tous les sommets du graphe : $\phi_k = (\phi_k(s_1), \phi_k(s_2), \dots, \phi_k(s_n))$.

Les vecteurs et les valeurs propres d'un graphe sont utilisés pour trouver une représentation compacte, permettant de passer d'un espace de grande dimension (graphe $n \times n$) à un espace réduit. Ce plongement donne une visualisation des données dans un espace non euclidien (un vecteur de taille n). Pour des formes 3D, représentées sous forme de graphes, cette valeur est représentée sous formes de carte de couleurs, représentant les valeurs du vecteur propre en chaque sommet du graphe. Une couleur est associée à chaque sommet selon la valeur du vecteur propre en ce sommet. Les couleurs des régions bleues et rouges indiquent, respectivement, des valeurs minimales et des valeurs maximales des fonctions propres. La Figure 2.5 montre un exemple de cartes de couleurs utilisant les différents vecteurs propres ϕ_i de la matrice Laplacienne L du graphe correspondant au modèle.

L'utilisation des valeurs propres et des fonctions propres de l'opérateur LB dans l'analyse de forme est largement due à leur invariance à l'isométrie et à leur robustesse au bruit. De plus, les premières valeurs propres et fonctions propres, puisque traduisant les basses fréquences du maillage, permettent une reconstruction approximative de la forme générale de l'objet. Comme le montre la Figure 2.5, les fonctions propres (non triviales) de l'opérateur LB codent des informations importantes sur la géométrie globale intrinsèque d'une forme. Notons que les fonctions propres associées à des valeurs propres plus grandes oscillent plus rapidement. Cette représentation permet de comprendre la géométrie des surfaces, et la façon dont les sommets sont reliés entre eux. La première valeur propre non-nulle λ_1 (en anglais appelée *Fiedler value*) donne une indication sur la connectivité algébrique du graphe et correspond au nombre de composantes connexes du graphe. Quand au vecteur propre correspondant à cette valeur propre (également appelé vecteur de Fiedler), il permet de donner un ordre aux sommets dans le graphe selon l'axe de l'objet. La Figure 2.6 montre l'allure de la première fonction propre. Nous pouvons remarquer que cette fonction propre définit une paramétrisation naturelle de l'objet, qui suit sa forme principale. D'une certaine manière, ceci définit une "analyse en composantes principales curviligne", qui parvient à capturer la forme générale de l'objet.

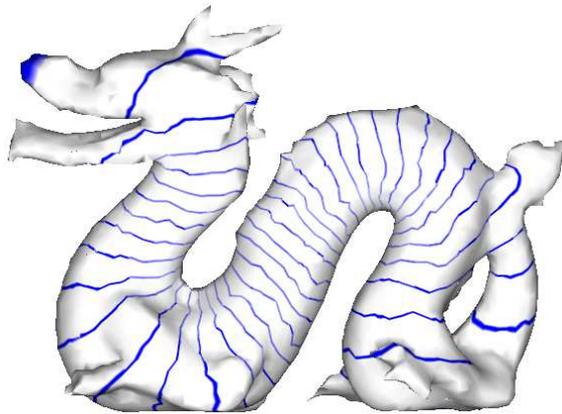


FIGURE 2.6 – Le vecteur de Fiedler fournit un ordre naturel pour ordonner les sommets d'un maillage. Les lignes bleues correspondent aux iso-valeurs de la première fonction propre. Nous montrons ici comment l'ordre induit par le tri des sommets par valeurs croissantes suit naturellement la forme de l'objet, même si elle n'est pas rectiligne.

2.4/ SIGNATURES SPECTRALES DE FORMES

Afin de déterminer la ressemblance ou la similarité entre des objets, il est d'abord primordial de trouver une représentation simplifiée permettant de caractériser ces objets. Cette représentation, appelée descripteur de formes, permet d'extraire des éléments caractéristiques à partir de l'objet. Ces caractéristiques sont facilement mesurables et utilisables pour calculer la similarité entre plusieurs objets. Elles peuvent être des primitives géométriques simples telles que le volume de l'objet, sa surface, les courbures aux différents points de la surface de l'objet, la distribution des distances entre les points de la surface, etc.

Dans la littérature, nous pouvons distinguer trois grandes familles de descripteurs de formes 3D : les descripteurs structurels et topologiques [53, 65], les descripteurs géométriques [66, 67] et les descripteurs par prise de vues [18, 19] comme l'illustre plus en détail la Figure 2.7.

Plusieurs descripteurs spectraux sont développés pour capter les caractéristiques locales et sont plus stables pour la mesure de la densité du voisinage local, tandis que d'autres descripteurs sont généralement développés sur la forme et sont définis pour capter la densité de voisinage globale. De plus, la plupart des signatures de points peuvent facilement être agrégées pour former des descripteurs globaux en intégrant sur toute la surface de la forme.

Ces dernières années, plusieurs descripteurs globaux et locaux basés sur les valeurs propres et les fonctions propres de l'opérateur LB ont été proposés dans la littérature, notamment ShapeDNA [24], la signature de point globale (GPS) [23], la signature du noyau de chaleur (HKS) [20], la signature de chaleur moyenne (HMS) [15], le descripteur de distribution de température (TD) [53] et la signature du noyau d'onde (WKS) [21]. En effet, nous avons utilisé des méthodes standards très connues ; nous les avons toutes implantées pour établir des comparaisons qualitatives et quantitatives, positionner objectivement nos approches et ainsi pour décrire les contributions des chapitres à venir.

2.4.1/ SHAPEDNA

Les descripteurs de formes globaux sont plus populaires pour la tâche de récupération de forme, où de tels descripteurs peuvent être utilisés pour la description complète de la forme. L'un des premiers descripteurs de forme spectrale est ShapeDNA [24]. En effet, ce descripteur est une séquence normalisée des premières valeurs propres de l'opérateur LB. Ses principaux avantages sont la simplicité de sa représentation (un vecteur de nombres) et l'invariance d'échelle. Malgré sa simplicité, ShapeDNA montre une meilleure performance dans la recherche de formes non rigides. Cependant, comme les valeurs propres représentent un descripteur global, ShapeDNA ne peut pas être utilisé pour l'analyse de forme locale ou partielle. Par ailleurs, une extension récente de cette méthode a été proposée dans [69], où un nouveau descripteur global est calculé en utilisant la double décomposition Laplacienne pour la mise en correspondance des formes. Le descripteur de valeurs propres (EVD) [70] est aussi une séquence des valeurs propres mais d'une matrice de distance géodésique. ShapeDNA et EVD peuvent, tous les deux, être normalisés par la deuxième valeur propre.

2.4.2/ SIGNATURE DE POINT GLOBALE

La signature de point globale (GPS) [23] en un point de surface est un vecteur de fonctions propres mises à l'échelle de l'opérateur LB. Cette signature est basée sur la structure globale des objets. Elle est capable de capter des informations substantielles de différentes formes et permet d'effectuer des opérations de classification, de segmentation et de regroupement sur différents ensembles de données. La GPS est une caractéristique globale dans le sens où elle ne peut pas être utilisée pour l'appariement de formes partielles. La signature GPS en un sommet s est un vecteur de valeurs de dimension infinie définie en termes de valeurs et de vecteurs propres de la matrice Laplacienne du graphe représentant le modèle, telle que :

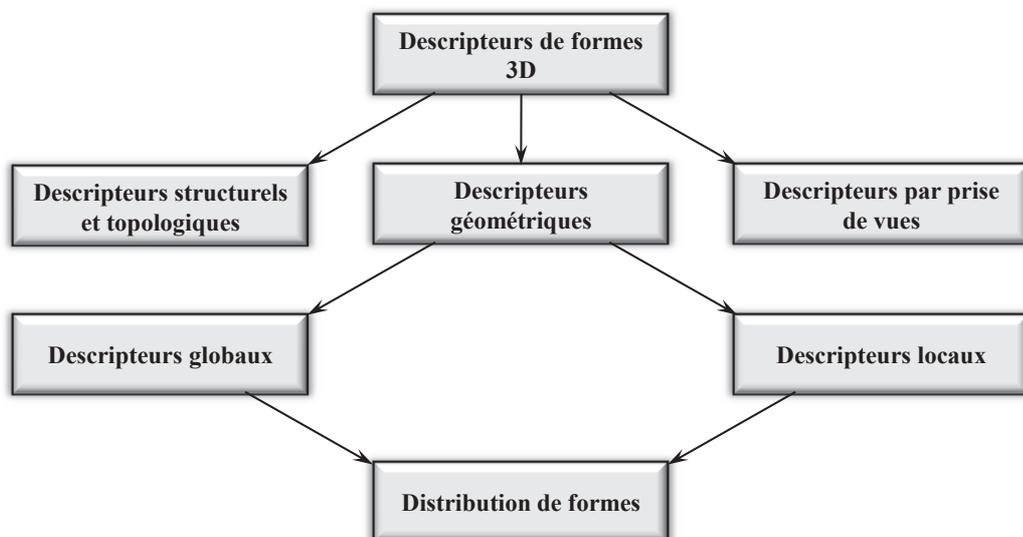


FIGURE 2.7 – Types de descripteurs de formes 3D [68].

$$\text{GPS}(s) = \left(\frac{\phi_1(s)}{\sqrt{\lambda_1}}, \frac{\phi_2(s)}{\sqrt{\lambda_2}}, \dots, \frac{\phi_i(s)}{\sqrt{\lambda_i}}, \dots, \frac{\phi_n(s)}{\sqrt{\lambda_n}} \right). \quad (2.13)$$

La signature GPS a de nombreuses propriétés : elle est invariante sous les déformations isométriques de la forme, plus robuste pour les changements topologiques et a un bon pouvoir de discrimination entre les objets. Toutefois, elle souffre du problème de la commutation des fonctions propres lorsque les valeurs propres associées sont proches les unes des autres. Elle est aussi incapable de traiter des maillages dégénérés [23, 55].

2.4.3/ SIGNATURE DU NOYAU DE CHALEUR

La géométrie de diffusion, plus particulièrement, dans le domaine de la reconnaissance et de la classification de formes, est devenue un outil très important et souvent utilisé. Elle est liée à un processus de diffusion (distribution), comme par exemple ici celui de la chaleur u , sur la surface du modèle. Le processus de diffusion de la chaleur est défini comme :

$$\Delta_{\mathcal{M}} u(s, t) = -\frac{\partial u(s, t)}{\partial t}, \quad (2.14)$$

où $\Delta_{\mathcal{M}}$ représente l'opérateur Laplacien de \mathcal{M} , u satisfait la condition de la limite de Dirichlet $u(s, t) = 0$ pour tout $s \in \mathcal{M}$ et t est le temps de diffusion de la chaleur. La solution de l'équation de la chaleur est connue sous le nom de noyau de chaleur. Le noyau de chaleur $p_t(s_i, s_j)$ est une solution fondamentale de l'équation de la chaleur [71] en un point s_i à l'instant t avec une distribution initiale $u_0(s_i) = \delta(s_i - s_j)$ en un point $s_j \in \mathcal{M}$; et il est défini en termes de valeurs propres et de fonctions propres de $\Delta_{\mathcal{M}}$ comme suit :

$$p_t(s_i, s_j) = \sum_{k=0}^{\infty} e^{-\lambda_k t} \phi_k(s_i) \phi_k(s_j), \quad (2.15)$$

où, λ_k et ϕ_k sont les valeurs propres et les fonctions propres de l'opérateur LB. En effet, le noyau de chaleur décrit la quantité de chaleur qui est propagée ou transférée du point s_i au point s_j à l'instant t . Par conséquent, $p_t(s, s)$ décrit la quantité de chaleur restante au point s après un temps t . Pour chaque point $s \in \mathcal{M}$, la signature du noyau de chaleur (HKS) [20] est représentée dans le domaine temporel discret par un vecteur de caractéristiques de dimension n par :

$$\text{HKS}(s, t) = (p_{t_1}(s, s), p_{t_2}(s, s), \dots, p_{t_n}(s, s)), \quad (2.16)$$

où t_1, t_2, \dots, t_n sont les différentes échelles du temps. En d'autres termes, $\text{HKS}(p_t(s, s))$ est la diagonale de la matrice du noyau de chaleur $(p_t(s_i, s_j))$ à plusieurs échelles. Bien que $\text{HKS}(s, t)$ ne soit pas suffisamment compact pour être vraiment utile, il a été montré que $\text{HKS}(s, s)$ permet néanmoins de conserver suffisamment d'information pour rester exploitable. La Figure 2.8 illustre une représentation du noyau de chaleur par rapport à la signature du noyau de chaleur.

Le descripteur HKS contient des informations provenant principalement des basses fréquences qui correspondent aux caractéristiques macroscopiques de la forme ; il présente

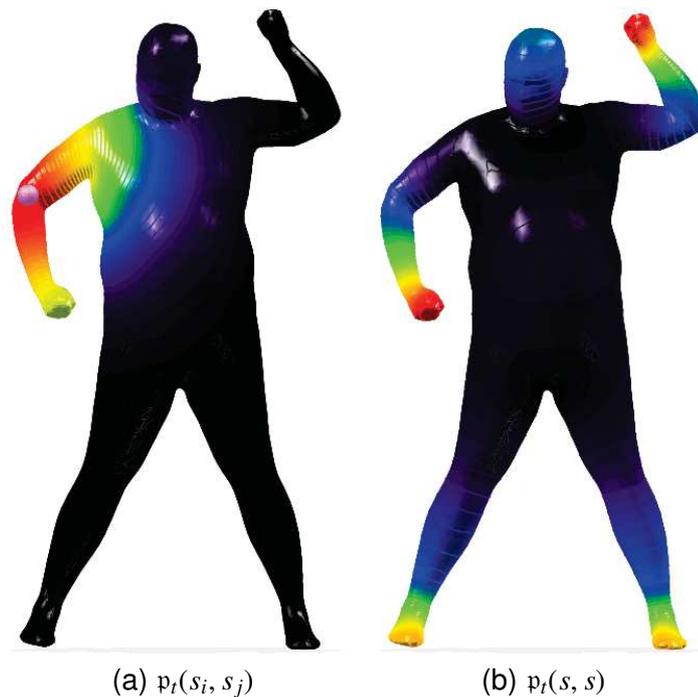


FIGURE 2.8 – (a) Propagation de la chaleur, $(p_t(s_i, s_j))$ à partir d'un point spécifié sur le coude de la forme humaine au reste de la forme pour un temps t donné. (b) Représentation de la signature du noyau de chaleur acquise par la diagonale de la matrice du noyau de chaleur. Comme il est indiqué, la chaleur augmente lorsque la couleur passe du noir au rouge. En outre, les valeurs maximales et minimales des courbures gaussiennes se rapportent, respectivement, à la quantité élevée et faible du $p_t(s, s)$.

ainsi une capacité de discrimination majeure dans les tâches de récupération et de classification de formes. Avec plusieurs facteurs d'échelle t_ℓ , une collection de filtres passe-bas peut être établie. Plus la valeur t_ℓ est grande, plus les hautes fréquences sont supprimées. Cependant, différentes fréquences sont toujours mélangées dans HKS, et la tâche de localisation de haute précision peut échouer en partie, à cause de la suppression des informations de haute fréquence qui correspondent à des caractéristiques microscopiques. $HKS(s, t)$ caractérise ainsi le paramètre d'échelle de temps et la taille de voisinage de s ce qui donne la capacité à l'appariement partiel [20, 55]. $HKS(s, s)$ est une simplification pour des soucis d'efficacité qui permet néanmoins de réaliser avec succès de la récupération ou de la classification, parce que cela contient principalement des basses fréquences. En comparaison avec le descripteur GPS, la signature HKS présente des avantages supplémentaires. Etant donné que HKS est une somme pondérée sur les carrés des fonctions propres, elle n'est donc pas sensible ni à l'ordre des fonctions propres ni à leurs signes.

2.4.4/ SIGNATURE DE CHALEUR MOYENNE

La signature de chaleur moyenne (HMS) [15] évalue quantitativement la distribution de la température résultant d'un processus de flux de chaleur :

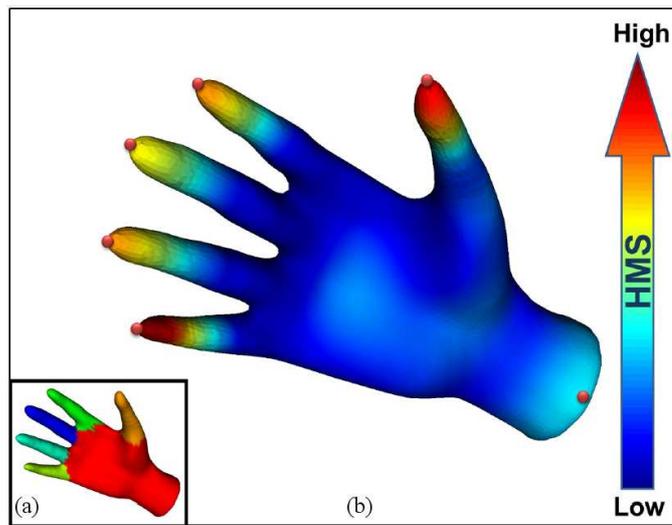


FIGURE 2.9 – Illustration de la signature moyenne de chaleur (HMS) sur un modèle d'une main humaine [15]. La Figure (a) montre les six segments de la main en utilisant PCMS. La Figure (b) illustre la distribution HMS à travers la surface de maillage d'un modèle d'une main humaine.

$$\text{HMS}_t(s) = \frac{1}{n} \sum_{s_i \neq s_j} p_t(s_i, s_j), \quad (2.17)$$

ce qui peut être physiquement interprété comme la température moyenne sur la surface obtenue en appliquant une quantité unitaire de chaleur appliquée en un point donné et après une certaine quantité de temps de dissipation de la chaleur. Un paramètre t , relativement petit, est souvent choisi empiriquement pour conserver une version de plus haute résolution de la surface originale [72]. La Figure 2.9(b) illustre la signature de chaleur moyenne et les centres de chaleur. Ensuite, une HMS multi-échelle est construite pour comparer la distribution de température avec plusieurs temps de diffusion, et est définie comme suit :

$$\text{HMS}(s) = (\text{HMS}_{t_1}, \text{HMS}_{t_2}, \dots, \text{HMS}_{t_n}). \quad (2.18)$$

La Figure 2.9(a) montre que la segmentation de formes est l'une des tâches particulières du HMS et qu'elle puisse correctement estimer le nombre de segments d'un modèle. Le descripteur HMS a des propriétés souhaitables qui le rendent puissant dans l'application de PCMS (*Perceptually Consistent Mesh Segmentation*) : (1) Il est invariant à la transformation quasi-isométrique du modèle 3D ; (2) Il est résistant au bruit numérique et topologique ; (3) Il reflète fidèlement la distribution de température pendant le processus de diffusion de la chaleur.

2.4.5/ DESCRIPTEUR DE DISTRIBUTION DE TEMPÉRATURE

Le descripteur de distribution de température (TD) [53], qui imite HMS, simule le processus de diffusion de la chaleur sur la surface d'un modèle : une unité de chaleur est appliquée en un sommet, et elle se diffuse aux autres sommets au cours du temps. Ce

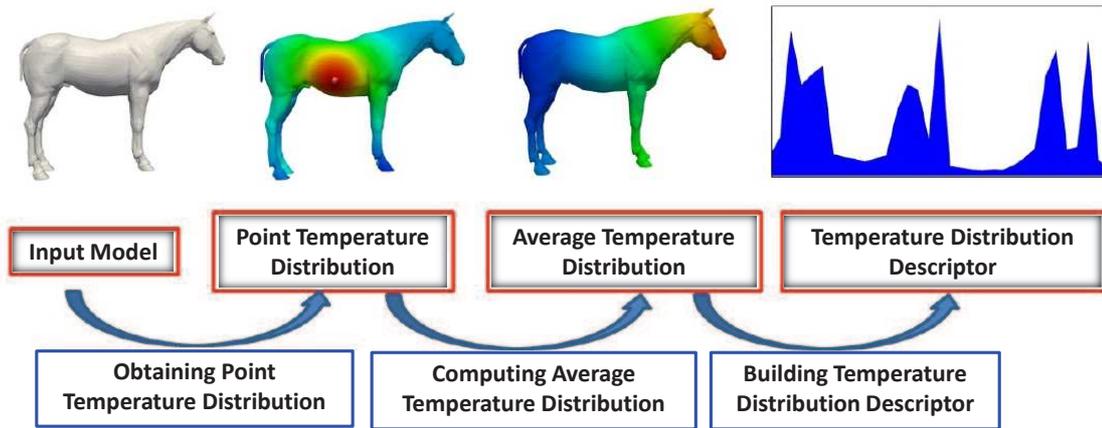


FIGURE 2.10 – Le descripteur de diffusion de chaleur calculé pour différents modèles [53]. Les valeurs du descripteur calculées pour les points sont représentées par une carte de couleurs graduée de la plus faible valeur en bleu à la plus importante valeur en rouge.

descripteur est basé sur la distribution des valeurs de températures moyennes pour tous les sommets du maillage. La fonction de la température moyenne *AVG* (*Average temperature function*) pour un sommet s , au temps t de la dissipation de la chaleur, est définie comme suit :

$$AVG_t(s) = \frac{1}{n-1} \sum_{s_j, s_j \neq s_i} \sum_k e^{-\lambda_k t} \phi_k(s_i) \phi_k(s_j) = \frac{1}{n-1} \sum_{s_j, s_j \neq s_i} p_t(s_i, s_j), \quad (2.19)$$

où n est le nombre total de sommets et t est une constante choisie empiriquement. En pratique, seuls quelques vecteurs propres sont utilisés ($k = 20$), ceux correspondant aux valeurs propres de plus grand module.

La Figure 2.10 illustre la manière de calculer le descripteur TD pour un modèle de cheval. L'organigramme comprend trois étapes principales. (1) Obtention de la distribution de température de point pour chaque sommet de la surface maillée : une unité chaleur est appliquée sur un sommet de la surface maillée et la distribution de la température est enregistrée. Ceci est répété pour chaque sommet du maillage ; (2) Calcul de la distribution de température moyenne : la valeur de la température moyenne est d'abord calculée pour chaque sommet et toutes ces valeurs produisent ensemble la distribution de température moyenne pour l'ensemble du modèle ; (3) Construction du descripteur de distribution de température : construire un histogramme unidimensionnel basé sur la répartition des valeurs de la température moyenne. La distance entre deux formes est la norme ℓ_2 calculée entre leurs histogrammes.

Le descripteur de TD hérite naturellement des propriétés du noyau de chaleur. Il est invariant par transformations isométriques comme les changements de pose, et résistant au bruit d'échantillonnage.

2.4.6/ SIGNATURE DU NOYAU D'ONDE

La signature de noyau d'onde (WKS) [21] est mieux adaptée que HKS pour la caractérisation des points sur la surface d'objets. Elle est de nature plus discriminative et ca-

pable de contenir des informations locales et globales de chaque point de différentes formes. WKS est plus précis, informatif et robuste que la signature du noyau de chaleur. Contrairement au HKS, le WKS sépare les influences de différentes fréquences, en traitant toutes les fréquences de manière égale. En d'autres termes, HKS utilise des filtres passe-bas, tandis que WKS utilise des filtres passe-bande. Cela aide à différencier clairement les différentes échelles et fréquences. De plus, le descripteur WKS est plus stable sous des perturbations non isométriques de différentes formes. Il peut également détecter la correspondance des caractéristiques en cas de données bruitées et même si sous des déformations topologiques de la forme. WKS est basé sur la caractérisation du point sur une surface avec des mesures et des probabilités moyennes de chaque particule dans différents niveaux d'énergie. La fonction d'onde d'une particule quantique est exprimée par :

$$\psi_E(s, t) = \sum_{k=0}^{\infty} e^{i\lambda_k t} \phi_k f_E(\lambda_k), \quad (2.20)$$

où E désigne l'énergie de la particule à un temps $t = 0$ et f_E sa distribution initiale. Puisque $|\psi_E(s, t)|^2$ est la probabilité de mesurer la particule en un point s , à l'instant t et de niveau d'énergie E , il s'ensuit que la probabilité moyenne (dans le temps) de mesurer une particule en s est donnée par :

$$P_E(s) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T |\psi_E(s, t)|^2 = \sum_{k=0}^{\infty} \phi_k^2(s) f_E^2(\lambda_k). \quad (2.21)$$

Le descripteur WKS est capable de capter des informations à partir de différentes fréquences. Ainsi, les propriétés de différentes formes dépendent entièrement de la valeur de f_E^2 . Dans WKS, le paramètre d'échelle de temps n'est pas considéré car il n'est pas directement interprété dans les formes. Par conséquent, le paramètre d'énergie est utilisé dans la signature du noyau d'onde au lieu du paramètre de temps. Le vecteur de caractéristiques de dimension n avec différentes probabilités est représenté par :

$$\text{WKS}(s) = (P_{e_1}(s), P_{e_2}(s), \dots, P_{e_n}(s)), \quad (2.22)$$

où $e_k = \log E_k$ est l'échelle d'énergie logarithmique. Le descripteur WKS représente la moyenne des probabilités calculées en chaque sommet, en mesurant l'évolution d'une particule quantique sur la surface du modèle.

2.5/ AUTRES MÉTHODES SPECTRALES

De nombreux chercheurs ont apporté des modifications au calcul des approches spectrales précédentes afin d'augmenter leurs performances de recherche pour certains problèmes. Dans cette section, nous détaillons ces méthodes et commentons leur nouveauté.

Raviv *et al.* [73] ont étendu la signature du noyau de chaleur, normalement calculée à partir de maillages, à un descripteur volumétrique. Dans ce cas, l'opérateur LB est calculé à partir d'une version voxélisée du modèle 3D pour générer la signature du noyau

de chaleur volumétrique VHKS (*Volumetric Heat Kernel Signature*). En utilisant l'amplitude de la transformée de Fourier, Kokkinos *et al.* [74] ont introduit la signature de noyau de chaleur invariante à l'échelle SIHKS (*Scale Invariance Heat Kernel Signature*), qui est construite sur la base d'un espace d'échelle logarithmiquement échantillonné. Très récemment, Zeng *et al.* [75] ont étendu HKS pour introduire une nouvelle signature du noyau de chaleur invariante à l'échelle NSIHKS (*New Scale Invariance Heat Kernel Signature*). L'avantage de cette signature réside dans l'optimisation du paramètre temps de HKS qui rend la caractéristique plus adaptable et robuste. Les auteurs ont évalué leur signature sur la base de donnée de formes 3D non rigides SHREC-2010 [76], et ont montré qu'elle surpasse significativement HKS et SIHKS dans le processus de recherche par forme clef. Une autre modification à la HKS a été faite par Castellani *et al.* [7], où ils ont introduit la signature du noyau de chaleur globale GHKS (*Global Heat Kernel Signature*), qui est une concaténation d'histogrammes pour un nombre fixe d'échelles de HKS. Ils ont utilisé la GHKS pour la classification de cerveaux afin de distinguer les patients atteints du schizophrénie.

Une signature SGW (*Spectral Graph Wavelet*) de forme généralisée a été introduite par Li et Hamza dans [77]. Cette signature est un descripteur local multirésolution non seulement invariant aux transformations isométriques, mais aussi compact, facile à calculer et qui combine les avantages des filtres passe-bas et passe-bande. Masoumi *et al.* [78] ont amélioré les travaux antérieurs [77] en incorporant la zone de sommet dans le calcul du descripteur. Récemment, Ye et Yu [79] ont profité d'opérateurs fonctionnels pour concevoir un cadre spécifique pour coder des géométries non rigides en utilisant un opérateur de noyau intégral sensible au contexte de la forme. Li *et al.* [80] ont calculé un descripteur pour la recherche de forme non rigide basée sur la HKS, qui est seulement calculé sur des points-clés assignés pour réduire la complexité de calcul. Mohamed et Hamza [81] ont créé un descripteur basé sur le squelette de forme spectrale calculé à partir de la deuxième fonction propre de l'opérateur LB, et ont comparé ces squelettes en utilisant un cadre de correspondance de graphes. Dernièrement, Han [82] a développé et calculé ShapeDNA en utilisant la méthode du point le plus proche [83], où le spectre tronqué de l'opérateur LB est utilisé pour identifier l'objet. L'auteur a montré que la robustesse est encore améliorée par la méthode du point le plus proche qui est capable de représenter les surfaces sans aucune paramétrisation.

2.6/ CONCLUSION

Dans ce chapitre, nous avons présenté les notions de base de la géométrie différentielle et spectrale, ainsi qu'un état de l'art des descripteurs de formes utilisés dans le domaine de la reconnaissance et de la correspondance de formes 3D. Ces descripteurs peuvent être repartis en trois classes principales : les descripteurs géométriques, les descripteurs structurels et topologiques, et les descripteurs par prises de vues. Nous nous sommes intéressés aux descripteurs géométriques, et plus particulièrement ceux construits à partir de l'analyse spectrale de l'opérateur LB, car ils considèrent les caractéristiques géométriques globales et locales de la forme. Les descripteurs géométriques sont répartis en deux classes : les descripteurs locaux, et les descripteurs globaux. Ces descripteurs sont des sous familles des descripteurs basés sur la géométrie de diffusion et la décomposition spectrale. Ce type de descripteur prend en compte des informations géométriques locales pour décrire la totalité de la forme.

Le descripteur calculé permet d'attribuer à chaque point sur la surface du modèle une valeur numérique. L'ensemble de toutes les valeurs numériques calculées et associées à chaque point sur la surface de l'objet constitue un vecteur de caractéristiques, représentant la propriété spectrale le long de la forme. Ces valeurs sont ensuite transformées en une distribution ou histogramme. La distance entre deux formes est la distance entre leurs histogrammes associés.

Dans les chapitres suivants, nous présenterons nos contributions au domaine de recherche et d'appariement de formes, en utilisant différents descripteurs de formes décrits dans ce chapitre.

SIGNATURE DE POINT GLOBALE AVANCÉE (AGPS)

Dans ce chapitre, nous proposons un nouveau descripteur d'objets 3D, appelé signature de point globale avancée (AGPS), qui est basé sur l'analyse spectrale de la forme et est obtenu par combinaison linéaire de certaines fonctions propres mises à l'échelle de l'opérateur de Laplace-Beltrami. Comme il est construit sur le concept de la signature de point globale, AGPS hérite de plusieurs propriétés utiles telles que sa robustesse au bruit, sa stabilité et son invariance à l'échelle. A partir du descripteur AGPS, nous exposons une méthode d'extraction des caractéristiques saillantes, qui permet une caractérisation simple et efficace de la forme, à partir d'objets semi-rigides représentés sous forme de maillages triangulaires. Pour qualifier la performance de notre descripteur en terme de robustesse contre le bruit et les modifications topologiques, nous avons effectué des expériences sur plusieurs bases de données de référence et comparé notre méthode à celles de l'état de l'art pour la reconnaissance et la récupération des formes.

3.1/ INTRODUCTION

La reconnaissance, la classification et l'appariement de formes 3D sont des défis clés en matière d'infographie, de vision, de robotique et de traitement d'images. Depuis qu'il est devenu plus facile et rapide de produire des données 3D massives, ces tâches ont aujourd'hui une importance majeure dans de nombreux domaines allant de la recherche scientifique au divertissement. Cependant, ces dernières restent encore délicates, ou très spécifiques en fonction de l'application en raison de multiples facteurs, y compris les transformations locales ou globales, rigides, semi-rigides ou non rigides, l'échantillonnage potentiellement irrégulier, les variations de triangulation de la forme, etc. En conséquence, la conception d'un descripteur de forme simple et efficace, mais aussi suffisamment discriminant, constitue toujours une tâche difficile.

Dans ce contexte, beaucoup d'attention a été accordée aux techniques de plongement spectral (*spectral embedding*), c'est-à-dire à l'utilisation des valeurs propres et de leurs fonctions propres correspondantes de l'opérateur de Laplace-Beltrami de la forme. Ces techniques sont invariantes sous les transformations isométriques, ce qui permet de représenter les valeurs d'un descripteur calculées pour tous les points du maillage par une carte de couleur graduée et similaire entre des formes approximativement isométriques. Le plongement (ou projection) d'une variété, en particulier, dans un espace euclidien, est

souvent utilisé pour simplifier les procédures d'appariements et de comparaisons d'un même objet dans différentes expressions ou poses. Dans cette catégorie de descripteurs, nous proposons la signature de point globale avancée (AGPS) en tant que nouveau descripteur d'objets 3D possédant les propriétés souhaitables suivantes :

- Il exploite la structure intrinsèque d'une forme et organise ses informations de manière efficace.
- Il est stable que ce soit sous des transformations non rigides ou sous des perturbations de la forme, y compris le bruit géométrique et les changements topologiques.
- Il peut être calculé rapidement, avec précision et efficacité.

Le descripteur AGPS peut être utilisé dans de nombreuses applications, y compris la mise en correspondance robuste, la classification et l'appariement de formes, comme montré dans la Figure 3.1 qui illustre, pour diverses poses et perturbations, la robustesse de notre descripteur, ainsi que sa stabilité pour la détection de structures géométriques similaires. Plus précisément, la première colonne affiche un Centaure dont le plongement spectral AGPS est montré dessous. La deuxième colonne représente une autre pose avec son plongement spectral AGPS associé. Les troisième et quatrième colonnes montrent, respectivement, des Centaures transformés par dilatation et ajout de bruit, avec leurs projections AGPS correspondantes. Comme le montre la Figure 3.1, les quatre représentations d'AGPS et les points d'intérêt sur les différentes formes restent similaires.

3.1.1/ TRAVAUX ANTÉRIEURS

Plusieurs travaux de recherche ont été menés sur la conception de divers descripteurs pour la reconnaissance et l'appariement de formes. Nous pouvons distinguer deux grandes catégories : le plongement spectral et les signatures de formes. L'idée d'utiliser le plongement spectral pour l'analyse des maillages n'est pas nouvelle, car elle a été appliquée pour le partitionnement dans [84] et la mise en correspondance dans [85, 86]. Bérard *et al.* [87] ont été les premiers à suggérer d'utiliser les valeurs propres et les fonctions propres de l'opérateur de Laplace-Beltrami pour le plongement spectral à l'aide du noyau de chaleur. Ils ont ensuite utilisé la distance de Hausdorff pour définir une métrique entre les classes de formes isométriques. Nous rappelons que le descripteur GPS a été introduit par Rustamov dans [23]. Il a été utilisé par plusieurs chercheurs dans divers domaines, par exemple pour l'analyse de forme en médecine et en biologie [49], et pour la segmentation et la registration de formes [62]. Cependant, le descripteur GPS ne peut pas être utilisé pour détecter des symétries partielles ni pour effectuer un appariement global ou partiel et souffre du problème de la commutation des fonctions propres lorsque les valeurs propres sont proches [20, 88]. Shtern *et al.* dans [25] ont introduit le champ de gradient spectral (ou *spectral GFs*), qui est défini pour chaque point de la forme en utilisant des paires de fonctions propres de l'opérateur de Laplace-Beltrami au lieu d'utiliser les fonctions propres elles-mêmes. Un vecteur de points caractéristiques est utilisé pour trouver la correspondance en projetant les formes dans l'espace euclidien qui est, à son tour, basé sur les produits internes et externes entre les champs de gradient de paires de fonctions propres. Selon les fonctions propres et les champs de gradient, les produits internes et externes sont relativement stables sous les déformations isométriques, la mise à l'échelle et les différentes poses et articulations de la forme.

Dans la catégorie des signatures de formes, plusieurs méthodes récentes sont utilisées pour la reconnaissance et l'appariement de formes. La signature HKS reste parmi les

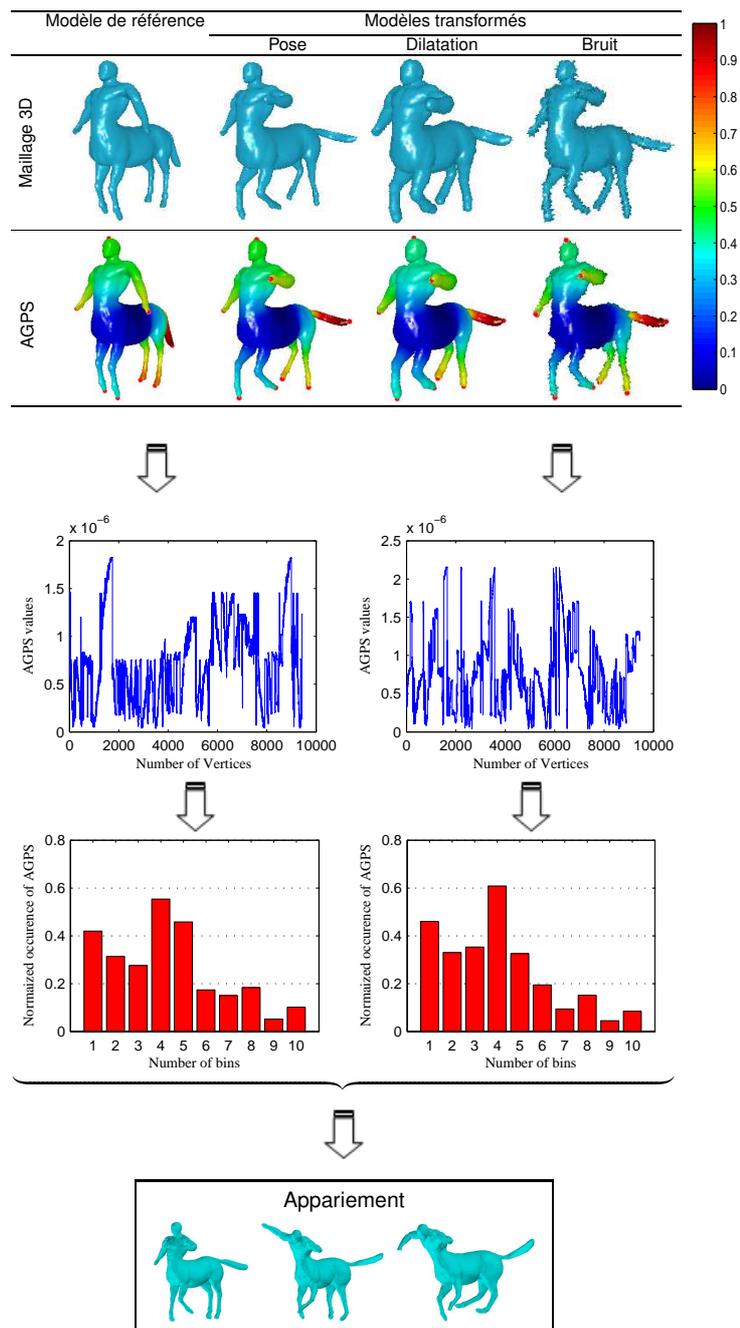


FIGURE 3.1 – Illustration sur le modèle Centaure. L'AGPS reste similaire sous diverses poses et perturbations puisque le descripteur est quasi invariant aux déformations isométriques et semi-rigides et au bruit. La recherche de forme est simplement réalisée en utilisant la similarité d'histogramme après la quantification d'AGPS sur tous les points du maillage. Dans toutes nos figures, les couleurs bleues et rouges représentent les faibles et importantes valeurs calculées par AGPS pour tous les points de la forme.

descripteurs les plus utilisés malgré sa localisation relativement faible comme relevé dans [89]. Nous renvoyons les lecteurs à [74, 73, 66] pour les extensions de HKS, et à [21] pour la signature du noyau d'onde (WKS) qui a été introduite pour remédier à la

forte sensibilité aux basses fréquences de HKS. Le descripteur SGW [77] a été présenté dans le but de décrire à la fois la géométrie globale et locale de l'objet. Pour une étude approfondie de la plupart de ces méthodes, nous nous référons à [55]. Ces descripteurs ont un inconvénient majeur, ils ignorent à titre d'exemple les informations directionnelles. Récemment, Andreux *et al.* [90] ont proposé un opérateur LB anisotrope qui conserve les propriétés clés de l'opérateur LB isotrope et qui bénéficie d'un processus de diffusion plus significatif sur le plan sémantique. Plus tard, Boscaini *et al.* [91] ont construit une nouvelle classe de descripteurs de forme à partir de noyaux de diffusion orientés anisotropes qui ont été appris en utilisant une architecture d'apprentissage profond. De plus, afin de formuler un descripteur de caractéristique générique de formes, une approche d'apprentissage profond basée sur des descripteurs spectraux a été récemment proposée par Litman *et al.* [92]. Dans le même contexte, une approche différente a été proposée très récemment par Masci *et al.* [93]. Leur méthode consiste à généraliser un réseau de neurone convolutionnel (CNN) appliqué à des données géométriques traitées comme des variétés euclidiennes et non-euclidiennes. En particulier, les auteurs se sont concentrés sur la définition intrinsèque de l'opération de convolution sur les maillages. CNNs sont coûteux en terme de matériel et nécessitent beaucoup de données pour l'apprentissage, néanmoins ils sont compétitifs et efficaces. Par comparaison avec toutes ces méthodes, notre méthode est très simple, efficace, peu coûteuse, et n'a donc pas besoin d'une longue procédure d'optimisation.

Parmi tous les descripteurs non spectraux, le descripteur de distribution (D2) [94] est considéré comme une méthode de référence très simple et qui donne de bons résultats pour des objets rigides, ce qui permet de donner un ordre de grandeur des méthodes non spectrales sans toutes les réimplanter. Le descripteur D2 est global. Ce descripteur échantillonne n points sur la surface de l'objet, et associe à chaque point une valeur numérique en utilisant une mesure donnée. La mesure peut être la distance au centre de gravité de l'objet, l'angle formé entre trois points, etc. Ces valeurs sont ensuite transformées en une distribution ou histogramme. La distance entre deux objets est la distance entre leurs histogrammes associés. Pour plus de détails et comparaisons, le lecteur pourra se référer aux [34, 53].

Jusqu'à présent, un grand nombre de méthodes pour la recherche de formes ont été proposées. Dans une étude très récente, Lian *et al.* [2] ont introduit un benchmark de formes 3D non rigides qui comprend 1200 maillages triangulaires et ont évalué et comparé la performance de sept méthodes de recherche d'objets. Puisque nous utilisons également ce benchmark, ici, nous concentrons notre attention sur ces sept méthodes. Choi a introduit une méthode appelée SNU (*Seoul National University*). Dans cette méthode, seules les distributions de distance géodésique des modèles de maillage sont utilisées. Pour chaque maillage, 1600 points sont échantillonnés. Ensuite, toutes les distances géodésiques entre les points échantillonnés sont calculées, générant une matrice de distance géodésique (GDM) de taille égale à 1600×1600 qui est convertie en un histogramme. La dissemblance entre différents modèles de maillage est calculée en appliquant différentes fonctions de mesure de similarité telles que la distance euclidienne et la mesure de corrélation [95]. Lai et Sun ont fusionné les descripteurs HKS, WKS et la surface du maillage SA (*Surface Area*) [96] pour la construction d'un descripteur multi-caractéristiques (*Multi-feature Descriptor*). Ce descripteur a été utilisé pour améliorer la précision lors de la mise en correspondance. Pickup *et al.* [96], qui ont introduit SA, adoptent une mesure de la surface totale du maillage. Cette mesure n'est pas indépendante de l'échelle. SA est triviale à implanter et est très efficace pour le calcul. Li a proposé une méthode pour la

représentation et la recherche de formes non rigides appelée SG (*Spectral Geometry*). Cette méthode se compose de deux étapes : (1) la signature SGW [77] pour l'extraction de descripteurs, et (2) l'appariement de pyramides spatiales intrinsèques [97] pour la comparaison de forme. Limberger et Wilson ont introduit un cadre statistique discriminatif pour le codage de caractéristiques FVF (*Fisher Vector Framework*). La méthode combine des signatures spectrales locales qui décrivent les caractéristiques locales de la forme dans un descripteur global pour la recherche de formes. En résumé, cette méthode calcule des descripteurs locaux pour chaque modèle, puis calcule un dictionnaire en sélectionnant un sous-ensemble de modèles et en estimant un modèle de mixture gaussienne pour chaque couche des descripteurs concaténés depuis le sous-ensemble. Après cela, chaque signature de forme est codée en une représentation globale de la forme en utilisant FVF. Cette étape résulte en un vecteur de grande dimension qui décrit chaque forme en fonction de sa déviation depuis le dictionnaire. Ce vecteur est utilisé comme une signature globale de la forme. Nakanishi *et al.* ont proposé d'utiliser l'analyse de séries temporelles pour la recherche de forme TSASR (*Time Series Analysis for Shape Retrieval*). L'idée clé de cette méthode est de représenter le vecteur de caractéristiques d'un modèle 3D sous la forme d'une série temporelle. Comme l'illustre la Figure 3.2, la méthode comprend trois étapes principales : le tri des sommets, la génération de séries temporelles et les coefficients de diffusion de la série temporelle. Pevzner *et al.* [98] ont introduit le descripteur d'intersection de sphère SID (*Sphere Intersection Descriptor*). En substance, cette méthode suit les évolutions des sphères et agrège les courbes d'intersection en un seul descripteur. En transformant le descripteur en domaine fréquentiel, les auteurs ont obtenu une représentation d'image 2D de l'échantillonnage de la géométrie de la surface locale. La transformation produit ainsi un descripteur de caractéristique locale invariant en rotation. Finalement, la distance de Manhattan est utilisée pour mesurer le coût de correspondance entre deux représentations données. La Figure 3.3 montre l'intersection de la sphère avec le maillage, la courbe résultante sur le plan (ϕ, θ) et la transformation vers le domaine fréquentiel.

3.1.2/ CONTRIBUTIONS

Nos contributions dans ce chapitre peuvent être résumées comme suit :

- (i) Nous introduisons la signature de point globale avancée comme un outil pour caractériser les sommets sur une surface de maillage dans un système de coordonnées finies. Voir le Tableau 3.1 pour un résumé des méthodes de plongement et des signatures de formes existantes.

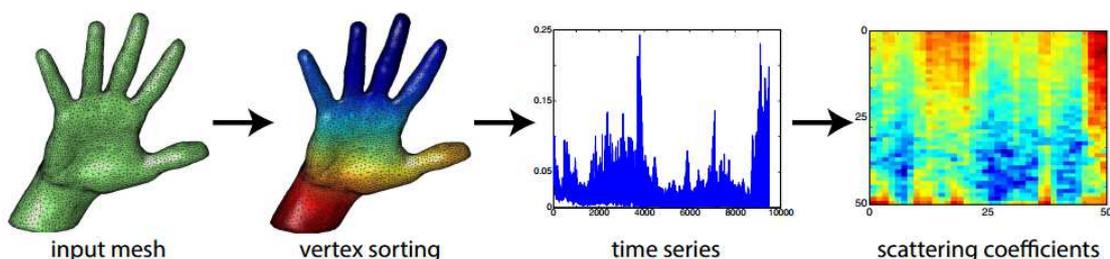


FIGURE 3.2 – Pipeline du cadre de recherche de formes basé sur TSASR [2].

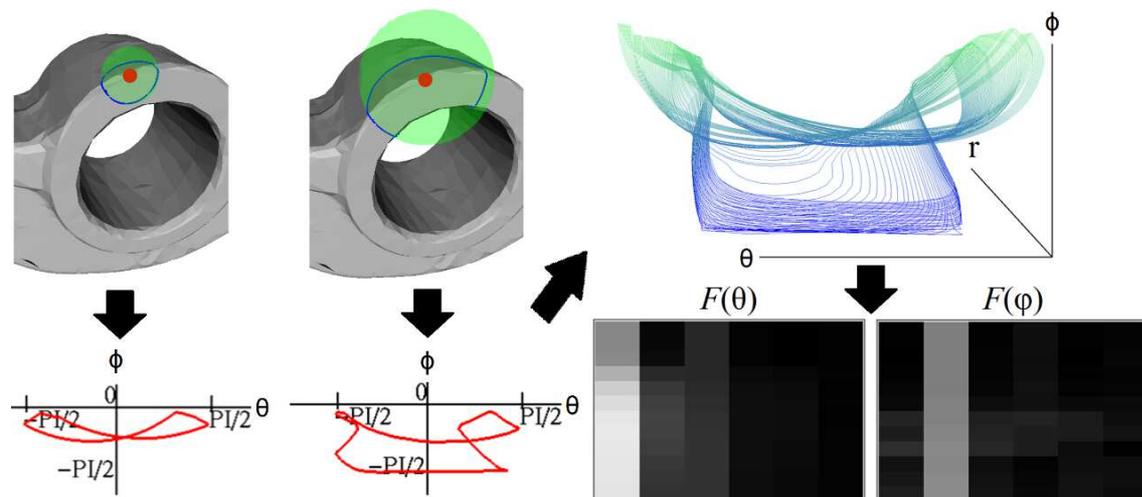


FIGURE 3.3 – Vue d’ensemble du descripteur SID pour une seule caractéristique. En haut à gauche : deux intersections de sphères avec des rayons différents. En bas à gauche : courbes d’intersection paramétrées correspondantes. En haut à droite : plusieurs intersections agrégées. En bas à droite : transformation de domaine fréquentiel donnant une représentation d’image 2D compacte [98].

- (ii) La signature de point globale avancée, en tant que caractéristique spectrale, est démontrée comme invariante isométrique, parce que les valeurs propres et les fonctions propres sont naturellement invariantes à la rotation, à la translation et à la mise à l’échelle. En outre, l’AGPS est relativement stable et permet d’obtenir une meilleure discrimination de formes.
- (iii) L’AGPS est étonnamment compacte car seul un petit nombre de vecteurs propres et de valeurs propres est nécessaire pour obtenir une description de forme précise.

Le reste de ce chapitre est organisé comme suit. Dans la section 3.2, nous présentons la signature de point globale avancée. La section 3.3 fournit un algorithme détaillé pour l’extraction des points d’intérêt, l’appariement et la récupération des formes, ainsi que la méthodologie d’évaluation adoptée. Nos expériences, résultats et discussions, sur deux bases de données de formes 3D standards, sont présentées dans la section 3.4. Nous concluons ensuite sur les points forts de notre descripteur dans la section 3.5.

3.2/ L’APPROCHE PROPOSÉE

Contrairement au descripteur GPS, nous recherchons un descripteur invariant pour les changements de signe des fonctions propres, stable, robuste pour la commutation propre et aussi compact que possible. Étant donné un point s sur le maillage \mathcal{M} , nous définissons son AGPS comme :

$$\text{AGPS}(s) = \sum_{i \geq 1}^k \left(\frac{\phi_i(s)}{\lambda_i} \right)^2, \quad (3.1)$$

où $\phi_i(s)$ est la valeur de la fonction propre ϕ_i au point s . Notons que ϕ_0 est vide d’information, et donc inutilisée.

TABLE 3.1 – AGPS et autres méthodes de plongement spectral et signatures de formes.

AGPS [34]	$\sum_i \lambda_i^{-2} \phi_i^2(s) ; i \geq 1$
GFs spectral [25]	$(\sqrt{\lambda_i \lambda_j})^{-1} \langle \nabla \phi_i(s), \nabla \phi_j(s) \rangle,$ $(\sqrt{\lambda_i \lambda_j})^{-1} ((\nabla \phi_i(s), \nabla \phi_j(s)) \cdot \mathbf{n}(s)) ; i, j \geq 1$
Plongement spectral [87]	$e^{-\lambda_i t} \phi_i(s) ; i \geq 1, t > 0$
GPS [23]	$(\sqrt{\lambda_i})^{-1} \phi_i(s) ; i \geq 1$
HKS [20]	$\sum_k \exp(-\lambda_k t) \phi_k(s) ; t > 0$

Le nom d'AGPS vient de l'intuition que ce vecteur de dimension finie est une compression des vecteurs de dimension infinie de la signature de point globale. Par conséquent, la projection des fonctions AGPS sur un objet constitue une caractérisation de chaque point sur toute la surface du maillage. Par ailleurs, AGPS peut être considéré comme un détecteur de points saillants ; il permet de localiser les sommets les plus importants sur la surface de l'objet. Dans la section 3.3.1 nous utilisons l'AGPS pour détecter des caractéristiques géométriques saillantes sur la surface du maillage, alors qu'en section 3.4.2 nous l'utilisons pour de la recherche de forme.

L'équation (3.1) montre que l'AGPS est une combinaison linéaire des carrés des valeurs des fonctions propres mises à l'échelle. Il peut, en outre, être considéré comme une cartographie des colorants (puisque une couleur est associée à chaque sommet selon la valeur de la fonction AGPS en ce sommet) sur la surface dans un espace de dimension finie égal à $(n \times 1)$. L'image ou la projection de cette carte de couleur sur les points $s \in M$ du maillage de la forme est appelée le plongement AGPS de la surface. Nous nous intéressons à la cohérence de l'AGPS à différents niveaux et types de pose et pour des objets subissant des déformations semi-rigides. A titre d'exemple, dans la Figure 3.4, nous utilisons des modèles d'Armadillo et du Flamant rose où chacun d'eux est différent dans la position, l'orientation, la pose, l'échelle, le nombre de sommets et la triangulation. Comme l'illustre cette dernière figure, l'AGPS est quasi invariant pour chaque modèle en dépit des nombreuses transformations subies.

Propriété intrinsèque Si $T : M \rightarrow N$ est une isométrie entre deux variétés riemanniennes M et N , alors $\text{AGPS}^M(s) = \text{AGPS}^N(T(s))$ pour tout $s \in M$.

Rappelons que l'opérateur de Laplace-Beltrami et les fonctions propres sont intrinsèques dans le sens où les valeurs des fonctions propres associées aux points de la surface ne dépendent pas de la position de la surface en coordonnées cartésiennes. Cela permet de caractériser chaque point du maillage selon sa valeur AGPS. L'invariance de notre descripteur sous des déformations isométriques est simplement la conséquence directe de l'invariance de l'opérateur de Laplace-Beltrami, puisque la signature de point globale avancée n'implique que des propriétés intrinsèques de la surface. Une conséquence pratique de cette propriété est que le descripteur AGPS peut être utilisé pour analyser des maillages subissant une déformation non rigide, ce qui, par exemple, sera utile pour reconnaître et mettre en correspondance des formes articulées dans différentes poses.

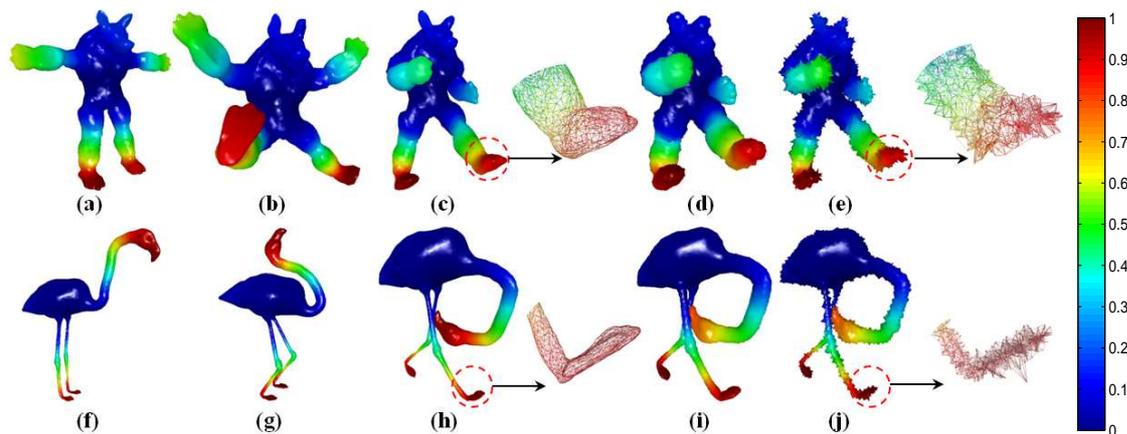


FIGURE 3.4 – Le plongement AGPS sur deux modèles (a, f) qui subissent plusieurs types de transformations (b–j). Déformations colonne par colonne du (b, g) au (e, j) sont ; changement de pose, un nouveau changement de pose, gonflement et ajout de bruit, respectivement ; les vues agrandies montrent la différence entre les formes avant et après l’ajout de bruit.

Stabilité Dans la pratique, de nombreux modèles déformables ne sont pas strictement isométriques et une signature de point robuste ne devrait pas être sensible à de si faibles perturbations. Dans la section 3.1.1, nous avons signalé que la signature de point globale est robuste, mais elle n’est pas stable sous la perturbation car les fonctions propres sont uniquement définies au signe près. Pour l’AGPS, les changements continus sur la surface de la forme entraînent des changements continus dans le spectre propre rendant la représentation insensible au signe des fonctions propres. Par ailleurs, les principaux types de perturbations peuvent souvent affecter la forme et donc le descripteur, toutefois nous démontrons le contraire : c’est que notre descripteur est stable et ne s’affecte quasiment plus par les faibles perturbations géométriques appliquées sur la forme.

Pour une forme possédant une symétrie bilatérale T , la théorie prouve que bien que deux fonctions propres correspondent à des valeurs propres non répétitives, les valeurs absolues des vecteurs propres ϕ ne seront pas conservées sous les symétries bilatérales, telles que $|\phi(T(s))| \neq |\phi(s)|$, comme il est requis par [99]. Ainsi, la théorie des perturbations montre que deux vecteurs propres peuvent être échangés. Puisque notre descripteur peut être vu comme une somme des carrés des fonctions du descripteur GPS mises à l’échelle telles que $AGPS(s) = \sum_i GPS_i^2(s)/\lambda_i$, il n’est alors ni sensible au changement de signe ni à l’ordre des fonctions propres. Maintenant, il est à noter que contrairement à la stabilité des calculs de fonction propre utilisée dans [23] et [99] qui dépend de l’écart spectral, la stabilité du descripteur AGPS dépend uniquement de la perturbation elle-même, ce qui est plus facile à contrôler. Outre que le descripteur AGPS hérite de nombreuses propriétés utiles du descripteur GPS, la stabilité contre les perturbations de la forme est une autre propriété importante qui se rajoute à la liste des propriétés d’AGPS. Notre descripteur est plus stable que le GPS et peut être utilisé pour détecter précisément des structures géométriques similaires, telles que des points, comme indiqué dans la section 3.4.

Relation avec la courbure moyenne Le descripteur AGPS peut fournir une indication sur la courbure moyenne de la forme. Il conduit à des valeurs importantes sur les régions



FIGURE 3.5 – La signature de point globale avancée AGPS (s) effectué pour les 50 plus petites valeurs propres sur les modèles de l'Araignée, la main, et l'Icosaèdre. Les valeurs d'AGPS (s) augmentent à mesure que la couleur passe du bleu au rouge.

à courbure positive et tend vers des valeurs marginales sur les régions à courbure négative ou nulle. La Figure 3.5 trace l'AGPS pour les 50 plus petites valeurs propres sur trois formes. Notons que pour l'icosaèdre, les arêtes tranchantes représentent les maxima d'AGPS. Les couleurs représentent les valeurs de la fonction d'AGPS (s) en chaque sommet. La fonction AGPS(s) fournit une indication significative sur le type de la courbure (concavité, convexité, etc) à tous les points. Nous utilisons donc ces courbures, dans la section 3.3.1, pour identifier et détecter les caractéristiques saillantes sur la forme.

Relation avec HKS Un autre descripteur populaire qui dérive de l'opérateur LB est la signature du noyau de chaleur [20]. Les deux descripteurs, AGPS et HKS, sont invariants en isométrie, faciles à calculer, et ne souffrent pas du danger de "commutation" de la valeur propre sous de petites déformations qui ont été observées pour GPS. En revanche, le descripteur HKS possède un inconvénient remarquable qui est sa sensibilité à l'échelle de forme.

Pour résumer, notre descripteur de formes possède de nombreuses propriétés, qui sont : l'invariance à l'isométrie (deux formes isométriques ont des AGPS égaux), la stabilité face aux changements géométriques de la forme (stabilité de la représentation spectrale sur la forme entière), et aussi l'informativité : si deux formes ont la même AGPS, alors elles sont isométriques.

3.3/ CLASSIFICATION ET RECHERCHE DE FORMES

La recherche et la classification d'objets consistent à déterminer la nature d'une forme donnée, et la catégorie d'objets à laquelle il est susceptible d'appartenir. Cependant, pour la classification des caractéristiques saillantes de la forme, nous proposons l'algorithme de détection de points d'intérêt basé sur AGPS. En revanche, pour mesurer et évaluer la performance de notre descripteur dans le processus de recherche par forme clef, nous calculons la distance entre les modèles en utilisant de différentes métriques de similarité, et définissons les notions classiques de rappel et précision.

3.3.1/ DÉTECTION DE POINTS D'INTÉRÊTS

Dans une étude récente, Dutagaci *et al.* [100] ont introduit un benchmark de formes 3D qui comprend 43 maillages triangulaires et une méthodologie d'évaluation de la performance de cinq algorithmes [101, 102, 103, 104, 105] conçus pour prédire les points d'intérêt en 3D. Pour établir des comparaisons pertinentes en terme de données et de traitement, nous utilisons les benchmarks et les méthodes pour lesquelles des résultats qualitatifs et quantitatifs sont disponibles. Lee *et al.* [101], qui ont introduit la saillance de maillage (*Mesh saliency*), abordent la détection de points d'intérêt grâce à des estimations de courbure locale couplée à un schéma d'encadrement à plusieurs échelles. La saillance totale d'un sommet est définie comme la somme de la différence des opérateurs gaussiens (DoG) sur toutes les échelles. Castellani *et al.* [103], qui ont introduit les points saillants (*Salient points*), adoptent également une approche multi-échelle. Les filtres DoG sont appliqués aux sommets pour calculer un vecteur de déplacement de chaque sommet à chaque échelle. Les vecteurs de déplacement sont alors projetés sur les normales des sommets produisant une "carte à l'échelle" pour chaque échelle. Les points d'intérêt sont extraits parmi les maxima locaux des cartes à l'échelle. Sipiran et Bustos [104] ont généralisé le détecteur de Harris et Stephens 2D [106] à un détecteur 3D (3D *Harris*). Le calcul est maintenant effectué sur les anneaux d'un sommet, qui jouent le rôle de pixels voisins. Une surface quadratique est ajustée autour de chaque sommet. Ceci permet le calcul d'un filtre similaire à l'opérateur Harris, dont les réponses maximales sont sélectionnées en tant que points d'intérêt. Le détecteur 3D SIFT (3D *Scale Invariant Feature Transform*) a été introduit par Godil et Wagan [105] qui convertissent initialement le modèle de maillage en une représentation de voxels. Ensuite, des filtres 3D gaussiens sont appliqués au modèle de voxels à différentes échelles, comme dans l'algorithme SIFT standard. Les filtres DoG sont utilisés pour calculer la différence entre le modèle original et le modèle à une échelle particulière et leurs extrema sont considérés comme des points d'intérêt potentiels. Le dernier ensemble de points d'intérêt est celui qui se trouve également à la surface de l'objet 3D. Novatnack et Nishino [102] ont introduit un détecteur dépendant de l'échelle (*Scale Dependent Corners*). Ils mesurent la variabilité d'échelle géométrique d'un maillage 3D sur une représentation 2D de la géométrie de surface donnée par ses cartes normales et de distorsion, qui peuvent être obtenues en dépliant la surface du modèle sur un plan 2D. Un espace-échelle géométrique qui code l'évolution des normales de surface sur le modèle 3D pendant qu'il est progressivement lissé est construit et les points d'intérêt sont extraits comme des points à forte courbure à plusieurs échelles.

L'AGPS peut être appliqué pour identifier, distinguer et différencier les points saillants. Une observation similaire pour HKS est mentionnée dans [20, 107]. Ces points-clés sont identifiés par les maxima locaux de la fonction AGPS(s). En pratique, nous proclamons un point s comme point-clé si $AGPS(s) > AGPS(s_i)$ pour tout s_i dans le voisinage à deux anneaux de s . Ces maxima locaux permettent de détecter, par exemple, les pieds, les oreilles, la queue et les défenses du modèle d'Éléphants ou aussi les mains, les pieds et la tête du modèle d'homme comme illustré sur la Figure 3.6. Le nombre des maxima locaux est remarquablement fixe pour chaque modèle et à travers une collection de poses appartenant à la même catégorie. Malgré le fait que les modèles subissent des déformations non rigides, il n'est pas nécessaire de considérer un grand nombre de vecteurs et fonctions propres pour obtenir des résultats robustes. Dans les faits, uniquement une dizaine de vecteurs suffisent. Ceci, est dû à la nature locale de l'AGPS, puisqu'elle décrit la distribution du colorant du point à lui-même et qui ne dépend pas de la variabilité de la

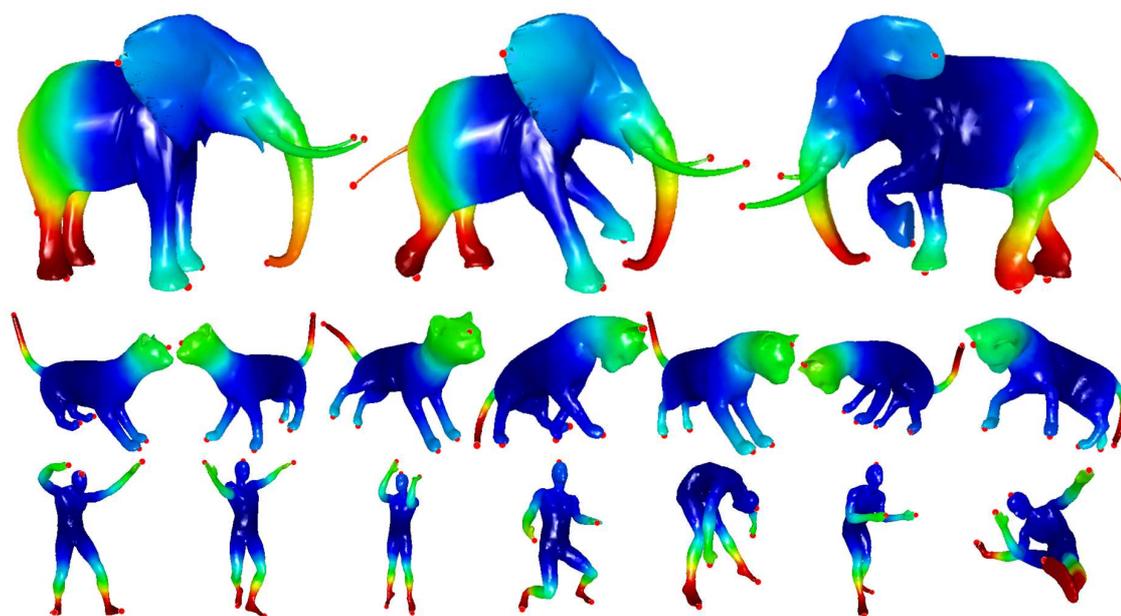


FIGURE 3.6 – Consistance de la méthode de détection des maxima locaux (points rouges) basée sur AGPS. Le nombre de points d'intérêts détectés est 10, 6 et 5 respectivement pour chaque pose du modèle d'Eléphant, de Chat et d'homme.

surface locale de la forme. De plus, même pour un faible nombre k de valeurs propres, l'AGPS est globale et, par conséquent, les points-clés sont principalement détectés sur les protubérances de la forme. Plus formellement, à mesure que nous augmentons ou diminuons le nombre de valeurs propres et de vecteurs propres considérés, le même nombre de points caractéristiques peut être observé sur la forme. A titre de remarque, nous avons étonnamment observé que l'AGPS ne nécessite pas un grand nombre k , comme détaillé dans la section 3.4.

3.3.2/ AGPS POUR LA RECHERCHE DE FORME

Dans cette section, notre objectif est d'introduire différentes mesures pour calculer la distance entre les distributions de formes. Une fois le calcul d'AGPS effectué, chaque point du maillage a un descripteur scalaire associé. Les valeurs de ces descripteurs construisent un sac de caractéristiques en tant que vecteur de n éléments. Ensuite, ce vecteur décrit les caractéristiques géométriques du maillage entier. Deuxièmement, il est organisé sous forme d'un histogramme qui stocke les occurrences de ses valeurs qui existent sur toute la forme. De plus, comme l'AGPS hérite du GPS, deux descripteurs AGPS entre un objet et une de ses transformations isométriques doivent être très similaires. Sur la base de ce fait, les deux vecteurs caractéristiques qui contiennent les descripteurs de deux formes sont comparés à travers une mesure de distance.

Soient M_1 et M_2 deux formes, $AGPS_1$ et $AGPS_2$ deux vecteurs de descripteurs. Si H_1 et H_2 représentent leurs histogrammes (distribution) ayant N cases (intervalles) et i l'index de chaque case dans l'histogramme. La comparaison entre les histogrammes est obtenue en utilisant trois métriques définies ci-dessous. La différence entre ces histogrammes est donnée par la corrélation d_C , la distance χ^2 (ou la distance du Khi-carré) et la distance de Bhattacharyya d_B comme indiquées dans les équations (3.2), (3.3) et

(3.4), respectivement.

$$d_C(H_1, H_2) = \frac{\sum_i (H_1(i) - \bar{H}_1)(H_2(i) - \bar{H}_2)}{\sqrt{\sum_i (H_1(i) - \bar{H}_1)^2 \sum_i (H_2(i) - \bar{H}_2)^2}}, \quad (3.2)$$

où $\bar{H}_k = 1/N \sum_j H_k(j)$ et N est le nombre total des cases dans l'histogramme. La valeur de $d_C(H_1, H_2)$ varie entre -1 et $+1$.

$$d_{\chi^2}(H_1, H_2) = \sqrt{\sum_{i=1}^N \frac{(H_1(i) - H_2(i))^2}{H_1(i) + H_2(i)}}, \quad (3.3)$$

$$d_B(H_1, H_2) = \sqrt{1 - \frac{1}{N \sqrt{\bar{H}_1 \bar{H}_2}} \sum_{i=1}^N \sqrt{H_1(i) \cdot H_2(i)}}. \quad (3.4)$$

Les métriques ci-dessus donnent des résultats numériques qui expriment à quel point deux histogrammes se correspondent. Pour la méthode de corrélation, plus la métrique est élevée, plus la correspondance est précise. Pour les deux autres mesures, lorsqu'elles sont normalisées, moins le résultat est élevé, meilleure est la correspondance.

Nous évaluons leur performance de récupération d'information basée sur les courbes de précision/rappel P/R . La précision, par définition, représente la proportion des éléments pertinents récupérés pour une requête donnée, tandis que le rappel correspond à la proportion des éléments pertinents sélectionnés qui ont été récupérés avec succès parmi tous les éléments pertinents sélectionnables. Étant donné A l'ensemble de tous les objets pertinents et B l'ensemble de tous les objets récupérés, la précision et le rappel sont définis comme :

$$\text{Précision} = \frac{|A \cap B|}{|B|}, \quad \text{Rappel} = \frac{|A \cap B|}{|A|}. \quad (3.5)$$

Notons que les deux mesures appartiennent à l'intervalle $[0, 1]$. Un score de précision parfait de 1.0 signifie que chaque résultat récupéré par une recherche était pertinent, alors qu'un score de rappel parfait de 1.0 signifie que tous les objets pertinents ont été récupérés par la recherche. Pour chaque requête, nous avons donc une courbe P/R . Dans ce chapitre, nous adoptons la courbe moyenne de P/R en prenant la moyenne des valeurs de P/R calculées pour toutes les requêtes. Les éléments quantitatifs (nombre de requêtes, de maillages, etc.) sont fournis dans la section suivante.

3.4/ EXPÉRIENCES ET RÉSULTATS

Dans cette section, nous présentons les résultats qualitatifs pour la classification des caractéristiques et les résultats quantitatifs pour la récupération de la forme. Notez que la construction de la matrice Laplacienne et le calcul des AGPS sur tous les points de maillage sont implantés en C++, alors que la résolution des problèmes propres est implantée sous l'environnement MATLAB© R2016b.

3.4.1/ RÉGLAGE DES PARAMÈTRES ET TEMPS DE CALCUL

Nous décrivons d'abord le comportement de l'algorithme avant de résumer les comparaisons des benchmarks. Pour la classification et la correspondance des formes, nous avons utilisé des modèles décimés — le nombre de sommets variait de quelques milliers à dix mille. En raison de la dépendance $1/\lambda^2$ des coordonnées AGPS, la distribution de la courbe dans le domaine d'AGPS est dominée par les fonctions propres de basse fréquence (correspondant aux plus petites valeurs propres). Parmi plusieurs avantages, l'utilisation de quelques valeurs propres est également un atout pour notre méthode. Dans la plupart des cas, pour calculer AGPS qui capture (ou représente) 98% de l'énergie totale du spectre, le nombre de fonctions propres nécessaires ne doit pas être inférieur à 8. Comme conséquence, les calculs de ce descripteur ont pris seulement entre 0.1 et 1 seconde sur un ordinateur portable Intel Centrino 2 GHz, tandis que le calcul de 250 vecteurs propres prenait entre 10 et 40 secondes. Le Tableau 3.2 montre le temps de calcul de la signature de point globale avancée par rapport à GPS pour certains modèles présentés dans ce chapitre. A titre de comparaison, nous citons deux exemples : GPS dans [23] et HKS dans [20] utilisent – au moins – 25 et 300 valeurs propres et vecteurs propres, respectivement. En d'autres termes, nous avons étudié à quel point notre descripteur est sensible au nombre limite inférieur de fonctions propres. Il est intéressant de visualiser comment l'énergie des fonctions propres mises à l'échelle est distribuée en fonction des valeurs propres. Cette distribution d'énergie s est calculée par :

$$s_j = \sum_{i=1}^n \sum_{j=1}^{k-1} \left(\frac{\phi_j(s_i)}{\lambda_j} \right)^2, \quad (3.6)$$

sachant que λ_0 est ignorée et $j = 1, \dots, k - 1$. Dans la Figure 3.7, nous présentons la distribution d'énergie d'AGPS en fonction du nombre des valeurs propres utilisées et nous analysons le choix de l'indice minimum relativement à sa valeur propre associée et de son impact sur le plongement AGPS. Nous observons que dans tous nos cas, les huit premières fonctions propres sont suffisantes pour capturer l'énergie d'AGPS jusqu'à au moins 98%, comme illustré dans la Figure 3.7. Quasiment dans tous les cas, nous avons observé que la meilleure performance, pour représenter une distribution géométrique similaire sur les mêmes formes, est obtenue fidèlement pour tout $\lambda \geq \lambda_{j=8}$. Ce résultat surprenant est aussi un atout de notre descripteur puisqu'il montre sa compacité de représentation.

TABLE 3.2 – Temps de calculs pour AGPS et GPS sur un ordinateur de 2 GHz, 2 Duo CPU et 3G RAM. Les troisième, quatrième, cinquième et sixième colonnes montrent le temps (en seconde) de construction de la matrice Laplacienne, la résolution des paires propres, le calcul de l'AGPS et du GPS à tous les points avec $k = 50$.

Modèle	#sommets	Matrice	Décomposition	AGPS	GPS
Araignée	9.5k	0.385	3.117	0.010	0.011
Centaure	9.4k	0.367	3.069	0.009	0.010
Femme	5.6k	0.214	2.421	0.006	0.006

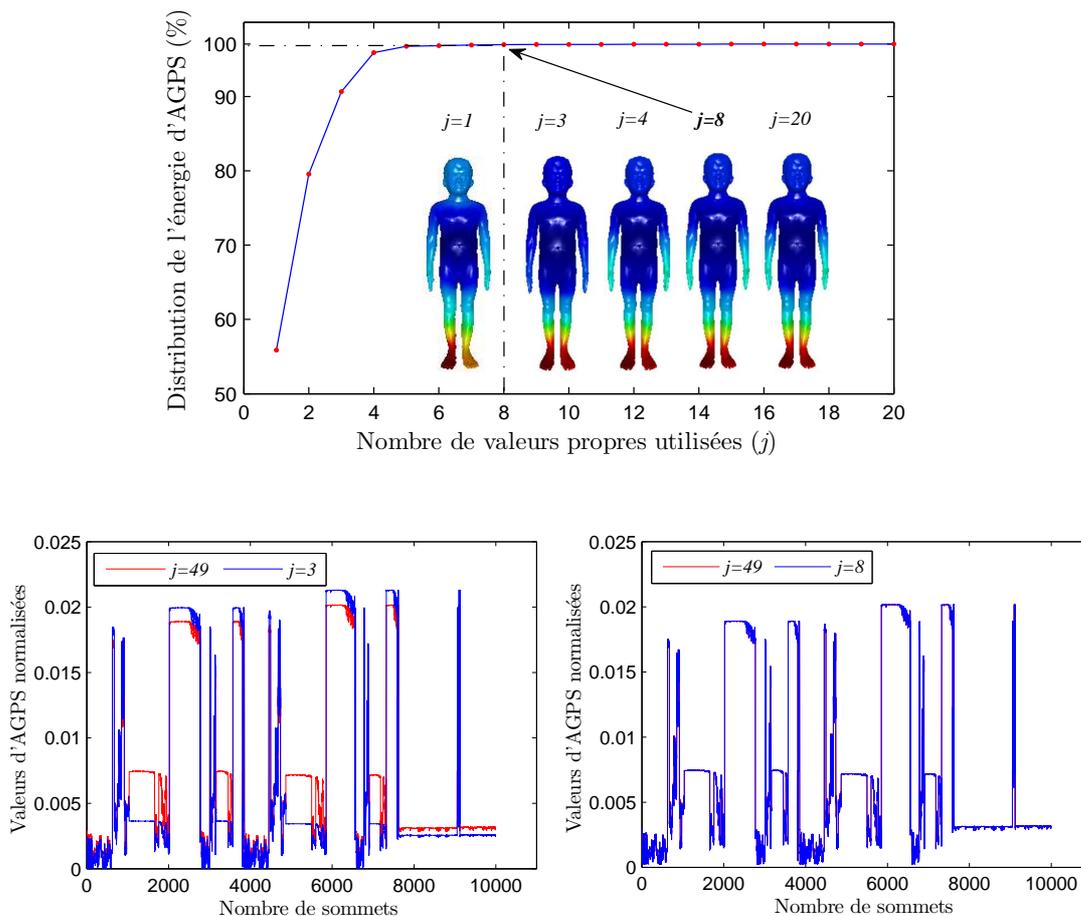


FIGURE 3.7 – En haut : la distribution de l'énergie en fonction du nombre de valeurs propres. Pour les $k = 50$ couples propres, le nombre j utilisé pour représenter les formes de gauche à droite est $j = 1, 3, 4, 8$ et $j = 20$, respectivement. Le premier point de la courbe qui atteint un seuil de 98% de l'énergie suggère que $j = 8$ comme nombre minimal de valeurs propres qui doit être utilisé pour une représentation consistante de forme sur le plan perceptuel. En bas : la comparaison entre l'AGPS normalisés pour un certain nombre de valeurs propres utilisées. On observe que l'écart entre les deux courbes devient marginal dès que $j = 8$.

Bases de données La performance du descripteur proposé est évaluée sur deux bases de données SHREC : nous utilisons SHREC-2012 [108] et SHREC-2015 [2]. Ce choix vient du fait que les différents descripteurs présentés dans ce manuscrit ont été déjà évalués sous ces deux bases de données. La première base de donnée contient 400 maillages triangulaires divisés en 20 classes, dont seulement 13 classes d'objets considérées étanches, c'est-à-dire sans trous, bords ou parties manquantes. Les maillages ont été collectés de certaines bases de données telles que [109, 76, 110]. La deuxième base de données contient 1200 maillages triangulaires répartis en 30 catégories d'objets, où chaque catégorie contient 24 objets avec des postures distinctes. Chaque forme dans la base de données a approximativement $n = 9400$ sommets. Cette base de données est également disponible sur le site : <http://www.icst.pku.edu.cn/zlian/shrec15-non-rigid/>. Des exemples de formes provenant de ces deux benchmarks sont présentés dans la Figure 3.8.

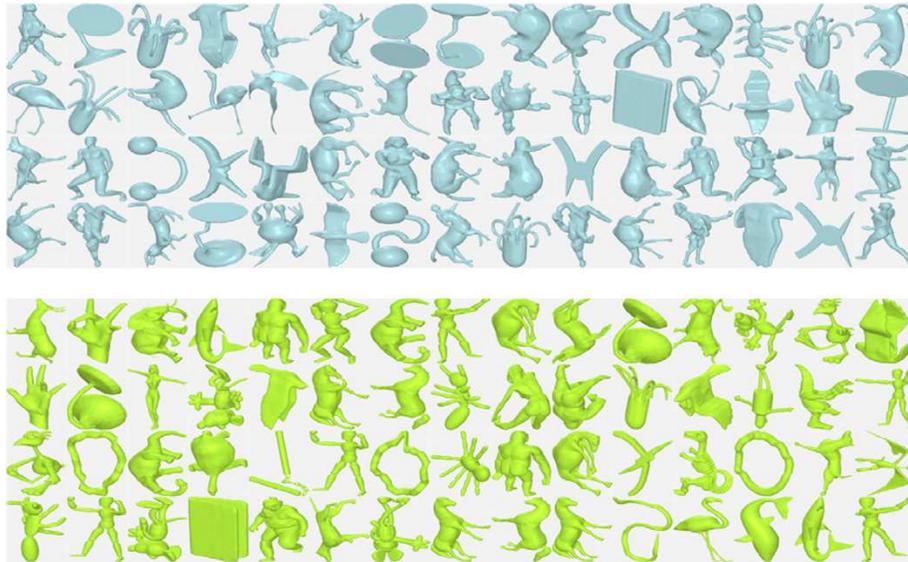


FIGURE 3.8 – Exemples de formes de SHREC-2012 (en haut) et SHREC-2015 (en bas).

3.4.2/ CLASSIFICATION DES CARACTÉRISTIQUES

Parce que nous n'identifions seulement que quelques points d'intérêt sur chaque maillage, la complexité calculatoire de cette méthode est assez faible. Dans ce contexte, nous utilisons AGPS pour trouver toutes les structures géométriques similaires dans la même forme. La partie gauche de la Figure 3.9 montre les points saillants détectés sur 4 poses différentes d'un même modèle, tandis que la partie droite montre la projection de 52 points caractéristiques trouvés sur les mêmes formes et représentés sur le plan 2D. Remarquons que l'AGPS joue un rôle vital pour différencier et distinguer les différentes classes d'intérêts, telles que les pieds, les mains et la tête. Dans cet exemple, le nombre de tous ces points et la représentation de la distribution ne sont consistants que pour les cinq plus petites valeurs propres ou plus. Ceci illustre que notre fonction AGPS n'est pas seulement invariable mais aussi facile à comparer et peu coûteuse à stocker.



FIGURE 3.9 – A gauche : les points caractéristiques détectés sur quatre poses du modèle de femme. A droite : Les valeurs normalisées des points caractéristiques basées sur leur AGPS tracées en fonction de leur indice. La couleur de chaque point projeté sur le plan 2D correspond à la couleur du point détecté sur la forme associée.

3.4.3/ CONSISTANCE D'AGPS FACE AU CHANGEMENT TOPOLOGIQUE

Nous analysons la performance d'AGPS, c'est-à-dire sa capacité à détecter et localiser précisément les maxima locaux, sur des modèles qui subissent des changements topologiques, comme le montre la Figure 3.10. Par exemple, la main qui est à droite a un lien qui relie deux doigts. Le sportif qui est à droite a aussi deux liens courts qui relient sa main droite à son visage, et sa main gauche à sa hanche. Malgré les changements de topologie qui conduisent à une forte modification dans la matrice Laplacienne, nos résultats de représentation de la distribution géométrique restent très consistants. Le résultat expérimental sur un modèle topologiquement modifié montre que notre méthode est cohérente sur le plan perceptuel et que le mappage vectoriel d'AGPS est robuste aux changements topologiques. A titre de remarque, nous rajoutons que les taux d'échantillonnage sont également légèrement différents. Dans la même figure, les formes en haut à gauche et en haut à droite ont respectivement 7242 et 7628 sommets, alors que les deux formes qui se situent en bas ont 1505 sommets.

3.4.4/ APPARIEMENT ET LA RECHERCHE GLOBALE DE FORMES

Généralement, les descripteurs de formes globaux nécessitent la géométrie complète de la surface de forme 3D pour encoder ses informations ; cette forme 3D peut être donc recherchée globalement. Comme nous l'avons vu précédemment, notre descripteur, même en utilisant une représentation très compacte, conduit à une identification et à des appariements globaux plus efficaces.

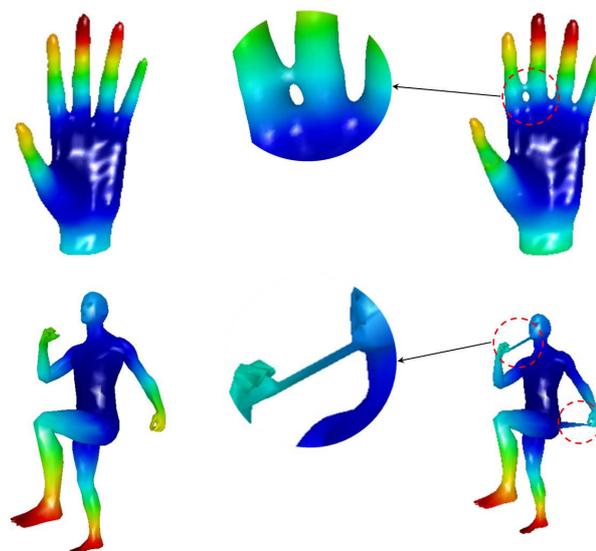


FIGURE 3.10 – Résultat d'AGPS contre le changement topologique. La figure de gauche montre les modèles de référence. Les courts-circuits topologiques sont rajoutés dans les modèles à droite.

3.4.4.1/ EXPÉRIENCES SUR SHREC-2012 ET SHREC-2015

La performance du descripteur proposé est évaluée sur deux benchmarks de référence tout en combinant la base de données SHREC-2012, qui est utilisée à la section 3.4.2, avec la base de données SHREC-2015. Ensuite, nous avons extrait arbitrairement 8 formes par classe et de chaque catégorie. Chaque forme est comparée aux autres modèles qui existent dans la base de données combinée pour choisir les meilleurs correspondants. Puisque notre descripteur extrait des caractéristiques géométriques spectrales stables et distinctives, la tâche de récupération de formes est très simple : nous comparons les scores de la correspondance moyenne des trois mesures mentionnées à la section 3.3.2 dans toute la base de données, puis nous sélectionnons les meilleurs résultats. La Figure 3.11 illustre quelques résultats démontrant la stabilité, la fiabilité et la précision de notre approche en utilisant AGPS sur l'ensemble de la base de données combinée. Pour valider davantage notre méthode, un exemple des 6 meilleurs résultats retournés, pour une requête complète de la Lunette et du Poulpe par la méthode AGPS, GPS, HKS et HMS, est présenté dans le Tableau 3.3. Comme on peut le voir, l'approche proposée renvoie des résultats cohérents, alors que les méthodes GPS, HKS et HMS fournissent parfois des résultats incohérents, voire parfois médiocres pour certains cas.

Le Tableau 3.4 montre que le descripteur proposé fournit aussi des résultats d'appariement corrects, où une valeur élevée (affichée en gras) de la mesure de dissimilarité d_c indique que les objets de la même catégorie sont plus similaires. En outre, pour les mêmes ensembles de données, notre méthode surpasse significativement le meilleur résultat rapporté pour HKS [1], la distribution de forme [111], D2 [94], GPS et la machine de

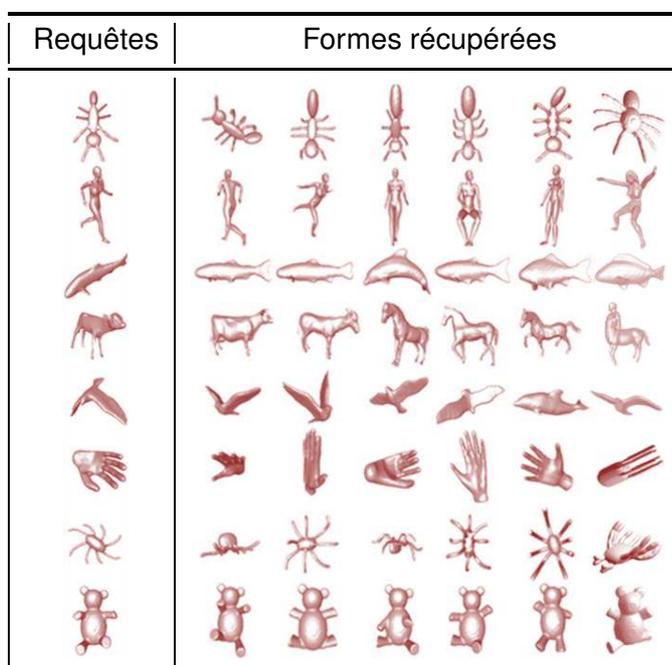


FIGURE 3.11 – Exemples de récupération de formes utilisant le descripteur AGPS comme vecteur de caractéristiques. Les formes 3D dans la première colonne sont des requêtes d'entrée, et celles de droite sont les six premiers résultats récupérés pour chaque requête. Les modèles récupérés sont classés de gauche à droite en fonction de l'ordre croissant de dissimilarité.

TABLE 3.3 – Résultats de recherche pour le modèle de la Lunette et du Poulpe utilisant notre algorithme, GPS, HKS et HMS. La couleur jaune indique les récupérations correctes.

Formes de référence							
							
Formes récupérées							
AGPS	GPS	HKS	HMS	AGPS	GPS	HKS	HMS
							
							
							
							
							
							

TABLE 3.4 – Résultats de correspondances AGPS. Chaque objet est comparé à tous les autres objets de la base de données SHREC-2012 et SHREC-2015. Chaque cellule montre la mesure de similarité moyenne $d_c(H_1, H_2)$ entre deux objets.

								
	0.896	0.359	0.325	0.511	0.313	0.516	0.350	0.507
	0.376	0.905	0.691	0.402	0.833	0.795	0.893	0.831
	0.407	0.856	0.982	0.438	0.925	0.850	0.916	0.910
	0.628	0.411	0.487	0.945	0.487	0.475	0.440	0.418
	0.539	0.863	0.911	0.496	0.939	0.834	0.887	0.908
	0.576	0.818	0.815	0.491	0.772	0.827	0.819	0.808
	0.424	0.915	0.884	0.451	0.964	0.820	0.989	0.948
	0.563	0.887	0.912	0.692	0.899	0.879	0.945	0.977

Boltzmann à cercle convolutionnel restreint (CCRBM) [112]. La Figure 3.12 montre la performance du descripteur AGPS et compare la moyenne des courbes P/R . En se basant sur les courbes de cette figure, nous pouvons clairement voir que la précision d'AGPS surpasse tous les descripteurs, hormis CCRBM qui est devenu meilleur pour tout rappel $R > 0.7$. Ceci signifie qu'à partir de cette valeur, CCRBM commence à retourner beaucoup plus d'objets pertinents à la requête qu'AGPS.

Ensuite, quatre critères de performance, soit le plus proche voisin (NN), le premier niveau (FT), le deuxième niveau (ST) et le gain cumulatif réduit (DCG), sont utilisés pour évaluer

le descripteur AGPS sous SHREC-2015 pour la tâche de récupération de forme globale. La comparaison est réalisée contre plusieurs approches de référence [2, 113], y compris le SNU, HKS, SA, WKS, multi-feature, SG, FVF-HKS, TSASR, SID, et EDBCF-AV. Les résultats sont rapportés dans le Tableau 3.5. AGPS obtient de meilleurs résultats que ces méthodes. Par exemple, AGPS surpasse l'approche SG de 4,2% dans NN, 11,8% dans FT, 13,5% dans ST et 6,4% dans DCG. Cette meilleure performance est consistante avec toutes les métriques d'évaluation de la récupération de formes.

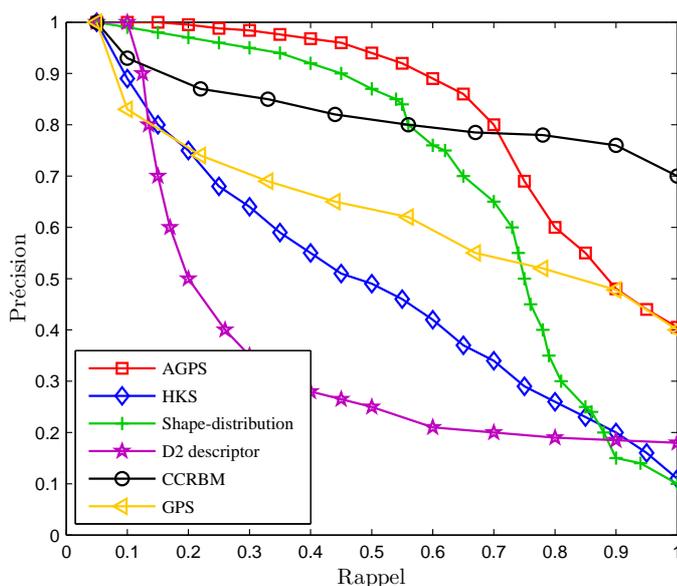


FIGURE 3.12 – Courbes précision-rappel pour la comparaison des descripteurs sous la base de données combinée.

TABLE 3.5 – Comparaison des résultats de récupération par notre méthode (dernière rangée) avec l'état de l'art sur l'ensemble de la base de données combinée. Les chiffres en gras indiquent les meilleurs résultats de récupération.

Méthodes	NN	FT	ST	DCG
SNU	0.898	0.563	0.669	0.832
HKS	0.065	0.063	0.124	0.391
SA	0.065	0.067	0.128	0.393
WKS	0.134	0.074	0.137	0.408
Multi-feature	0.450	0.186	0.262	0.525
SG	0.936	0.668	0.736	0.875
FVF-HKS	0.960	0.725	0.809	0.913
TSAR	0.813	0.463	0.544	0.749
SID	0.795	0.484	0.614	0.778
EDBCF-AV	0.975	0.769	0.868	0.935
AGPS	0.978	0.786	0.871	0.939

3.4.4.2/ EXPÉRIENCES SUR LA BASE DE DONNÉES MCGILL

Dans cette section, nous avons également testé la performance du descripteur proposé sur une base de données couramment utilisée de formes 3D articulées nommé McGill [110]. Cette base de données a été la première référence pour la recherche d'objets par forme clef, ainsi pour l'évaluation de la performance des descripteurs contre les articulations de formes. Ce référentiel de formes 3D est disponible publiquement et contient 255 objets avec des parties articulées qui sont divisées en 10 catégories. Des exemples de modèles sont montrés sur la Figure 3.13. L'ensemble de données McGill est disponible sous forme de maillage triangulaire et de forme voxelisée, une représentation que nous voyons rarement de nos jours.

Le Tableau 3.6 montre que l'AGPS produit des résultats d'appariement corrects, où une valeur élevée (également affichée en gras) de la mesure de la corrélation d_c indique que les objets appartenant à la même classe sont plus similaires. De plus, dans notre méthode AGPS proposée, nous extrayons aléatoirement 7 formes par classe de chaque catégorie. En fait, chaque modèle est comparé aux autres formes dans la base de données McGill afin de déterminer les meilleurs appariements.

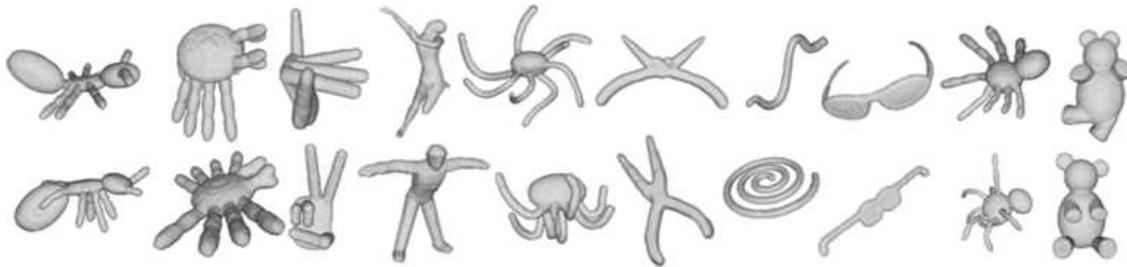


FIGURE 3.13 – Exemples de formes 3D à partir de la base de données McGill. Seules deux formes articulées sont représentées dans chacune des 10 classes d'objets.

TABLE 3.6 – Résultats de correspondances AGPS. Chaque objet est comparé à tous les autres objets de la base de données McGill. Chaque cellule montre la mesure de similarité moyenne $d_c(H_1, H_2)$ entre deux objets.

							
	0.889	0.884	0.813	0.811	0.857	0.875	0.820
	0.882	0.889	0.842	0.840	0.875	0.857	0.880
	0.810	0.882	0.902	0.888	0.889	0.852	0.867
	0.802	0.837	0.887	0.995	0.887	0.854	0.877
	0.852	0.877	0.887	0.886	0.992	0.870	0.888
	0.876	0.866	0.837	0.844	0.867	0.994	0.885
	0.818	0.886	0.865	0.874	0.887	0.874	0.987

Les méthodes que nous utilisons dans nos comparaisons sur les parties articulées du banc d'essai McGill sont : CCRBM, HKS, shapeDNA [24], image de spin intrinsèque (ISI) [114], descripteur de champ lumineux (LFD) [18] et le descripteur de moment (Moment) [115]. Les courbes P/R obtenues par ces méthodes sont représentées sur la Figure 3.14. Comme le montre cette figure, le descripteur AGPS proposé obtient le meilleur résultat de récupération, ainsi que sa précision et son efficacité sont toujours garanties parmi toutes les méthodes de comparaison jusqu'à un rappel $R \approx 0.8$. En revanche, par rapport à notre méthode, CCRBM est devenue légèrement meilleure dès que $R \gtrsim 0.8$. Cela signifie qu'à ce stade, AGPS commence à manquer beaucoup plus d'objets pertinents que CCRBM.

De nouveau, les quatre critères de performance, c'est-à-dire NN, FT, ST et DCG sont utilisés pour évaluer ces méthodes. Le Tableau 3.7 illustre les performances de récupération de ces méthodes. Comme on peut le voir dans ce tableau, comparé aux méthodes de l'état de l'art [18, 116, 118, 119, 117], la méthode AGPS proposée peut atteindre une meilleure performance sur les quatre critères, à l'exception de la métrique ST, où notre méthode proposée est légèrement inférieure à celui de la BF-SIFT [117]. Les déformations importantes non rigides des objets 3D de la base de données McGill constituent un

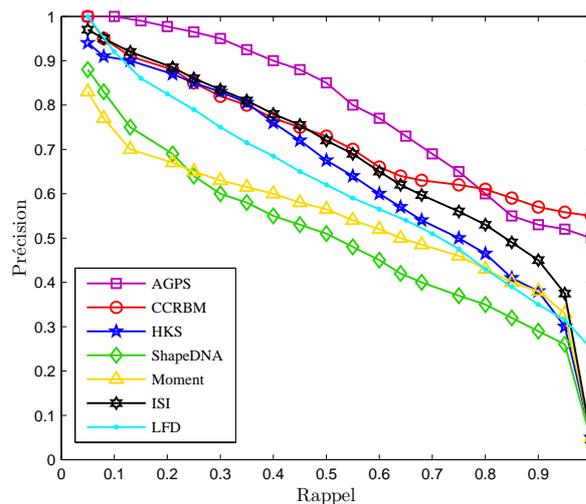


FIGURE 3.14 – Courbes P/R de notre méthode (AGPS) et six autres approches évaluées pour les parties articulées de la base de données McGill [112].

TABLE 3.7 – Comparaison des résultats de récupération de notre méthode (première rangée) avec l'état de l'art sur la base de données McGill. Les chiffres en gras indiquent les meilleurs résultats de récupération.

Méthodes	NN	FT	ST	DCG
AGPS	0.978	0.775	0.861	0.939
Covariance method [116]	0.977	0.732	0.818	0.937
BF-SIFT [117]	0.973	0.746	0.870	0.937
PCA based VLAT [118]	0.969	0.658	0.781	0.894
Hybrid BOW [119]	0.957	0.635	0.790	0.886
LFD [18]	0.910	0.528	0.697	0.837

défi que notre descripteur doit surmonter. Néanmoins, grâce à la capacité de distinction d'objets, AGPS est toujours robuste aux déformations non rigides.

3.4.5/ ÉVALUATION DE LA DÉTECTION DE POINTS SAILLANTS PAR AGPS

Il existe de nombreuses façons que les chercheurs ont utilisé pour évaluer et démontrer quantitativement le succès de leurs algorithmes de détection de point d'intérêt. En ce qui concerne la vérité terrain (*ground truth*) générée par des humains, notre schéma d'évaluation est basé sur deux mesures de performance : l'erreur de faux négatifs (FNE) et l'erreur de faux positifs (FPE). En outre, AGPS est comparé à cinq techniques de détection de point d'intérêt, à savoir, Mesh saliency [101], Saliient points [103], 3D-Harris [104], 3D-SIFT [105] et SD-corners [102], et qui ont été à leur tour comparées entre elles en utilisant les mêmes critères de performance. Pour une description plus détaillée sur ces techniques de détection de points d'intérêts, nous renvoyons le lecteur à [120] et [100].

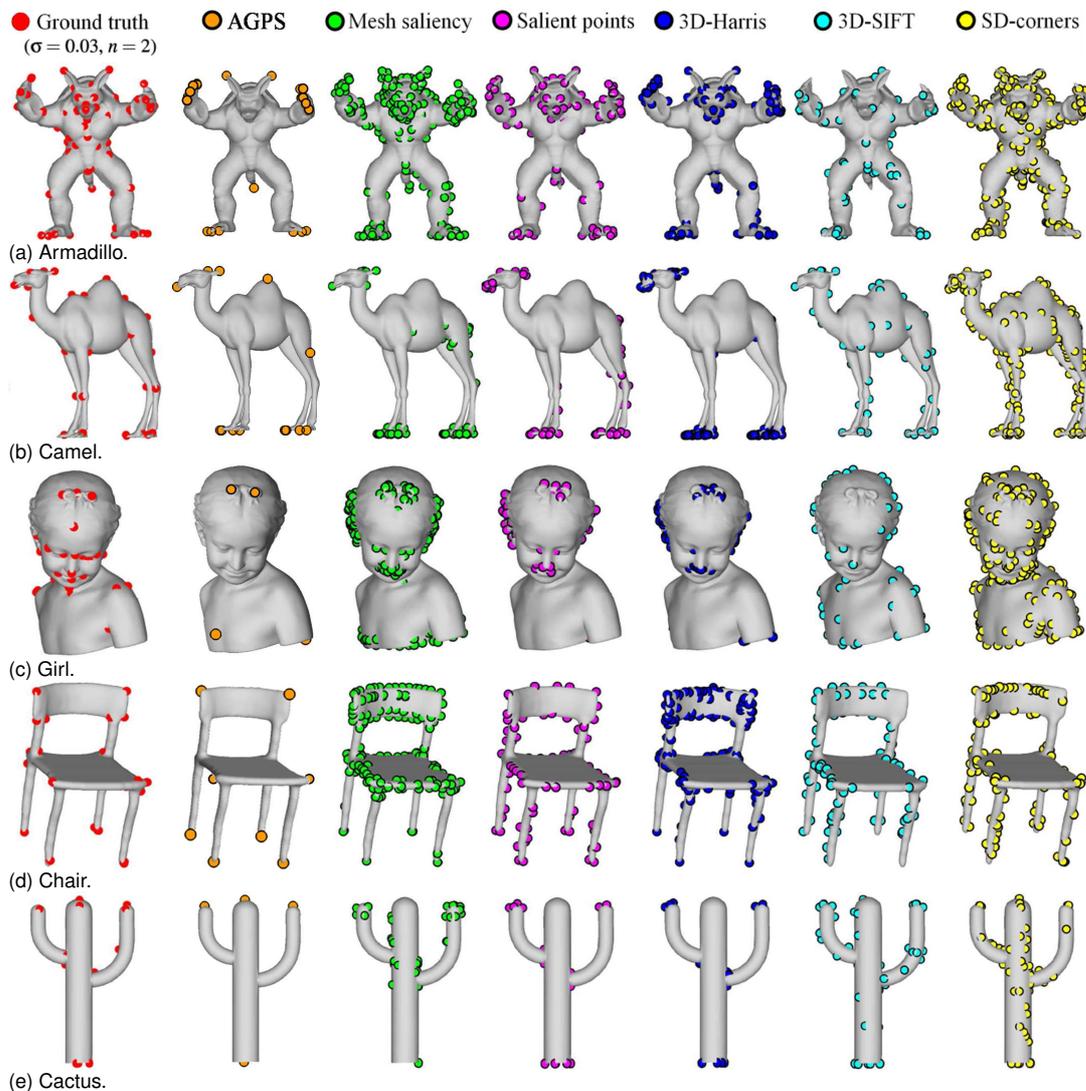


FIGURE 3.15 – Détection de points saillants par plusieurs approches. De gauche à droite : vérité terrain, AGPS, Mesh Saliency, Saliient points, 3D-Harris, 3D-SIFT et SD-corners.

La Figure 3.15 expose cinq modèles qui sont choisis à partir de la base de données B [100]. Cet ensemble contient 43 modèles. La première colonne montre les points du relevé de terrain (points rouges) marqués par différents marqueurs (16 sujets des humains) et obtenus en réglant les paramètres $\sigma = 0.03$ et $n = 2$. Pour faire une comparaison équitable, nous avons utilisé les mêmes valeurs de ces paramètres qui ont été également employés dans les méthodes de référence. Les six dernières colonnes fournissent une comparaison perceptuelle des points-clés détectés en utilisant six techniques de détection de points d'intérêt. Similairement à Mesh saliency, le descripteur SD-corners tend à détecter un grand nombre de points d'intérêt plus que ce que les utilisateurs humains ont marqué. Le descripteur 3D-SIFT capte des points d'intérêt à grande échelle (la pointe du cactus, le dos du chameau), cependant, il ne localise pas les points caractéristiques plus fins comme les quatre autres approches (doigts, queue et pointes d'oreille du modèle Armadillo). En revanche, notre technique se comporte différemment. Comme indiqué dans la section 3.3.1, les maxima locaux d'AGPS sont considérés comme des points caractéristiques recueillis sur les formes ; le descripteur renvoie donc quelques points dont la plupart correspondent aux extrémités saillantes des modèles. Ceci, par exemple, est assez apparent pour les formes d'Armadillo et du Chair (voir Figure 3.15 (a) et (d)).

La Figure 3.16 montre des graphiques FNE et FPE en fonction de la tolérance d'erreur de localisation r pour AGPS et les cinq autres algorithmes de détection de points d'intérêts mentionnés précédemment. Les graphiques de ces figures sont moyennés sur tous les modèles de la base de données. FNE chute rapidement avec la méthode de Mesh saliency et donne le plus petit taux d'erreur jusqu'à $r = 0.07$. En alternant avec la méthode de Mesh saliency à environ $r = 0.07$, la méthode SD-corners atteint le plus bas niveau de FNE à $r = 0.12$, ce qui indique un taux de détection élevé avec une précision de localisation élevée.

Notre algorithme présente un comportement différent par rapport aux cinq autres algorithmes. En effet, la méthode AGPS croise 3D-SIFT à $r = 0.03$ et donne, pour les autres valeurs de r , la plus haute FNE parmi toutes les autres méthodes, car elle détecte moins de points que les sujets humains marquent habituellement. Cependant, presque tous les points captés par le descripteur AGPS correspondent à un point d'intérêt du relevé de

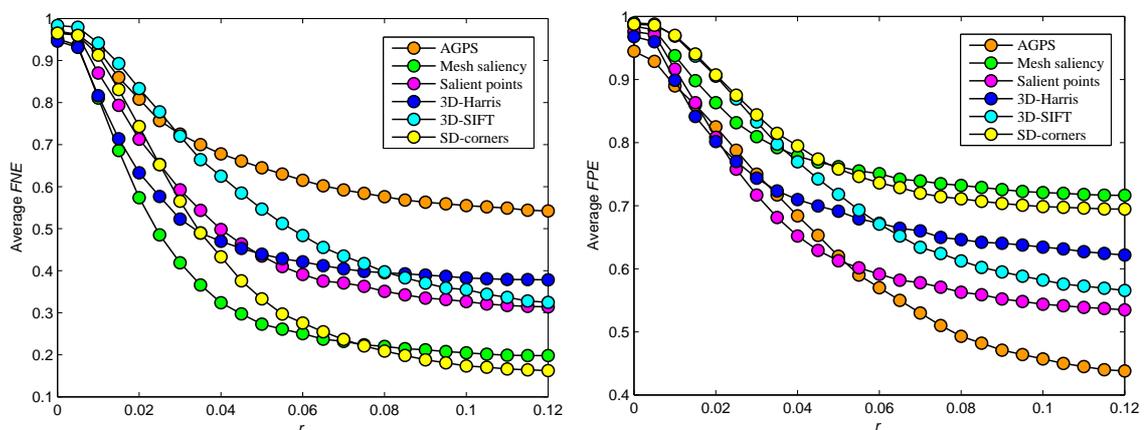


FIGURE 3.16 – Évaluation de la performance de six descripteurs sur l'ensemble B de la base de données (43 modèles, 16 sujets). Erreur de faux négatifs (côté gauche) et erreur de faux positifs (côté droit) de tous les algorithmes. Relevé de terrain obtenu avec $\sigma = 0.03$ et $n = 2$.

terrain pour tout $r < 0.052$, ce qui se retrouve dans la figure à partir de sa courbe FPE. Ensuite, FPE devient le plus bas pour la méthode AGPS en coupant la courbe de la méthode Saliens points à environ une tolérance d'erreur de localisation $r = 0.052$ ainsi que par rapport aux quatre autres algorithmes ; signifiant que le descripteur AGPS recouvre peu les points-clés autres que ceux qui sont habituellement indiqués comme points caractéristiques par des sujets humains.

3.5/ CONCLUSIONS

Nous avons proposé un nouveau descripteur basé sur les fonctions propres de l'opérateur LB. Le descripteur est basé sur la géométrie de la surface, en tenant compte des caractéristiques locales et globales. En d'autres termes, l'AGPS peut être utilisé pour déterminer des caractéristiques locales sur le maillage de la forme, comme par exemple les points saillants, cependant, en considérant l'ensemble des valeurs AGPS pour tous les points du maillage, nous obtenons un descripteur global. Le descripteur AGPS est invariant par changement de poses, de la position, de l'orientation et de l'échelle ; il reste robuste aux variations de triangulations (nombre de sommets, connectivité), et permet de décrire et de caractériser localement et globalement la forme. En outre, il présente l'avantage d'être compact, rapide et facile à mettre en oeuvre. Nous avons évalué notre approche sur une variété des bases de données et d'objets 3D. Les essais montrent que le descripteur AGPS est robuste, efficace et nettement plus performant que des descripteurs de forme 3D pré-existants.

SIGNATURE OPTIMISÉE DU NOYAU D'ONDE (OWKS)

Dans le cadre de la recherche de forme dans une base de données d'objets 3D, nous pouvons également réfléchir, non pas seulement au descripteur comme l'AGPS, mais également à optimiser un descripteur pour encore mieux discriminer les classes d'objets. L'AGPS ayant très peu de paramètres ajustables (hormi le nombre de vecteurs propres, et encore, il n'en faut que quelques uns pour que cela tourne), nous nous intéressons à une des signatures les plus efficaces (WKS) que nous allons chercher à optimiser pour une base d'objets donnée.

Dans ce chapitre, nous présentons une signature du noyau d'onde optimisée (OWKS) utilisant un algorithme d'optimisation par essaim de particules modifié (MPSO). Le paramètre de variance joue un rôle très important dans ce noyau. Afin d'éviter le choix purement arbitraire des paramètres internes de la signature du noyau d'onde classique (WKS), nous présentons un cadre complet de ce descripteur en quatre étapes. Notre objectif est de montrer la façon d'améliorer WKS en agissant sur son paramètre de variance. L'avantage de la méthode améliorée provient de l'ajustement du paramètre de variance en utilisant MPSO et de la sélection du premier vecteur de l'OWKS construit à sa première échelle d'énergie, donnant ainsi une meilleure précision d'appariement et de récupération de formes 3D déformables. Le choix spécial de ce vecteur est pour renforcer la stabilité de la méthode d'extraction des points saillants des maillages 3D. Les résultats expérimentaux démontrent l'efficacité de notre approche de classification et de recherche de formes par rapport aux méthodes de l'état de l'art.

4.1/ INTRODUCTION

Avec l'avancement des technologies qui produisent et manipulent des modèles 3D, la classification des modèles 3D est devenue cruciale dans différents domaines d'applications nécessitant d'identifier des modèles dans une large collection d'objets 3D. La disponibilité et l'utilisation généralisée de ces bases de données, accouplées à la nécessité d'exploiter leurs modèles 3D, ont suscité le besoin de classer, d'organiser et de rechercher ces vastes répertoires, et de récupérer efficacement les sélections les plus pertinentes. Le problème de recherche et de classification des formes a fait l'objet d'études approfondies dans la littérature scientifique, allant des enquêtes exhaustives présentées dans [121, 122, 123, 124] à des bases de données 3D comparables telles que la base

de modèles articulés McGill (*McGill shape benchmark*) [110], et les bases de données SHREC-2011 [1], SHREC-2012 [108] et SHREC-2015 [2].

Avec la présence de très larges bases de données, la correspondance de formes est devenue un domaine de recherche très actif au cours des ces dernières décennies. Les travaux de recherches scientifiques dans ce domaine ont mené à la création de plusieurs techniques pour la caractérisation de formes, à savoir les descripteurs de formes. Parmi la grande diversité des techniques, certains développements théoriques récents sur l'utilisation du spectre de l'opérateur de Laplace-Beltrami pour les maillages 3D ont conduit à une très large gamme d'applications, allant de l'appariement (ou auto-appariement), de la segmentation et de la classification pour les objets rigides et non rigides. En outre, les méthodes spectrales font l'objet d'une attention accrue pour leurs propriétés avantageuses, ce qui nous ouvre les horizons à la construction d'un descripteur spectral perfectionné dédié à une tâche spécifique.

Dans ce chapitre, nous adoptons une approche basée sur le spectre de l'opérateur LB. De plus, nous proposons une signature de forme optimisée non seulement invariante aux isométries et robuste aux faibles déformations quasi isométriques, mais aussi compacte et facile à calculer, qui surpasse et remplace l'ancien et donne lieu à une correspondance sensiblement plus précise en utilisant un algorithme d'optimisation métaheuristique.

4.1.1/ TRAVAUX ANTÉRIEURS

De nombreux descripteurs sont construits à partir de la décomposition spectrale de l'opérateur de Laplace-Beltrami (LB) associé à la forme [81, 20, 21, 25]. Ces descripteurs accomplissent des performances de pointe dans de nombreuses tâches d'analyse de formes. Par ailleurs, pour construire une signature spectrale, il est nécessaire d'appliquer un filtre aux spectres de forme (valeurs propres de l'opérateur LB) de manière à pouvoir créer un vecteur de caractéristiques pour chaque point de la forme. Chaque élément du vecteur caractéristique est une combinaison de différentes fréquences des fonctions propres spectrales. Ces filtres doivent être optimisés pour faire face aux bruits et aux déformations de la forme. Les signatures les plus couramment utilisées et connues sont HKS et WKS.

Rappelons que la signature du noyau de la chaleur [20] a été appliquée pour rechercher des formes dans de nombreuses autres occasions, telles que proposées par Bronstein *et al.*, Bronstein et Kokkinos, Litman *et al.* et Ovsjanikov *et al.*, respectivement, dans [13], [74], [92] et [125]. HKS applique des filtres passe-bas au spectre de forme, illustrés sur la Figure 4.1, en acquérant principalement des informations globales de forme.

En revanche, la signature du noyau d'onde (WKS) [21] est fortement dominée par l'information des hautes fréquences, qui correspondent aux propriétés locales d'une forme. En effet, la WKS est calculée à partir d'une collection de filtres passe-bande appliqués sur le spectre de forme, comme le montre la Figure 4.2. Malgré sa fonctionnalité de correspondance, telle que proposée initialement, elle peut également être appliquée à la recherche de forme non rigide. Cependant, la capacité du descripteur WKS pour la classification des caractéristiques et l'exactitude des correspondances entre les formes dépend de ses paramètres. Outre le fait que les paramètres affectent les caractéristiques du descripteur, ils sont également liés à la sensibilité de la signature aux propriétés globales ou locales autour d'un point d'intérêt [89].

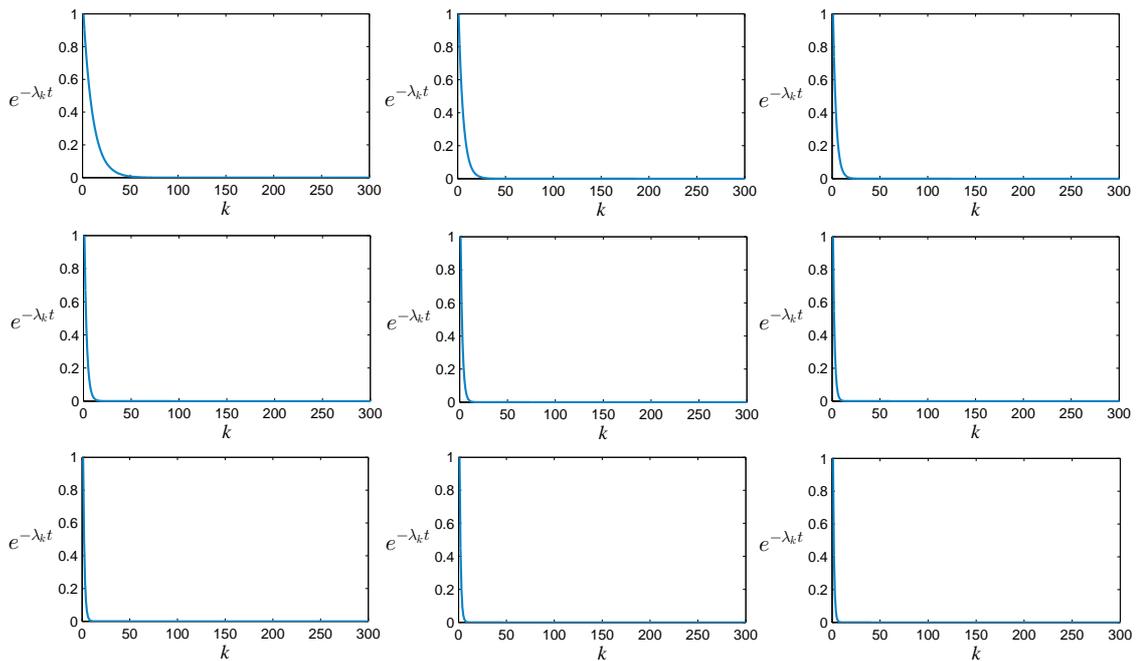


FIGURE 4.1 – Illustration des filtres passe-bas ($e^{-\lambda_k t}$) du HKS appliqués au spectre de forme. Nous montrons les fréquences 20, 30, 40, 50, 60, 70, 80, 90 et 100, respectivement.

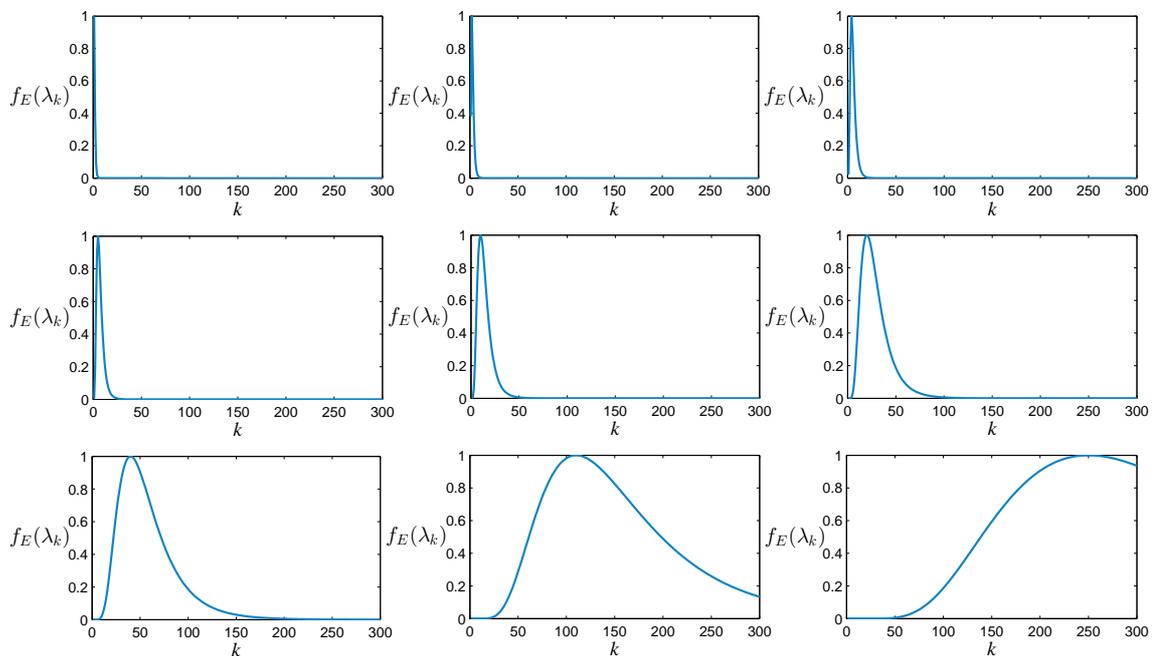


FIGURE 4.2 – Illustration des filtres passe-bande ($f_E(\lambda_k)$) du WKS appliqués au spectre de forme. Nous montrons les fréquences 20, 30, 40, 50, 60, 70, 80, 90 et 100, respectivement.

Nous avons effectué une analyse des descripteurs locaux cités ci-dessus pour comprendre les raisons pour lesquelles ces signatures permettent de rechercher de manière satisfaisante des modèles à partir de bases de données non rigides. Néanmoins, nous étudions les moyens d'améliorer les performances de recherche de ces descripteurs. En analysant les filtres du HKS et WKS (Figure 4.1 et 4.2), nous pouvons voir que WKS rassemble plus d'informations sur le spectre de forme dans les descripteurs. Cette dernière obtient également de meilleurs scores de recherche par rapport aux HKS et SIHKS [21]. Pour ces raisons, nous étudions les moyens d'améliorer WKS pour mieux décrire les caractéristiques de recherche de forme 3D non rigide.

Les descripteurs d'objets 3D doivent être robustes et discriminants pour pouvoir analyser, représenter, et ensuite distinguer les formes. Tous les descripteurs ont des paramètres internes qu'il faut régler de manière cohérente avec les données à traiter et en fonction de la tâche à effectuer. Nous pouvons citer à titre indicatif les paramètres temps t et variance σ respectivement pour HKS et WKS. Ces paramètres sont ajustés manuellement et empiriquement en fonction de l'application, ce qui en influence de facto le comportement. Pour cette raison, plusieurs méthodes d'optimisations stochastiques telles que celle par algorithme génétique (GA) [126], l'optimisation par essaim de particules (PSO) [127, 128], l'optimisation des colonies de fourmis (ACO) [129] et l'algorithme de saut de grenouille mélangé (SFLA) [130] ont été utilisées. Un algorithme stochastique populaire et très largement utilisé et étudié par rapport aux autres paradigmes en intelligence artificielle est PSO, qui a été appliqué à des problèmes d'optimisation complexes. Par la suite, il a été appelé PSO standard (SPSO). SPSO est un algorithme évolutionnaire basé sur l'intelligence de l'essaim qui a été inspiré par le comportement alimentaire des oiseaux. Dernièrement, une méthode d'optimisation par essaim de particules modifiée (MPSO) [131, 132] a été présentée. Cette méthode a obtenu une attention croissante en raison de sa mise en œuvre simple, de la précision de la solution et de l'excellence de ses performances. De plus, et contrairement à SPSO et à GA, la variante MPSO présente des qualités en termes de fiabilité et de la vitesse de convergence [132] puisqu'elle utilise un poids d'inertie adaptatif. Généralement, ce poids d'inertie est un paramètre utilisé pour contrôler la vitesse des particules. Le poids d'inertie adaptative est proposé pour équilibrer rationnellement les capacités d'exploration globale et d'exploitation locale pour l'optimisation des essaims de particules, ou autrement dit, il permet d'améliorer la capacité du MPSO à éviter autant que possible les optimums locaux. L'algorithme MPSO peut être appliqué dans plusieurs domaines tels que l'optimisation combinatoire, l'apprentissage des réseaux de neurones, le contrôle de système flou et la reconnaissance de formes.

4.1.2/ CONTRIBUTIONS

Nos principales contributions dans ce chapitre peuvent être résumées comme suit :

- (i) Nous proposons une signature du noyau d'onde optimisée (OWKS) afin d'améliorer : (1) les résultats de classification et obtenir des points caractéristiques fiables à travers une collection de formes ; (2) le taux de précision et de récupération de formes à travers une forme requête (3) la robustesse face aux changements de postures qu'une forme puisse subir.
- (ii) Dans notre cas, la signature OWKS est calculée à l'aide de l'algorithme d'optimisation MPSO, pour rechercher et sélectionner la valeur optimisée du paramètre de variance pour WKS. Autrement dit, l'idée principale de notre méthode présen-

tée dans ce chapitre consiste à optimiser de manière stochastique le descripteur WKS pour qu'il soit le plus discriminant possible. La fonction objectif (ainsi appelée fonction d'adaptation ou fonction d'évaluation, en anglais *fitness*) à minimiser est l'erreur quadratique moyenne (MSE). LOWKS est ensuite utilisée comme descripteur de forme local pour la classification, la reconnaissance et l'appariement de formes et de leurs points d'intérêts. Nous observons, comme l'illustre la Figure 4.3, que l'écart entre deux signatures d'un même point, placé sur deux formes 3D quasi isométriques, devient marginal dès que nous utilisons OWKS. Notons que tout en restant quasiment stable sous les perturbations et robuste aux déformations de la forme, la signature OWKS reste informative sur l'échelle d'énergie e , c'est-à-dire qu'elle contienne toutes les informations sur la géométrie intrinsèque de la forme.

Le reste du chapitre est structuré comme suit. Après un rappel du descripteur WKS et de l'algorithme d'optimisation par essaim de particules modifié dans la section 4.2, nous présentons le concept de reconnaissance et d'appariement des formes basé sur OWKS dans la section 4.3. La supériorité de la méthode proposée est montrée expérimentalement sur une base de données de formes 3D standard dans la section 4.4. Enfin, nous présentons nos conclusions dans la section 4.5.

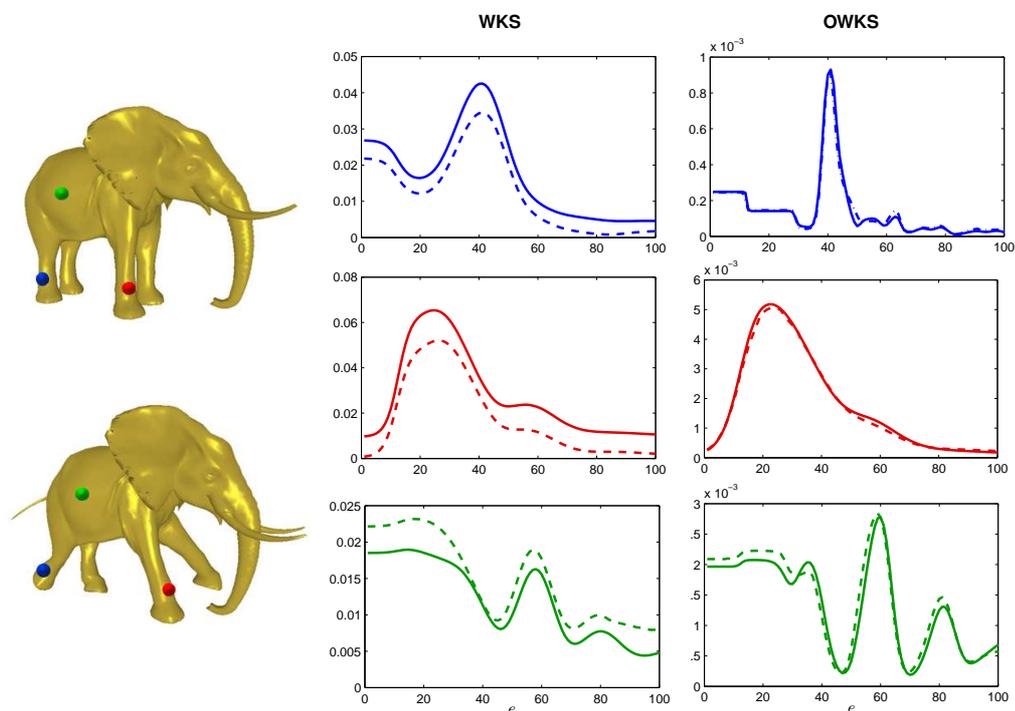


FIGURE 4.3 – Comparaison de la signature du noyau d'onde (deuxième colonne) et de la signature optimisée du noyau d'onde (troisième colonne) sur deux poses du modèle d'éléphant (première colonne) en trois points différents (marqués en *rouge*, *vert*, et *blue*). Les lignes pleines et pointillées représentent respectivement la forme en haut et en bas. Chaque signature est calculée sur $e = 100$ échelles d'énergie.

4.2/ PRÉLIMINAIRES THÉORIQUES

Dans cette section, nous décrivons brièvement la signature du noyau d'onde et nous présentons les théories d'optimisation par essaim de particules utilisées.

4.2.1/ SIGNATURE DU NOYAU D'ONDE REVISITÉE

Le processus du noyau d'onde sur une surface \mathcal{M} est régi par l'équation de Schrödinger :

$$\frac{\partial u}{\partial t}(s, t) = i\Delta_{\mathcal{M}}\psi_E(s, t), \quad (4.1)$$

où $\Delta_{\mathcal{M}}$ est l'opérateur LB de \mathcal{M} et $\psi_E(s, t)$ est la solution de l'équation de Schrödinger. $\psi_E(s, t)$ décrit l'évolution d'une particule quantique avec une position inconnue sur la surface \mathcal{M} et qui peut être exprimée dans le domaine spectral par l'équation (2.20).

Rappelons que $|\psi_E(s, t)|^2$ est la probabilité de trouver une particule de niveau d'énergie E sur un point $s \in \mathcal{M}$ [21, 91]. Les énergies sont directement liées aux valeurs propres de l'opérateur LB, plus particulièrement $\lambda_k = E_k$. La raison est simplement due au remplacement du paramètre de temps dans l'équation (2.20) par l'énergie. La signature du noyau d'onde à un point s sur le maillage est alors définie dans l'échelle logarithmique e_k par :

$$\text{WKS}(s, e) = C_e \sum_k \phi_k^2(s) e^{-\frac{(e - \log(E_k))^2}{2\sigma^2}}, \quad (4.2)$$

avec $C_e = 1/\sum_k e^{-\frac{(e - \log(E_k))^2}{2\sigma^2}}$ est une constante de normalisation, tandis que σ est la variance de la distribution de l'onde.

En confinant le noyau d'onde dans un domaine d'échelle d'énergie logarithmique et en fixant les variables spatiales, on peut obtenir la propagation d'onde en échelle d'énergie pour chaque point s sur une surface en calculant $\text{WKS}(s, e)$. Nous présentons sur la Figure 4.4 un exemple de propagation d'onde sur une échelle d'énergie sur la forme de la main droite, ainsi que la distribution d'onde pour trois points différents sur le maillage de la forme dans la Figure 4.5. Aubry *et al.* [21] ont formellement prouvé que la signature du noyau d'onde est isométriquement invariante, invariante à l'échelle, informative, multi-échelle, et stable contre les perturbations de la surface, mais qu'elle tend à générer une correspondance plus bruyante, ou autrement dit, plus dense [91].

4.2.2/ INTRODUCTION À SPSO ET MPSO

Une explication du fonctionnement du SPSO est illustrée à la Figure 4.6. Étant donné une population d'essaim de N particules. Chaque particule individuelle X_i représente une solution possible au problème d'optimisation dans un espace de dimension d portant un vecteur de position $\mathbf{x}_i = \{x_{i1}, x_{i2}, \dots, x_{id}\}$ et un vecteur de vitesse $\mathbf{v}_i = \{v_{i1}, v_{i2}, \dots, v_{id}\}$, où $i = 1, 2, \dots, N$, initialisés aléatoirement dans l'espace de recherche. Au cours de la t -ième itération, le prochain vecteur de vitesse et de direction de la i -ième particule $\mathbf{v}_i(t)$ est déterminé par son vecteur courant $\mathbf{v}_i(t-1)$, sa meilleure position antérieure \mathbf{p}_i , et la meilleure position globale \mathbf{p}_g sont obtenues par d'autres particules dans la population à

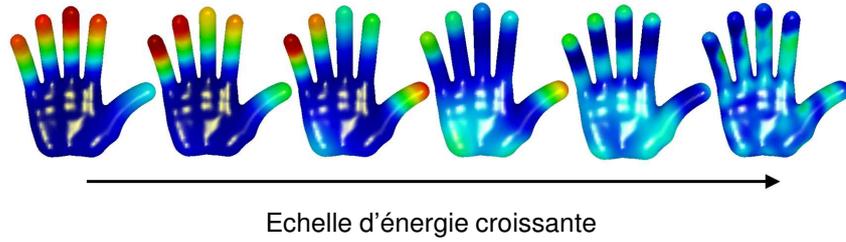


FIGURE 4.4 – La distribution de l'onde sur une échelle d'énergie croissante. Les couleurs vont du bleu (valeurs basses) au rouge (valeurs élevées). Les valeurs d'onde sur chaque point de la forme changent en fonction du paramètre d'énergie dans WKS (s, e).

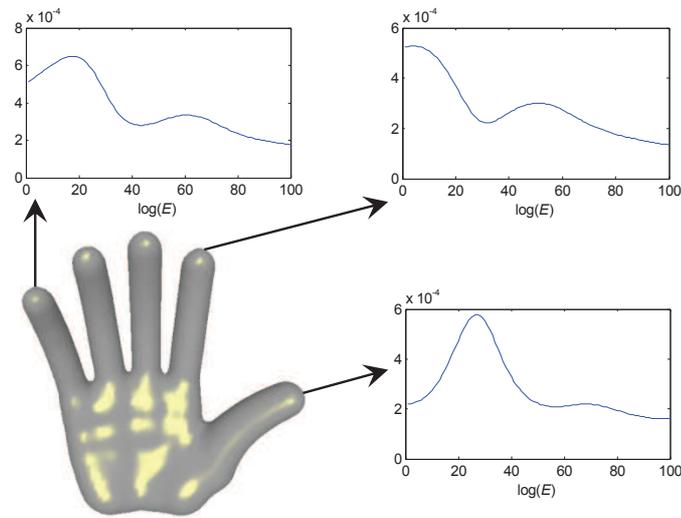


FIGURE 4.5 – Signature du noyau d'onde en trois points différents. La distribution des ondes dans l'énergie correspond au comportement montré dans la Figure 4.4.

l'itération t , la mise à jour s'effectue par la formule (4.3) et le vecteur de position est mis à jour par la formule (4.4) telles que :

$$\mathbf{v}_i(t+1) = \omega \cdot \mathbf{v}_i(t) + c_1 \cdot \boldsymbol{\varphi}_1(t) (\mathbf{p}_i - \mathbf{x}_i(t))^T + c_2 \cdot \boldsymbol{\varphi}_2(t) (\mathbf{p}_g - \mathbf{x}_i(t))^T, \quad (4.3)$$

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{v}_i(t+1), \quad (4.4)$$

où, ω est le poids d'inertie fixe qui contrôle l'exploration de l'espace de recherche, c_1 et c_2 sont les facteurs d'accélération, t est le nombre d'itérations en cours, $\boldsymbol{\varphi}_1(t)$ et $\boldsymbol{\varphi}_2(t)$ sont des vecteurs aléatoires qui varient dans l'intervalle $[0, 1]^d$, formulés par :

$$\begin{aligned} \boldsymbol{\varphi}_1(t) &= \{\varphi_{11}(t), \varphi_{12}(t), \dots, \varphi_{1d}(t)\} \\ \boldsymbol{\varphi}_2(t) &= \{\varphi_{21}(t), \varphi_{22}(t), \dots, \varphi_{2d}(t)\} \end{aligned} \quad (4.5)$$

La meilleure position personnelle est définie en utilisant la formule suivante :

$$\mathbf{p}_i(t+1) = \begin{cases} \mathbf{p}_i(t) & \text{si } f(\mathbf{x}_i) > f(\mathbf{p}_i(t)) \\ \mathbf{x}_i(t+1) & \text{si } f(\mathbf{x}_i) \leq f(\mathbf{p}_i(t)), \end{cases} \quad (4.6)$$

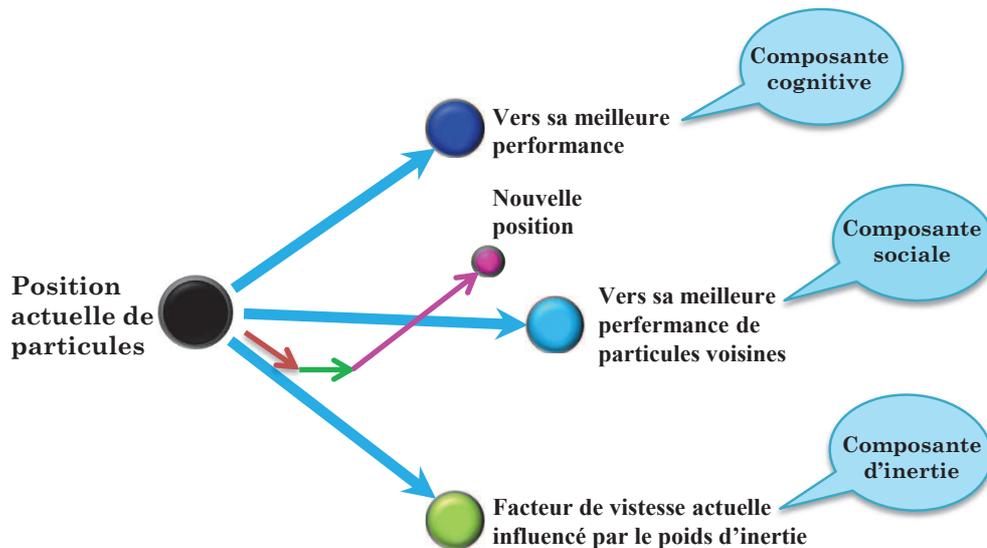


FIGURE 4.6 – Optimisation par essaim de particules : le déplacement des essais.

et la meilleure position globale est définie comme :

$$p_g(t+1) = \arg \min_{p_i} f(p_i(t+1)), \quad 1 \leq i \leq N. \quad (4.7)$$

Il est intéressant d'indiquer que le poids d'inertie fixe, utilisé dans SPSO, a été remplacé par un autre paramètre évolutif. En effet, lors de l'exploration initiale, un facteur de poids d'inertie important est utilisé et progressivement réduit à mesure que la recherche progresse. Nous définissons le concept d'un processus variable dans le temps de ce poids d'inertie par $\omega^{iter} = (\omega_{max} - \omega_{min}) \times \frac{iter_{max} - iter_{min}}{iter_{max}} + \omega_{min}$, où $iter_{max}$ est le nombre maximal d'itérations.

4.3/ RECONNAISSANCE DE FORMES BASÉE SUR OWKS

Nous optimisons la signature du noyau d'onde en utilisant MPSO. Contrairement à WKS, notre descripteur optimisé peut être appliqué pour mieux identifier, distinguer et différencier les points saillants détectés sur la forme à condition de choisir le premier vecteur caractéristique du descripteur OWKS (s_n, e_1). Une solution acceptable pour optimiser un noyau d'onde sur une base de données de forme consiste à minimiser l'écart des signatures WKS sur les basses fréquences du maillage. L'illustration générale de notre cadre est présentée dans la Figure 4.7 et est détaillée dans les étapes suivantes :

Etape 1 Calcul de la matrice Laplacienne L , en utilisant [34].

Etape 2 Décomposition spectrale de L .

Etape 3 Invocation de MPSO pour rechercher une nouvelle valeur au lieu de considérer la valeur fixe $\alpha = 7$ comme elle a été déclarée dans [21]. Ceci est équivalent à retrouver la valeur optimale globale de la variance σ_{opt} le long de toutes les itérations. Nous avons calculé les $k = 300$ premières valeurs propres de L et évalué WKS à $M = 100$ valeurs de e allant de $e_{min} = \log(E_1)$ à $e_{max} = \frac{\log(E_k)}{1.02}$ avec un incrément linéaire δ dans e est $\delta = \frac{e_{max} - e_{min}}{M}$; sachant que $\sigma_{opt} = \alpha_j \delta$.

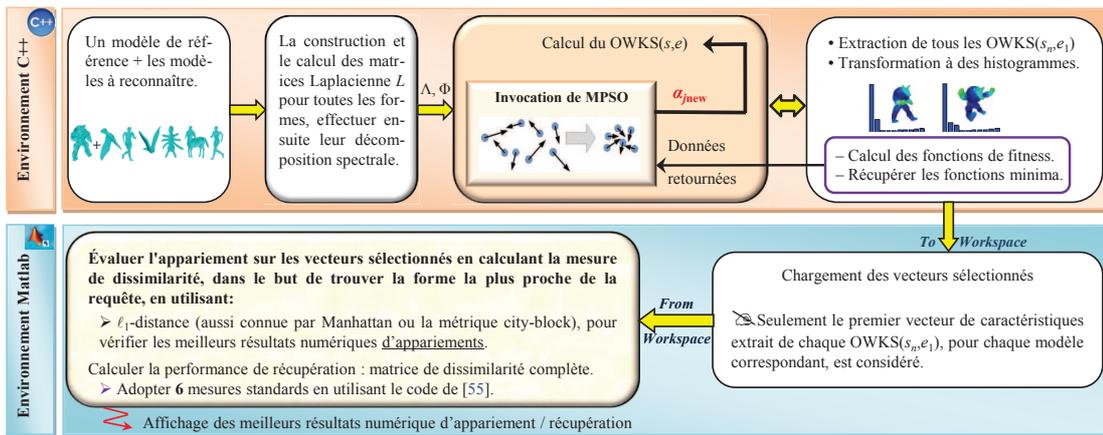


FIGURE 4.7 – Organigramme de la méthode proposée.

Etape 4 Soient S_1 et S_2 deux formes à comparer. Deux matrices WKS_{S_1} et WKS_{S_2} , chacune de taille égale à $(n \times M)$, sont construites. Ces deux matrices sont les descripteurs en cours d'optimisation. A ce stade, nous nous intéressons simplement à extraire le premier vecteur de dimension finie de chaque matrice pour représenter et caractériser chaque forme de manière compacte. $WKS_{S_1}(s_n, e_1)$ et $WKS_{S_2}(s_n, e_1)$ sont deux vecteurs caractéristiques de taille $(n \times 1)$. Nous extrayons la première échelle d'énergie e_1 sur M pour trouver les points saillants, car le premier vecteur caractéristique extrait de chaque OWKS correspond aux basses fréquences du maillage. En d'autres termes, de manière similaire à la méthode AGPS présentée au chapitre précédent, nous considérons les maxima de chaque vecteur comme des points saillants importants. H_1 et H_2 représentent les histogrammes normalisés de ces vecteurs, où chaque histogramme possède $b = 10$ cases. Ce nombre de cases, choisi empiriquement, nous a permis de trouver le meilleur compromis qui facilite l'interprétation de l'histogramme. Pour trouver les objets les plus similaires à la requête, nous comparons l'histogramme de la requête à l'histogramme de chaque objet, à chaque génération de l'algorithme MPSO. Nous calculons la meilleure solution globale, en minimisant l'erreur quadratique moyenne (MSE) qui est proposée pour l'algorithme MPSO. Soit i l'indice des cases dans chaque histogramme. MSE est donc calculée par l'équation suivante :

$$\text{MSE} = \text{Fitness} = \frac{1}{b} \sum_{i=1}^b \mathcal{H}_i^2, \quad (4.8)$$

où $\mathcal{H}_i = H_1(i) - H_2(i)$ est la différence entre deux distributions de formes converties en histogrammes. Bref, la plus faible valeur trouvée pour MSE correspond à la valeur optimisée de la variance. Cette valeur optimisée permet réellement d'obtenir un descripteur OWKS précis, efficace et ainsi capable d'identifier les meilleurs appariements.

Afin d'accélérer le processus de recherche, le descripteur OWKS de chaque forme dans la base de données est calculé que si c'est nécessaire, et stocké dans un fichier. Les fichiers sont enregistrés de telle sorte que chacun d'eux ne contienne que le premier vecteur du descripteur optimisé $WKS_S(s_n, e_1)$ de la forme correspondante. Les vecteurs de données sont maintenant disponibles pour être évalués deux à deux (un modèle de référence plus les modèles à reconnaître dans la base de données) en s'appuyant sur le calcul d'une mesure de dissimilarité. La distance de Manhattan $\ell_1(S_1, S_2) = \sum_{i=1}^b |\mathcal{H}_i|$, également connue sous le nom de la distance city-bloc ou métrique absolue, est utilisée.

4.4/ EXPÉRIENCES ET RÉSULTATS

Dans cette section, nous évaluons la performance de notre méthode et nous la comparons avec différentes méthodes de l'état de l'art. Des résultats qualitatifs et quantitatifs extensifs pour la classification, l'appariement et la recherche de formes 3D non rigides sont également présentés.

4.4.1/ RÉGLAGE DES PARAMÈTRES ET TEMPS DE CALCUL

L'algorithme MPSO dépend de plusieurs facteurs qui déterminent son comportement tels que la taille d'essaim, le nombre d'itérations, les facteurs de poids d'inertie et les coefficients d'accélération. Ici, nous donnons les valeurs des différents paramètres utilisés par l'algorithme MPSO pour obtenir des résultats optimaux. Les valeurs des paramètres recommandées pour MPSO sont présentées dans le Tableau 4.1. Ces valeurs sont sélectionnées et validées empiriquement en référence à plusieurs travaux de recherches portant sur l'analyse de convergence de variante MPSO. Autrement dit, l'ensemble de ces meilleures valeurs permet à la fois d'accélérer la convergence et d'atteindre la meilleure solution possible dans un temps CPU plus rapide [132]. Ensuite, elles sont invoquées dans MPSO afin de trouver le paramètre global optimisé pour WKS. Cela signifie qu'un choix correct d'une valeur de chacun de ces paramètres mène MPSO à atteindre sa haute performance, permettant d'améliorer le descripteur de forme, et par conséquent la reconnaissance et la précision du processus de recherche.

Le Tableau 4.2 compare le temps de calcul moyen de l'OWKS avec WKS. Dans la pratique, les descripteurs de formes des objets de la base de données sont calculés en même temps que ceux de la requête lors du processus de recherche : pour mesurer la dissimilarité entre la requête et chaque forme dans la base de données, il faut calculer les descripteurs de forme pour chacune d'entre elles.

Base de données La performance de notre méthode est testée pour trois tâches différentes, c'est-à-dire, pour la classification des points saillants, la classification et l'appariement de formes ; elle est ainsi évaluée sur une base de donnée récente : nous utilisons la base de données de formes 3D SHREC-2015 [2] présentée dans le chapitre précédent. La Figure 4.8 montre de nouveaux échantillons de formes 3D de cette base de donnée.

TABLE 4.1 – Valeurs des paramètres recommandées pour MPSO.

Paramètres	Valeurs
Taille d'essaim	10
Itération maximale	50
Facteurs de poids d'inertie	$\omega_{max} = 0.9$ et $\omega_{min} = 0.4$
Coefficients d'accélération	$c_1 = c_2 = 2$

TABLE 4.2 – Temps de calculs pour WKS et OWKS sur un ordinateur de 2 GHz, 2 Duo CPU et 3G RAM. Les troisième, quatrième, cinquième et sixième colonnes montrent le temps (en seconde) de construction de la matrice Laplacienne, la résolution des paires propres, le calcul du WKS et du OWKS à tous les points avec $k = 300$.

Modèle	#Sommets	Matrice	Eigen	WKS	OWKS
Armadillo	9.43k	1.10	47	15	8345
Centaure	9.45k	1.14	48	15	8362
Eléphant	10.0k	1.28	52	16	8851

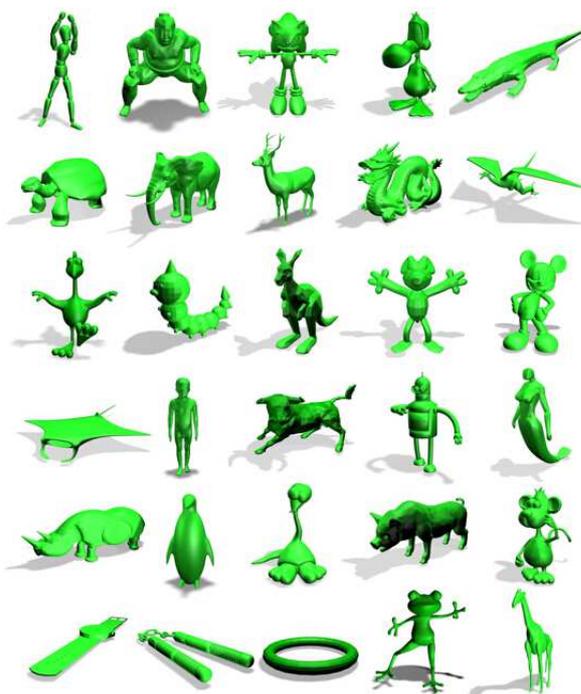


FIGURE 4.8 – Affichage de formes 3D à partir de la base de donnée SHREC-2015.

4.4.2/ CLASSIFICATION DES CARACTÉRISTIQUES

Nous soulignons, ici, la performance supérieure de notre descripteur OWKS par rapport à WKS classique dans la classification des points saillants extraits, par exemple, pour les doigts d'une main, seront mieux différenciés de ceux d'orteils. En effet, la recherche de la valeur moyenne optimisée $\widehat{\alpha}_{opt}$, qui est obtenue en terme de moyenne des variances calculées pour une classe d'objets, requiert l'utilisation de MPSO comme décrit dans la section 4.3. Cela améliore considérablement la fiabilité du calcul de la signature OWKS, et par conséquent la classification des points caractéristiques et la précision du processus de recherche.

Nous notons sur la Figure 4.9(a) que cet algorithme converge rapidement vers une valeur moyenne optimale $\widehat{\alpha}_{opt}$ pour la classe d'Armadillo à partir de la 28^e génération. En même temps, la fonction de fitness est minimisée pour atteindre une erreur quadratique moyenne égale à 1.52×10^{-3} comme indiqué sur la Figure 4.9(b). Par ailleurs, dans le cas où la base de donnée évolue, la valeur de la fonction d'évaluation et la valeur du paramètre variance sont également changées comme indiqué dans le Tableau 4.3.

La méthode de détection des points d'intérêt est également utilisée pour obtenir les points caractéristiques saillants sur les formes. En pratique, pour trouver les points caractéristiques sur le maillage, nous proclamons un point s comme un point d'intérêt si $OWKS(s, e_1) > OWKS(s_n, e_1)$ pour tout s_n dans le voisinage de deux anneaux de s , de manière similaire à notre approche par AGPS. En haut de la Figure 4.9, nous pouvons voir que le même nombre de points d'intérêt est détecté égal à 7, pour chaque pose. Cette figure illustre l'efficacité, la précision et la persistance de notre méthode de détecter la structure répétée à travers une collection de poses appartenant à la même classe de formes, telles que la tête, les mains et les pieds. La Figure 4.9(c-d) présente un exemple comparatif de classification des 28 points d'intérêt projetés dans \mathbb{R}^2 et basés sur leurs WKS et leurs OWKS. Nous pouvons clairement constater que l'algorithme MPSO améliore de manière significative les performances de WKS. Nous remarquons aussi que notre descripteur tend non seulement à maximiser la distance extra-classe, mais aussi à minimiser la distance intra-classe des caractéristiques détectées sur les quatre poses de l'Armadillo.

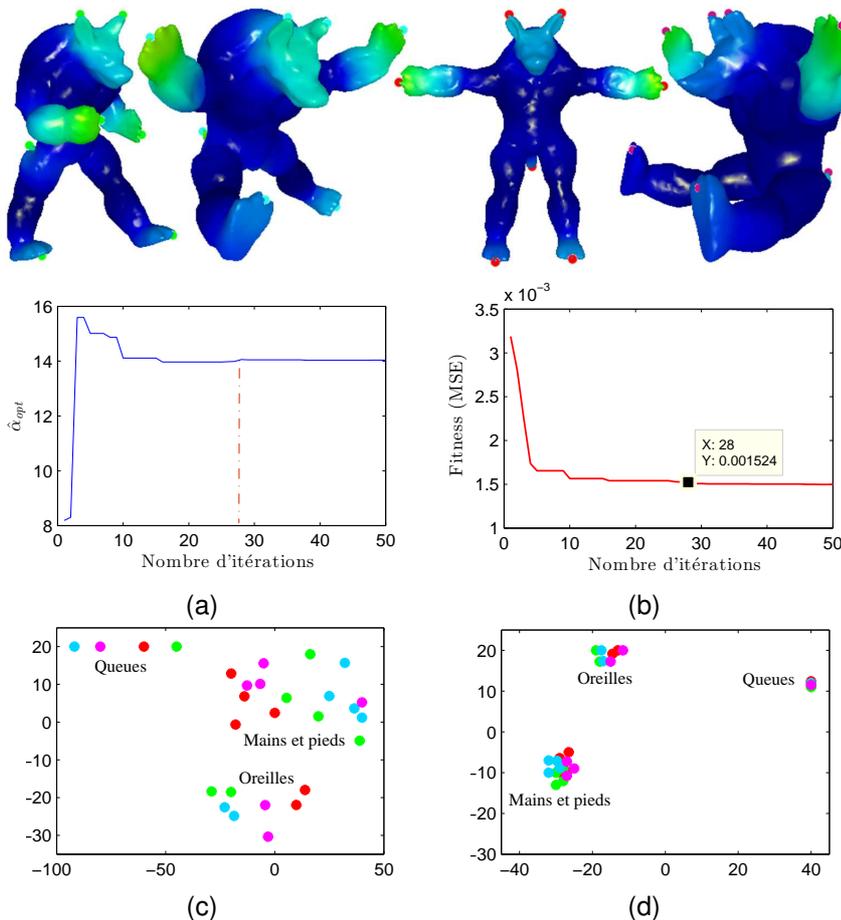


FIGURE 4.9 – En haut : Points caractéristiques détectés sur les quatre poses de l'Armadillo. (a-b) : Evolution de MPSO pour déterminer $\hat{\alpha}_{opt}$. (c-d) : Plongement CMDS des points caractéristiques en fonction de leur WKS pour $\alpha = 7$ et en fonction de leur OWKS (s, e_1) pour $\hat{\alpha}_{opt} = 14.03$. La couleur de chaque point projeté sur le plan 2D correspond à la pose à partir de laquelle il est pris.

TABLE 4.3 – Comparaison entre les valeurs de la fonction fitness et les valeurs de la variance avant et après l’optimisation.

Méthode de reconnaissance	WKS	OWKS	
Modèle de référence	Paramètres		
	Fitness pour $\alpha = 7$ in [21]	Fitness moyenne	Valeur moyenne $\hat{\alpha}_{opt}$
Armadillo	0,196	0,0015	14,03
Elephant	0,200	0,0011	03,43
Centaur	0,033	0,0005	12,29
Cat	0,590	0,1790	15,93

4.4.3/ CLASSIFICATION DE FORMES

La classification pour six classes de formes sélectionnées de la base de données est également illustrée dans la Figure 4.10. Remarquablement, la Figure 4.10(a) montre que le descripteur WKS ne permet pas une classification précise, presque tous les modèles sont regroupés. Différemment, à partir de la Figure 4.10(b), nous observons que le descripteur OWKS permet de mieux distinguer des modèles appartenant à différentes catégories, ce qui explique la surperformance et la capacité de notre méthode à assurer une meilleure séparabilité et à minimiser la distance inter-classe de formes. D’autre part, la classification de formes basée sur OWKS est également un atout pour rapprocher et représenter les formes qui ont presque les mêmes caractéristiques. Par exemple, la projection CMDS montre que le résultat de classification est presque identique pour la classe des hommes et des femmes par rapport à la classe des Centaures. En d’autres termes, puisque le Centaure est une forme à moitié humaine, il est très logique que les deux classes (des hommes et des femmes) soient les plus proches de la classe du Centaure, et vice versa. Pour valider davantage notre méthode, toutes ces observations et résultats sont confirmés par le calcul des distances intra-classe et inter-classe dans le Tableau 4.4.

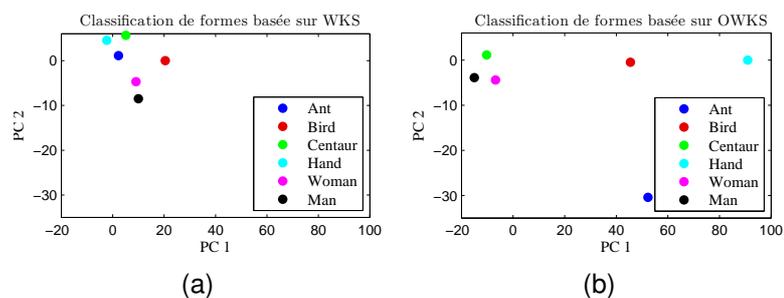


FIGURE 4.10 – Résultat de la classification des formes. La projection CMDS des similarités de forme calculées en utilisant, respectivement de gauche à droite, le WKS et l’OWKS.

TABLE 4.4 – Comparaison entre les distances inter-classe et intra-classe avant et après l’invocation de MPSO. Contrairement à WKS, OWKS conduit à une faible dispersion intra-classe et une grande dispersion extra-classe.

Descripteur	Distance	
	Inter-classe	Intra-classe
WKS	33.67	3.599
OWKS	38.28	2.294

4.4.4/ APPARIEMENT ET RECHERCHE DE FORMES

Dans cette section, nous présentons et discutons la performance d'appariement et les résultats de l'évaluation du processus de recherche par forme clef en utilisant le descripteur OWKS proposé et d'autres descripteurs de l'état de l'art.

4.4.4.1/ PERFORMANCE D'APPARIEMENT

Dans le but de retourner les objets les plus proches de la requête, nous proposons d'utiliser la distance ℓ_1 pour comparer la requête à chaque objet de la base de données. Le choix spécifique de cette distance provient du fait que les méthodes avec lesquelles nous nous comparons l'ont également utilisé. La performance du cadre proposé est évaluée sur la base de données SHREC-2015. Pour valider notre méthode, un exemple des six premières correspondances de formes récupérées pour deux modèles de référence (la Lunette et le Poulpe) par la méthode OWKS, WKS, GPS et HKS, est présentée dans le Tableau 4.5. Remarquablement dans ce tableau, à l'exception de notre approche qui permet d'obtenir des résultats de recherche plus stables, les méthodes WKS, GPS et HKS fournissent parfois des résultats instables, voire parfois médiocres pour certains cas. Comme le montre le Tableau 4.6, l'approche proposée est efficace et conduit à de très bons résultats d'appariement. La performance d'appariement de l'approche proposée est évaluée en effectuant une comparaison par paire de forme, autrement dit, entre le vecteur OWKS (s, e_1) d'un modèle de référence donné et tous les vecteurs OWKS (s, e_1) des formes dans la base de données SHREC-2015 en utilisant la distance ℓ_1 . Les formes appartenant à la même catégorie ont des valeurs beaucoup plus faibles pour le descripteur OWKS où la valeur la plus faible (affichée en gras) correspond au meilleur appariement. Cependant, la distance entre la classe des femmes et les deux autres classes des mains

TABLE 4.5 – Résultats de recherche pour deux modèles de références (Lunette et Poulpe) par notre méthode OWKS, WKS, GPS et HKS. La couleur jaune de la forme indique les récupérations correctes.

Formes de référence							
							
Formes récupérées							
OWKS	WKS	GPS	HKS	OWKS	WKS	GPS	HKS
							
							
							
							
							
							

TABLE 4.6 – Correspondance avant et après l’optimisation de WKS, sous SHREC-2015. Chaque forme est mise en correspondance avec toutes les autres formes de la base de données. Chaque cellule montre la mesure de dissimilarité entre deux formes sélectionnées dans la base de données. La plus petite valeur correspond au meilleur appariement.

La distance ℓ_1 avec WKS						La distance ℓ_1 avec OWKS					
											
	0.102	0.109	0.105	0.116	0.113		0.041	0.138	0.126	0.177	0.101
	0.112	0.091	0.117	0.101	0.109		0.142	0.006	0.118	0.127	0.152
	0.117	0.123	0.113	0.127	0.125		0.121	0.119	0.045	0.117	0.141
	0.171	0.164	0.169	0.158	0.161		0.173	0.133	0.130	0.115	0.203
	0.135	0.114	0.131	0.113	0.062		0.104	0.162	0.147	0.218	0.004

et des oiseaux augmente. Cela signifie, en particulier, que l’utilisation de l’algorithme MPSO à côté du descripteur WKS mène à identifier les classes d’objets de sorte que la distance entre les classes les plus similaires prend la plus petite valeur de la distance ℓ_1 . Prenons l’exemple des classes des femmes et des Centaures avant et après l’introduction du MPSO, elles sont d’abord très éloignées les une des autres, en revanche, une fois MPSO est introduit, nous remarquons que ces deux classes se rapprochent. Leur rapprochement se traduit par la diminution de la valeur de la distance ; ceci correspond mieux à la réalité tant que les modèles de ces deux classes se ressemblent.

4.4.4.2/ RÉSULTATS DE L’ÉVALUATION DE RÉCUPÉRATION

Dans cette section, nous adoptons des mesures standard pour la récupération de formes 3D en utilisant le code de [2]. Le descripteur OWKS est évalué de manière exhaustive à l’aide de six métriques communément utilisées : nous montrons les courbes P/R et les valeurs de précision du processus de recherche NN, FT, ST, E et DCG.

Nous avons calculé la matrice de dissimilarité entre tous les premiers vecteurs caractéristiques extraits de chaque OWKS en utilisant la distance ℓ_1 , ce qui permet de mesurer les performances des résultats de recherche. Nous avons représenté les courbes P/R d’OWKS par rapport à plusieurs méthodes de référence sur la Figure 4.11. Nous pouvons voir que le descripteur OWKS surpasse les autres méthodes (voir [2]) et qui sont : SA, HKS, WKS, multi-feature, TSASR, SID, SNU, SG et FVF-HKS. OWKS est donc plus pertinent et plus discriminant.

Ensuite, les cinq critères de performance, c’est-à-dire NN, FT, ST, E et DCG, sont utilisés pour évaluer OWKS pour la base de données SHREC-2015 pour la recherche de formes. Les résultats sont résumés dans le Tableau 4.7 qui montre les scores des cinq critères de performance pour le descripteur OWKS proposé et les autres descripteurs de référence. Nous pouvons voir dans ce tableau que le descripteur proposé obtient de meilleurs résultats dans le processus de recherche. Par exemple, en termes de métrique NN, OWKS atteint un score de 96,9%, avec des améliorations de performance de 0,9 et 3,3% par rapport aux méthodes de références les plus performantes FVF-HKS et SG, respectivement. En outre, OWKS surpasse le descripteur SID de 17,4% en NN, de 24,8% en FT, de 19,6% en ST, de 19,7% en E et de 15,8% en DCG. Nous notons que cette meilleure

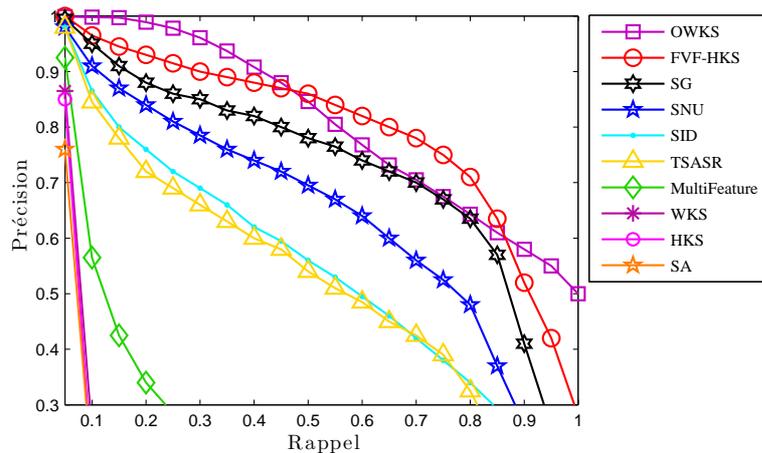


FIGURE 4.11 – Courbes P/R moyennes de notre descripteur OWKS par rapport aux autres approches appliqués sur la base de donnée SHREC-2015.

performance est consistante avec toutes les métriques d'évaluation dans le processus de récupération de formes.

Pour une comparaison équitable, nous avons comparé OWKS à des méthodes de référence de la même catégorie, c'est-à-dire des méthodes basées sur la représentation par sac de caractéristiques (*Bag of Features*, BoF). En outre, les approches basées sur le codage clairsemé (*sparse coding*) souffrent généralement de la longue durée d'exécution, en particulier pour construire la matrice Laplacienne et résoudre les paires propres. Bien que ces approches, telles que SPHSparseCoding, HAPT et SV-LSF [2], fonctionnent légèrement mieux que OWKS (retournent davantage de formes correspondantes à la requête que OWKS) ; le cadre proposé surpasse régulièrement les méthodes de référence dans la plupart des cas, comme en témoignent nos résultats expérimentaux.

TABLE 4.7 – Résultats de récupération par notre méthode (dernière ligne) comparée à l'état de l'art sur la base de données SHREC-2015. Les chiffres en gras indiquent les meilleurs résultats de récupération.

Méthodes	Mesures d'évaluation de récupération				
	NN	FT	ST	E	DCG
SA	0.065	0.067	0.128	0.078	0.393
HKS	0.065	0.063	0.124	0.074	0.391
WKS	0.134	0.074	0.137	0.083	0.408
Multi-Feature	0.450	0.186	0.262	0.184	0.525
TSASR	0.813	0.463	0.544	0.420	0.749
SID	0.795	0.484	0.614	0.459	0.778
SNU	0.898	0.563	0.669	0.516	0.832
SG	0.936	0.668	0.736	0.587	0.875
FVF-HKS	0.960	0.725	0.809	0.644	0.913
OWKS	0.969	0.732	0.810	0.656	0.936

4.5/ CONCLUSIONS

Dans ce chapitre, nous avons proposé une méthode d'un descripteur optimisé pour l'appariement et la classification de formes 3D appelé OWKS. Notre descripteur possède des propriétés importantes, qui sont : l'invariance à l'isométrie (deux formes isométriques ont la même OWKS), et aussi la capacité de détection de caractéristiques locales de la forme (à savoir les points saillants du maillage) si et seulement si le vecteur de plongement d'OWKS sur la forme est sélectionné à la première échelle d'énergie e_1 .

Nous avons évalué notre approche sur une variété d'objets 3D de la base de données SHREC-2015. Les résultats expérimentaux indiquent que le renforcement du descripteur WKS avec un paramètre de variance optimisé à l'aide de MPSO permet d'obtenir de meilleures performances par rapport aux méthodes de recherche de formes les plus récentes. Par conséquent, la supériorité de la méthode est directe, puisqu'elle utilise des paramètres qui ont été optimisés. En d'autres termes, l'OWKS est meilleur parce qu'il est plus finement ajusté pour une base de donnée fixe et particulièrement pour chaque classe d'objet. Néanmoins, la faiblesse de cette méthode réside dans le fait que si la base de donnée évolue, il faut alors refaire compiler tout l'algorithme pour ajuster chaque classe.

CONCLUSIONS ET TRAVAUX FUTURS

Nous avons présenté deux techniques de reconnaissance, d'appariement et de classification d'objets 3D. La première, basée sur la proposition d'un nouveau descripteur appelé AGPS qui est extrêmement compact et capable d'obtenir une description de forme précise. La seconde s'appuie sur une méthode existante, à savoir par noyau d'onde, mais nous proposons une version améliorée de la signature du noyau d'onde qui est plus informative et discriminante en optimisant les paramètres pour une base de donnée précise. Ces approches géométriques spectrales sont proposées pour la recherche de forme 3D non rigide en utilisant l'opérateur LB du graphe associé au maillage. Nous avons démontré, à travers des expériences approfondies, les meilleures performances des méthodes proposées en comparaison avec d'autres méthodes de l'état de l'art dans la littérature.

Dans la section 5.1, nous résumons chacune de ces contributions séparément. Des propositions pour les orientations des travaux futures relatives à cette thèse sont également fournies dans la section 5.2.

5.1/ CONTRIBUTIONS DE LA THÈSE

5.1.1/ RECONNAISSANCE ET RECHERCHE DE FORMES 3D UTILISANT UNE SIGNATURE DE POINT GLOBALE AVANCÉE

Dans le chapitre 3, nous avons examiné les travaux antérieurs en rapport avec des descripteurs spectraux pour l'analyse de forme. Ensuite, nous avons proposé une signature de point globale avancée en tant que nouveau vecteur de caractéristiques pour intégrer des formes non rigides dans un système de correspondance de forme holistique. Le mappage d'AGPS sur une forme entière permet de décrire et d'explorer sa structure intrinsèque. De plus, AGPS permet d'extraire des éléments caractéristiques, de capter et de conserver un nombre fixe de points d'intérêt. En outre, AGPS est peu coûteux en mémoire et en temps de calcul et peut être calculé facilement et fidèlement. Nous proposons un algorithme très simple pour détecter les points d'intérêt comme les maxima locaux de l'AGPS sur un 2-voisinage. Nous illustrons que notre proposition détecte mais également discrimine efficacement les différentes protubérances de forme, et donc sa capacité à différencier des classes de caractéristiques. La qualité de notre descripteur est prouvée expérimentalement. Les résultats expérimentaux effectués sur deux bases de données démontrent que l'approche que nous proposons surpasse les méthodes de l'état de l'art au niveau de la précision de la récupération et la reconnaissance de formes.

5.1.2/ APPARIEMENT ET LA RÉCUPÉRATION DE FORMES 3D DÉFORMABLES À TRAVERS UN DESCRIPTEUR DU NOYAU D'ONDE OPTIMISÉ

Dans le chapitre 4, nous avons présenté une approche optimisée de la signature du noyau d'onde qui fournit un cadre général et flexible pour l'appariement, la classification et la recherche d'objets 3D par forme clef [36, 35]. L'approche proposée prend non seulement en compte les relations spatiales entre les caractéristiques, mais améliore également de manière significative la capacité discriminante de la signature. Les résultats expérimentaux ont montré que la technique que nous proposons est plus précise et surpasse les approches existantes pour une base d'objets donnée.

5.2/ ORIENTATIONS DES TRAVAUX FUTURS

Plusieurs pistes de recherches sont exposées et discutées ci-dessous :

5.2.1/ AMÉLIORATION DE LA RECHERCHE DE FORMES 3D EN UTILISANT L'APPRENTISSAGE PROFOND

La disponibilité et l'utilisation généralisée de bases de données volumineuses associées à la nécessité d'explorer les modèles 3D en profondeur ont suscité la nécessité d'organiser et de rechercher ces vastes collections de données, de récupérer les sélections les plus pertinentes et de les réutiliser efficacement. Les objets 3D sont constitués d'informations géométriques et topologiques, et leur représentation compacte est une étape importante vers une variété d'applications de vision par ordinateur, en particulier l'appariement et la récupération dans une base de données de modèles 3D.

Inspirés par les récents succès des techniques d'apprentissage profond dans la récupération d'image basée sur le contenu (CBIR) [133], nous avons l'intention d'étudier l'état de l'art des approches d'apprentissage profond, notamment (DBN) [134], la machine de Boltzmann profonde (DBM) [135], les réseaux de neurones convolutionnels (CNN) [136] et les réseaux de neurones profonds (DNN) [137] pour l'apprentissage de caractéristiques de haut niveau. Les résultats récents [133] des études empiriques étendues sur CBIR montrent qu'un modèle CNN profond pré-entraîné sur un ensemble de données à grande échelle peut être directement utilisé pour capturer l'information sémantique élevée dans de nouvelles tâches CBIR. De plus, les caractéristiques extraites par un modèle CNN pré-entraîné en conjonction avec des cadres d'affinement de caractéristiques appropriés, surpassent systématiquement les caractéristiques artisanales conventionnelles sur toutes les bases de données [133]. Par ailleurs, notre méthode est efficace, peu coûteuse, et peut donc être injectée dans ce genre de techniques afin d'obtenir des caractéristiques de haut niveau qui décrivent les objets 3D avec plus de précision. Dans le cadre de travaux futurs, notre recherches visent à étendre nos approches à la correspondance de formes 3D partielles, à l'auto-similarité et à l'appariement d'objets fortement dégradés ; nous évaluerons d'autres bases de données diverses. En particulier, nous exploiterons CNNs pour rechercher et reconnaître des formes 3D non rigides.

5.2.2/ ANALYSE SPECTRALE DE FORMES MÉDICALES

La détection de phénotypes uniques à travers les populations peut être réalisée par l'analyse quantitative de la forme osseuse, à condition que les bases de données des pathologies normales et anormales soient disponibles. Comme orientation d'un travail futur, nous prévoyons d'effectuer une analyse statistique sur les os carpiens du poignet de la main humaine en représentant la surface corticale de l'os du carpe en utilisant le descripteur spectral de point global avancé pour fournir un moyen de comparer les formes des os du carpe. La Figure 5.1 montre un exemple d'os du carpe pour un homme en bonne santé. En outre, nous utiliserons cette représentation dans deux éventuelles applications : (1) analyser des différences de formes osseuses du carpe entre les femmes et les hommes, et (2) analyser des différences de forme osseuse du carpe entre la main droite et la main gauche à travers une population. Plus précisément, à partir de nos contributions, que ce soit pour AGPS ou bien pour OWKS, il est possible d'agréger d'abord les descripteurs locaux d'une forme puis à représenter chaque objet par une signature globale, nous proposerons un nouveau cadre d'extraction directe de deux descripteurs globaux appelés AGPS-BoF ou OWKS-BoF. Ainsi, nous allons contourner toute la procédure du paradigme BoF qui conduit à un temps de calcul plus bas ainsi qu'à une plus grande précision d'analyse. En outre, nous évaluerons la précision de notre cadre proposé en termes d'analyse de variance et de test de permutation pour les différents sexes et les os du carpe.

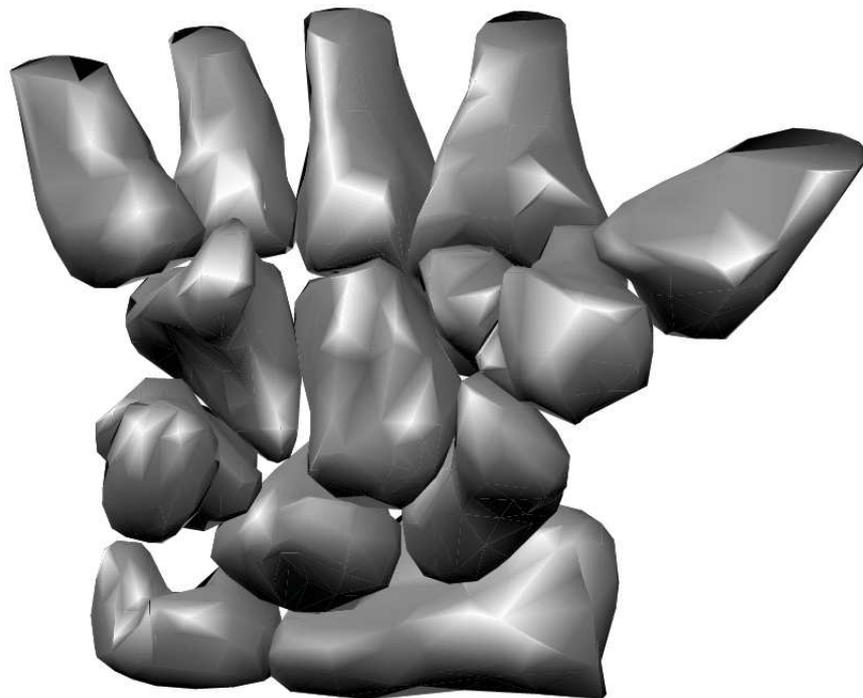


FIGURE 5.1 – Représentation 3D de l'os carpien gauche pour un homme en bonne santé.

5.2.3/ TATOUAGE DE FORMES 3D

Les progrès récents dans la conception et le traitement des contenus numériques ont conduit à la représentation des données précieuses dans des formes numériques, qui peuvent être distribuées via Internet. Étant donné que les contenus numériques peuvent facilement être dupliqués, nous devons protéger ces contenus à des fins de revendication de propriété et d'authentification. Les techniques de tatouage numérique ont été utilisées comme solutions efficaces pour résoudre les problèmes de vérification des droits d'auteur et de propriété en intégrant les informations de filigrane directement dans un objet 3D en modifiant soit la géométrie du maillage 3D, soit la topologie des triangles. Cependant, ces techniques sont souvent sensibles à différents types d'attaques. Nous avons l'intention de développer des techniques de tatouage 3D en utilisant l'analyse de maillage multi-résolution (décomposition spectrale et transformée en ondelettes graphique) dans le but de montrer une meilleure résistance aux différents types d'attaques.

5.2.4/ CONCEPTION D'AUTRES NOYAUX SPECTRAUX

Dans sa forme actuelle, l'approche OWKS proposée est générée à l'aide d'un noyau d'onde, et il a été démontré qu'elle ne donne des performances supérieures qu'avec des transformations isométriques ou quasi isométriques. À l'avenir, nous étudierons plus attentivement le choix optimal d'autres fonctions du noyau génératrices d'ondes, élargissant ainsi la portée du OWKS à des classes de déformations plus générales. En outre, la conception de signatures appropriées pour d'autres applications d'analyse de forme telles que le débruitage de surface est une orientation de travail future prometteuse que nous envisageons d'explorer.

5.2.5/ VERS UNE APPROCHE ROBUSTE DE LA SEGMENTATION DE FORMES

La segmentation de maillage 3D est une tâche fondamentale de bas niveau avec des applications dans des domaines aussi variés tels que la vision par ordinateur, la conception assistée par ordinateur, la bio-informatique et l'imagerie médicale 3D. Une segmentation de maillage perceptuellement cohérente (PCMS), telle qu'elle sera définie dans un travail futur, est celle qui satisfait : (1) l'invariance à la transformation isométrique de la surface sous-jacente, (2) la robustesse aux perturbations de la surface, (3) la robustesse aux différents niveaux de bruit numérique sur la surface, et (4) la proche conformation à la perception humaine. Nous exploiterons le système intelligent de la chaleur et de l'onde de nos deux signatures spectrales AGPS et OWKS en tant que message globalement structuré sur une surface maillée et développerons un schéma PCMS robuste, appelé mappage de chaleur (*Heat-mapping*) ou mappage d'onde (*Wave-mapping*) basé, respectivement, sur le descripteur AGPS et le noyau d'onde. Il y aura trois étapes principales dans le mappage de chaleur ou d'onde. Tout d'abord, le nombre de segments sera estimé sur la base de l'analyse du comportement du spectre Laplacien. Deuxièmement, le centre de chaleur ou d'onde, qui sera défini comme le sommet le plus représentatif sur chaque segment, sera découvert par le même algorithme de recherche de points d'intérêt proposé dans nos chapitres de contributions ; que ce soit dans le chapitre 3 ou dans le chapitre 4. Autrement dit, un centre de chaleur ou un centre d'onde correspondra à un point d'intérêt pour chaque segment de la forme. Troisièmement, un schéma de segmen-

tation conduit par le centre de chaleur ou par le centre d'onde révèle le PCMS avec une grande cohérence vers la perception humaine.

BIBLIOGRAPHIE

- [1] LIAN, Z., GODIL, A., BUSTOS, B., DAOUDI, M., HERMANS, J., KAWAMURA, S., KURITA, Y., LAVOUA, G., AND DP SUETENS, P. **SHREC'11 track : Shape retrieval on non-rigid 3D watertight meshes**. In *Eurographics Workshop on 3D Object Retrieval (3DOR)* (2011), pp. 79–88.
- [2] LIAN, Z., ZHANG, J., CHOI, S., ELNAGHY, H., EL-SANA, J., FURUYA, T., GIACHETTI, A., GULER, R. A., LAI, L., LI, C., LI, H., LIMBERGER, F. A., MARTIN, R., NAKANISHI, R. U., NETO, A. P., NONATO, L. G., OHBUCHI, R., PEVZNER, K., PICKUP, D., ROSIN, P., SHARF, A., SUN, L., SUN, X., TARI, S., UNAL, G., AND WILSON, R. C. **SHREC'15 Track : Non-rigid 3D Shape Retrieval**. In *Eurographics Workshop on 3D Object Retrieval* (2015), The Eurographics Association.
- [3] BIASOTTI, S., THOMPSON, E. M., AONO, M., HAMZA, A. B., BUSTOS, B., DONG, S., DU, B., FEHRI, A., LI, H., LIMBERGER, F., AND OTHERS. **Shrec'17 Track : Retrieval of surfaces with similar relief patterns**. In *10th Eurographics Workshop on 3D Object Retrieval* (2017).
- [4] BIASOTTI, S., CERRI, A., ABDELRAHMAN, M., AONO, M., HAMZA, A. B., EL-MELEGY, M., FARAG, A., GARRO, V., GIACHETTI, A., GIORGI, D., AND OTHERS. **SHREC'14 track : Retrieval and classification on textured 3D models**. In *Proceedings of the Eurographics Workshop on 3D Object Retrieval* (2014), pp. 111–120.
- [5] BRONSTEIN, A., BRONSTEIN, M., CASTELLANI, U., DUBROVINA, A., GUIBAS, L., HORAUD, R., KIMMEL, R., KNOSSOW, D., VON LAVANTE, E., MATEUS, D., AND OTHERS. **SHREC 2010 : robust correspondence benchmark**. In *Eurographics Workshop on 3D Object Retrieval* (2010).
- [6] CHEN, X., GOLOVINSKIY, A., AND FUNKHOUSER, T. **A benchmark for 3D mesh segmentation**. In *Acm transactions on graphics (tog)* (2009), vol. 28, ACM, p. 73.
- [7] CASTELLANI, U., MIRTUONO, P., MURINO, V., BELLANI, M., RAMBALDELLI, G., TANSELLA, M., AND BRAMBILLA, P. **A new shape diffusion descriptor for brain classification**. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (2011), Springer, pp. 426–433.
- [8] SAMIR, C., SRIVASTAVA, A., AND DAOUDI, M. **Three-dimensional face recognition using shapes of facial curves**. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 28, 11 (2006), 1858–1863.
- [9] MAALEJ, A., AMOR, B. B., DAOUDI, M., SRIVASTAVA, A., AND BERRETTI, S. **Shape analysis of local facial patches for 3D facial expression recognition**. *Pattern Recognition* 44, 8 (2011), 1581–1589.
- [10] GELFAND, N., MITRA, N. J., GUIBAS, L. J., AND POTTMANN, H. **Robust global registration**. In *Symposium on geometry processing* (2005), vol. 2, p. 5.
- [11] WANG, C., BRONSTEIN, M. M., BRONSTEIN, A. M., AND PARAGIOS, N. **Discrete minimum distortion correspondence problems for non-rigid shape matching**.

- In *International Conference on Scale Space and Variational Methods in Computer Vision* (2011), Springer, pp. 580–591.
- [12] MITRA, N. J., GUIBAS, L. J., GIESEN, J., AND PAULY, M. **Probabilistic fingerprints for shapes**. In *Symposium on Geometry Processing* (2006), no. EPFL-CONF-149326, pp. 121–130.
- [13] BRONSTEIN, A. M., BRONSTEIN, M. M., GUIBAS, L. J., AND OVSJANIKOV, M. **Shape google : Geometric words and expressions for invariant shape retrieval**. *ACM Transactions on Graphics (TOG)* 30, 1 (2011), 1.
- [14] SKRABA, P., OVSJANIKOV, M., CHAZAL, F., AND GUIBAS, L. **Persistence-based segmentation of deformable shapes**. In *Computer Vision and Pattern Recognition Workshops (CVPRW), 2010 IEEE Computer Society Conference on* (2010), IEEE, pp. 45–52.
- [15] FANG, Y., SUN, M., KIM, M., AND RAMANI, K. **Heat-mapping : A robust approach toward perceptually consistent mesh segmentation**. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on* (2011), IEEE, pp. 2145–2152.
- [16] LI, C., AND HAMZA, A. B. **Skeleton path based approach for nonrigid 3D shape analysis and retrieval**. In *International Workshop on Combinatorial Image Analysis* (2011), Springer, pp. 84–95.
- [17] MOHAMED, W., AND HAMZA, A. B. **Reeb graph path dissimilarity for 3D object matching and retrieval**. *the visual computer* 28, 3 (2012), 305–318.
- [18] CHEN, D.-Y., TIAN, X.-P., SHEN, Y.-T., AND OUHYOUNG, M. **On visual similarity based 3D model retrieval**. In *Computer graphics forum* (2003), vol. 22, Wiley Online Library, pp. 223–232.
- [19] OHBUCHI, R., AND FURUYA, T. **Distance metric learning and feature combination for shape-based 3D model retrieval**. In *Proceedings of the ACM workshop on 3D object retrieval* (2010), ACM, pp. 63–68.
- [20] SUN, J., OVSJANIKOV, M., AND GUIBAS, L. **A Concise and Provably Informative Multi-Scale Signature Based on Heat Diffusion**. In *Computer graphics forum* (2009), vol. 28, Wiley Online Library, pp. 1383–1392.
- [21] AUBRY, M., SCHLICKWEI, U., AND CREMERS, D. **The wave kernel signature : A quantum mechanical approach to shape analysis**. In *Computer Vision Workshops (ICCV Workshops), 2011 IEEE International Conference on* (2011), IEEE, pp. 1626–1633.
- [22] KOKKINOS, I., BRONSTEIN, M., AND YUILLE, A. **Dense scale invariant descriptors for images and surfaces**. PhD thesis, INRIA, 2012.
- [23] RUSTAMOV, R. M. **Laplace-Beltrami eigenfunctions for deformation invariant shape representation**. In *Proceedings of the fifth Eurographics symposium on Geometry processing* (2007), Eurographics Association, pp. 225–233.
- [24] REUTER, M., WOLTER, F.-E., AND PEINECKE, N. **Laplace-Beltrami spectra as ‘Shape-DNA’ of surfaces and solids**. *Computer-Aided Design* 38, 4 (2006), 342–366.
- [25] SHTERN, A., AND KIMMEL, R. **Spectral gradient fields embedding for nonrigid shape matching**. *Computer Vision and Image Understanding* 140 (2015), 21–29.

- [26] BRONSTEIN, A. M., BRONSTEIN, M. M., AND KIMMEL, R. **Numerical geometry of non-rigid shapes**. Springer Science & Business Media, 2008.
- [27] KRIM, H., AND HAMZA, A. B. **Geometric methods in signal and image analysis**. Cambridge University Press, 2015.
- [28] REUTER, M., WOLTER, F.-E., AND PEINECKE, N. **Laplace-spectra as fingerprints for shape matching**. In *Proceedings of the 2005 ACM symposium on Solid and physical modeling (2005)*, ACM, pp. 101–106.
- [29] LOWE, D. G. **Object recognition from local scale-invariant features**. In *Computer vision, 1999. The proceedings of the seventh IEEE international conference on (1999)*, vol. 2, IEEE, pp. 1150–1157.
- [30] MEYER, M., DESBRUN, M., SCHRÖDER, P., AND BARR, A. H. **Discrete differential-geometry operators for triangulated 2-manifolds**. In *Visualization and mathematics III*. Springer, 2003, pp. 35–57.
- [31] FLOATER, M. S. **Mean value coordinates**. *Computer aided geometric design* 20, 1 (2003), 19–27.
- [32] BELKIN, M., SUN, J., AND WANG, Y. **Constructing Laplace operator from point clouds in \mathbb{R}^d** . In *Proceedings of the twentieth annual ACM-SIAM symposium on Discrete algorithms (2009)*, Society for Industrial and Applied Mathematics, pp. 1031–1040.
- [33] BRONSTEIN, A. M. **Spectral descriptors for deformable shapes**. *arXiv preprint arXiv :1110.5015* (2011).
- [34] NAFFOUTI, S. E., FOUGEROLLE, Y., SAKLY, A., AND MÉRIAUDEAU, F. **An advanced global point signature for 3D shape recognition and retrieval**. *Signal Processing : Image Communication* 58 (2017), 228–239.
- [35] NAFFOUTI, S. E., FOUGEROLLE, Y., AOUISSAOUI, I., SAKLY, A., AND MÉRIAUDEAU, F. **Heuristic optimization-based wave kernel descriptor for deformable 3D shape matching and retrieval**. *Signal, Image and Video Processing* 12 (2018), 915–923.
- [36] NAFFOUTI, S. E., AOUISSAOUI, I., FOUGEROLLE, Y., SAKLY, A., AND MÉRIAUDEAU, F. **Enhancement and assessment of WKS variance parameter for intelligent 3D shape recognition and matching based on MPSO**. In *2016 4th International Conference on Control Engineering & Information Technology (CEIT) (2016)*, IEEE, pp. 1–6.
- [37] BONDY, J. A., MURTY, U. S. R., AND OTHERS. **Graph theory with applications**, vol. 290. Citeseer, 1976.
- [38] WEST, D. B., AND OTHERS. **Introduction to graph theory**, vol. 2. Prentice hall Upper Saddle River, 2001.
- [39] BROUWER, A. E., AND HAEMERS, W. H. **Spectra of graphs**. Springer Science & Business Media, 2011.
- [40] CHUNG, F. R. **Spectral graph theory**. No. 92. American Mathematical Soc., 1997.
- [41] FIEDLER, M. **Algebraic connectivity of graphs**. *Czechoslovak mathematical journal* 23, 2 (1973), 298–305.
- [42] FOUSS, F., PIROTTE, A., RENDERS, J.-M., AND SAERENS, M. **Random-walk computation of similarities between nodes of a graph with application to collaborative recommendation**. *IEEE Transactions on knowledge and data engineering* 19, 3 (2007), 355–369.

- [43] OSADA, R., FUNKHOUSER, T., CHAZELLE, B., AND DOBKIN, D. **Matching 3D models with shape distributions**. In *Shape Modeling and Applications, SMI 2001 International Conference On*. (2001), IEEE, pp. 154–166.
- [44] KAZHDAN, M., FUNKHOUSER, T., AND RUSINKIEWICZ, S. **Rotation invariant spherical harmonic representation of 3D shape descriptors**. In *Symposium on geometry processing* (2003), vol. 6, pp. 156–164.
- [45] BELKIN, M., NIYOGI, P., AND SINDHWANI, V. **Manifold regularization : A geometric framework for learning from labeled and unlabeled examples**. *Journal of machine learning research* 7, Nov (2006), 2399–2434.
- [46] LÉVY, B. **Laplace-beltrami eigenfunctions towards an algorithm that "understands" geometry**. In *Shape Modeling and Applications, 2006. SMI 2006. IEEE International Conference on* (2006), IEEE, pp. 13–13.
- [47] MASOUMI, M., AND HAMZA, A. B. **Spectral shape classification : A deep learning approach**. *Journal of Visual Communication and Image Representation* 43 (2017), 198–211.
- [48] RODOLA, E., COSMO, L., LITANY, O., BRONSTEIN, M., BRONSTEIN, A., AUDEBERT, N., HAMZA, A. B., BOULCH, A., CASTELLANI, U., DO, M., AND OTHERS. **SHREC'17 : Deformable Shape Retrieval with Missing Parts**. In *Proceedings of the Eurographics Workshop on 3D Object Retrieval, Lisbon, Portugal* (2017), pp. 23–24.
- [49] CHAUDHARI, A. J., LEAHY, R. M., WISE, B. L., LANE, N. E., BADAWI, R. D., AND JOSHI, A. A. **Global point signature for shape analysis of carpal bones**. *Physics in medicine and biology* 59, 4 (2014), 961.
- [50] TARMISSI, K., AND HAMZA, A. B. **Information-theoretic hashing of 3D objects using spectral graph theory**. *Expert Systems with Applications* 36, 5 (2009), 9409–9414.
- [51] GAO, Z., YU, Z., AND PANG, X. **A compact shape descriptor for triangular surface meshes**. *Computer-Aided Design* 53 (2014), 62–69.
- [52] GEBAL, K., BÆRENTZEN, J., AANÆS, H., AND LARSEN, R. **Shape Analysis Using the Auto Diffusion Function**. In *Proceedings of the Symposium on Geometry Processing* (2009), SGP '09, pp. 1405–1413.
- [53] FANG, Y., SUN, M., AND RAMANI, K. **Temperature distribution descriptor for robust 3D shape retrieval**. In *Computer Vision and Pattern Recognition Workshops (CVPRW), 2011 IEEE Computer Society Conference on* (2011), IEEE, pp. 9–16.
- [54] LIAN, Z., GODIL, A., BUSTOS, B., DAOUDI, M., HERMANS, J., KAWAMURA, S., KURITA, Y., LAVOUÉ, G., VAN NGUYEN, H., OHBUCHI, R., AND OTHERS. **A comparison of methods for non-rigid 3D shape retrieval**. *Pattern Recognition* 46, 1 (2013), 449–461.
- [55] LI, C., AND HAMZA, A. B. **Spatially aggregating spectral descriptors for non-rigid 3D shape retrieval : a comparative survey**. *Multimedia Systems* 20, 3 (2014), 253–281.
- [56] ROSENBERG, S. **The Laplacian on a Riemannian manifold : an introduction to analysis on manifolds**, vol. 31. Cambridge University Press, 1997.
- [57] SORKINE, O. **Differential representations for mesh processing**. In *Computer Graphics Forum* (2006), vol. 25, Wiley Online Library, pp. 789–807.

- [58] TAUBIN, G. **A signal processing approach to fair surface design**. In *Proceedings of the 22nd annual conference on Computer graphics and interactive techniques* (1995), ACM, pp. 351–358.
- [59] WARDETZKY, M., MATHUR, S., KÄLBERER, F., AND GRINSPUN, E. **Discrete Laplace operators : no free lunch**. In *Symposium on Geometry processing* (2007), pp. 33–37.
- [60] BELKIN, M., SUN, J., AND WANG, Y. **Discrete laplace operator on meshed surfaces**. In *Proceedings of the twenty-fourth annual symposium on Computational geometry* (2008), ACM, pp. 278–287.
- [61] HILDEBRANDT, K., AND POLTHIER, K. **On approximation of the Laplace–Beltrami operator and the Willmore energy of surfaces**. In *Computer Graphics Forum* (2011), vol. 30, Wiley Online Library, pp. 1513–1520.
- [62] REUTER, M. **Hierarchical Shape Segmentation and Registration via Topological Features of Laplace-Beltrami Eigenfunctions**. *International Journal of Computer Vision* 89, 2 (2010), 287–308.
- [63] REUTER, M., BIASOTTI, S., GIORGI, D., PATANÈ, G., AND SPAGNUOLO, M. **Discrete Laplace–Beltrami operators for shape analysis and segmentation**. *Computers & Graphics* 33, 3 (2009), 381–390.
- [64] ZHANG, H., VAN KAICK, O., AND DYER, R. **Spectral mesh processing**. In *Computer graphics forum* (2010), vol. 29, Wiley Online Library, pp. 1865–1894.
- [65] CHANG, M.-C., AND KIMIA, B. B. **Measuring 3D shape similarity by graph-based matching of the medial scaffolds**. *Computer Vision and Image Understanding* 115, 5 (2011), 707–720.
- [66] KOKKINOS, I., BRONSTEIN, M. M., LITMAN, R., AND BRONSTEIN, A. M. **Intrinsic shape context descriptors for deformable shapes**. In *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on* (2012), IEEE, pp. 159–166.
- [67] ZOU, K., ZHANG, Z., ZHANG, J., AND ZHANG, Q. **A 3D model feature extraction method using curvature-based shape distribution**. In *Fuzzy Systems and Knowledge Discovery (FSKD), 2015 12th International Conference on* (2015), IEEE, pp. 1809–1813.
- [68] MOKHTARI, B. **Appariement de formes, recherche par forme clef**. PhD thesis, Université Mohamed Khider-Biskra, 2016.
- [69] WU, H.-Y., AND ZHA, H. **Robust consistent correspondence between 3D non-rigid shapes based on “Dual Shape-DNA”**. In *Computer Vision (ICCV), 2011 IEEE International Conference on* (2011), IEEE, pp. 587–594.
- [70] JAIN, V., AND ZHANG, H. **A spectral approach to shape-based retrieval of articulated 3D models**. *Computer-Aided Design* 39, 5 (2007), 398–407.
- [71] DAVIES, E. B., AND SAFAROV, Y. **Spectral theory and geometry**, vol. 273. Cambridge University Press, 1999.
- [72] VAXMAN, A., BEN-CHEN, M., AND GOTSMAN, C. **A multi-resolution approach to heat kernels on discrete surfaces**. In *ACM Transactions on Graphics (TOG)* (2010), vol. 29, ACM, p. 121.
- [73] RAVIV, D., BRONSTEIN, M. M., BRONSTEIN, A. M., AND KIMMEL, R. **Volumetric heat kernel signatures**. In *Proceedings of the ACM workshop on 3D object retrieval* (2010), ACM, pp. 39–44.

- [74] BRONSTEIN, M. M., AND KOKKINOS, I. **Scale-invariant heat kernel signatures for non-rigid shape recognition**. In *Computer Vision and Pattern Recognition (CVPR), 2010 IEEE Conference on* (2010), IEEE, pp. 1704–1711.
- [75] ZENG, F., QIAN, J., ZHOU, Y., YUAN, C., AND WU, C. **Improved Three-Dimensional Model Feature of Non-rigid Based on HKS**. In *International Conference on Smart Computing and Communication* (2017), Springer, pp. 427–437.
- [76] SHILANE, P., MIN, P., KAZHDAN, M., AND FUNKHOUSER, T. **The princeton shape benchmark**. In *Shape modeling applications, 2004. Proceedings* (2004), IEEE, pp. 167–178.
- [77] LI, C., AND HAMZA, A. B. **A multiresolution descriptor for deformable 3D shape retrieval**. *The Visual Computer* 29, 6-8 (2013), 513–524.
- [78] MASOUMI, M., LI, C., AND HAMZA, A. B. **A spectral graph wavelet approach for nonrigid 3D shape retrieval**. *Pattern Recognition Letters* 83 (2016), 339–348.
- [79] YE, J., AND YU, Y. **A fast modal space transform for robust nonrigid shape retrieval**. *The Visual Computer* 32, 5 (2016), 553–568.
- [80] LI, P., MA, H., AND MING, A. **A non-rigid 3D model retrieval method based on scale-invariant heat kernel signature features**. *Multimedia Tools and Applications* 76, 7 (2017), 10207–10230.
- [81] MOHAMED, W., AND HAMZA, A. B. **Deformable 3D shape retrieval using a spectral geometric descriptor**. *Applied Intelligence* 45, 2 (2016), 213–229.
- [82] HAN, R. **Computing Shape DNA using the closest point method**. *arXiv preprint arXiv :1801.04621* (2018).
- [83] RUUTH, S. J., AND MERRIMAN, B. **A simple embedding method for solving partial differential equations on surfaces**. *Journal of Computational Physics* 227, 3 (2008), 1943–1961.
- [84] ZHANG, H., AND LIU, R. **Mesh segmentation via recursive and visually salient spectral cuts**. In *Proc. of vision, modeling, and visualization* (2005), Citeseer, pp. 429–436.
- [85] CARCASSONI, M., AND HANCOCK, E. R. **Spectral correspondence for point pattern matching**. *Pattern Recognition* 36, 1 (2003), 193–204.
- [86] JAIN, V., AND ZHANG, H. **Robust 3D shape correspondence in the spectral domain**. In *Shape Modeling and Applications, 2006. SMI 2006. IEEE International Conference on* (2006), IEEE, pp. 19–19.
- [87] BÉRARD, P., BESSON, G., AND GALLOT, S. **Embedding Riemannian manifolds by their heat kernel**. *Geometric & Functional Analysis GAFA* 4, 4 (1994), 373–398.
- [88] GOLUB, G. H., AND LOAN, C. F. V. **Matrix Computations (3rd Ed.)**. Johns Hopkins University Press, Baltimore, MD, USA, 1996.
- [89] WINDHEUSER, T., VESTNER, M., RODOLÀ, E., TRIEBEL, R., AND CREMERS, D. **Optimal Intrinsic Descriptors for Non-Rigid Shape Analysis**. In *BMVC* (2014).
- [90] ANDREUX, M., RODOLA, E., AUBRY, M., AND CREMERS, D. **Anisotropic Laplace-Beltrami operators for shape analysis**. In *European Conference on Computer Vision* (2014), Springer, pp. 299–312.
- [91] BOSCAINI, D., MASCI, J., RODOLÀ, E., BRONSTEIN, M. M., AND CREMERS, D. **Anisotropic diffusion descriptors**. In *Computer Graphics Forum* (2016), vol. 35, Wiley Online Library, pp. 431–441.

- [92] LITMAN, R., AND BRONSTEIN, A. M. **Learning spectral descriptors for deformable shape correspondence**. *IEEE transactions on pattern analysis and machine intelligence* 36, 1 (2014), 171–180.
- [93] MASCI, J., RODOLÀ, E., BOSCAINI, D., BRONSTEIN, M. M., AND LI, H. **Geometric deep learning**. In *SIGGRAPH ASIA 2016 Courses* (2016), ACM, p. 1.
- [94] OSADA, R., FUNKHOUSER, T., CHAZELLE, B., AND DOBKIN, D. **Shape distributions**. *ACM Transactions on Graphics (TOG)* 21, 4 (2002), 807–832.
- [95] SMEETS, D., FABRY, T., HERMANS, J., VANDERMEULEN, D., AND SUETENS, P. **Isometric deformation modelling for object recognition**. In *International Conference on Computer Analysis of Images and Patterns* (2009), Springer, pp. 757–765.
- [96] PICKUP, D., SUN, X., ROSIN, P. L., MARTIN, R., CHENG, Z., LIAN, Z., AONO, M., HAMZA, A. B., BRONSTEIN, A., BRONSTEIN, M., AND OTHERS. **SHREC'14 track : Shape retrieval of non-rigid 3D human models**. In *Proceedings of the 7th Eurographics workshop on 3D Object Retrieval* (2014), vol. 1, Eurographics Association, p. 6.
- [97] LI, C., AND HAMZA, A. B. **Intrinsic spatial pyramid matching for deformable 3d shape retrieval**. *International Journal of Multimedia Information Retrieval* 2, 4 (2013), 261–271.
- [98] PEVZNER, K., SHARF, A., AND EL-SANA, J. **Sphere intersection 3D shape descriptor (SID)**. *Computer Aided Geometric Design* 38 (2015), 51–63.
- [99] OVSJANIKOV, M., SUN, J., AND GUIBAS, L. **Global intrinsic symmetries of shapes**. In *Computer graphics forum* (2008), vol. 27, Wiley Online Library, pp. 1341–1348.
- [100] DUTAGACI, H., CHEUNG, C., AND GODIL, A. **Evaluation of 3D interest point detection techniques via human-generated ground truth**. *The Visual Computer* 28 (2012), 901–917. 10.1007/s00371-012-0746-4.
- [101] LEE, C. H., VARSHNEY, A., AND JACOBS, D. W. **Mesh saliency**. In *ACM transactions on graphics (TOG)* (2005), vol. 24, ACM, pp. 659–666.
- [102] NOVATNACK, J., AND NISHINO, K. **Scale-dependent 3D geometric features**. In *Computer Vision, 2007. ICCV 2007. IEEE 11th International Conference on* (2007), IEEE, pp. 1–8.
- [103] CASTELLANI, U., CRISTANI, M., FANTONI, S., AND MURINO, V. **Sparse points matching by combining 3D mesh saliency with statistical descriptors**. In *Computer Graphics Forum* (2008), vol. 27, Wiley Online Library, pp. 643–652.
- [104] SIPIRAN, I., AND BUSTOS, B. **Harris 3D : a robust extension of the Harris operator for interest point detection on 3D meshes**. *The Visual Computer* 27, 11 (2011), 963.
- [105] GODIL, A., AND WAGAN, A. I. **Salient local 3D features for 3D shape retrieval**. In *Three-Dimensional Imaging, Interaction, and Measurement* (2011), vol. 7864, International Society for Optics and Photonics, p. 78640S.
- [106] HARRIS, C., AND STEPHENS, M. **A combined corner and edge detector**. In *Alvey vision conference* (1988), vol. 15, Citeseer, pp. 10–5244.
- [107] NAFFOUTI, S. E., FOUGEROLLE, Y., SAKLY, A., AND MÉRIAUDEAU, F. **A more distinctive representation for 3D shape descriptors using principal component analysis**. In *2015 16th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)* (2015), IEEE, pp. 410–416.

- [108] LI, B., SCHRECK, T., GODIL, A., ALEXA, M., BOUBEKEUR, T., BUSTOS, B., CHEN, J., EITZ, M., FURUYA, T., HILDEBRAND, K., AND OTHERS. **SHREC'12 Track : Sketch-Based 3D Shape Retrieval**. In *3DOR* (2012), pp. 109–118.
- [109] LIAN, Z., GODIL, A., FABRY, T., FURUYA, T., HERMANS, J., OHBUCHI, R., SHU, C., SMEETS, D., SUETENS, P., VANDERMEULEN, D., AND OTHERS. **SHREC'10 Track : Non-rigid 3D Shape Retrieval**. *3DOR 10* (2010), 101–108.
- [110] SIDDIQI, K., ZHANG, J., MACRINI, D., SHOKOUFANDEH, A., BOUIX, S., AND DICKINSON, S. **Retrieving articulated 3-D models using medial surfaces**. *Machine vision and applications* 19, 4 (2008), 261–275.
- [111] XIE, J., ZHU, F., DAI, G., AND FANG, Y. **Progressive shape-distribution-encoder for 3D shape retrieval**. In *Proceedings of the 23rd ACM international conference on Multimedia* (2015), ACM, pp. 1167–1170.
- [112] HAN, Z., LIU, Z., HAN, J., VONG, C.-M., BU, S., AND LI, X. **Unsupervised 3D local feature learning by circle convolutional restricted Boltzmann machine**. *IEEE Transactions on Image Processing* 25, 11 (2016), 5331–5344.
- [113] SIPIRAN, I., BUSTOS, B., SCHRECK, T., BRONSTEIN, A. M., CHOI, S., LAI, L., LI, H., LITMAN, R., AND SUN, L. **Scalability of non-rigid 3D shape retrieval**. In *Proceedings of the 2015 Eurographics Workshop on 3D Object Retrieval* (2015), Eurographics Association, pp. 121–128.
- [114] WANG, X.-L., LIU, Y., AND ZHA, H. **Intrinsic spin images : a subspace decomposition approach to understanding 3D deformable shapes**. In *Proc. 3DPVT* (2010), vol. 10, pp. 17–20.
- [115] ELAD, A., AND KIMMEL, R. **On bending invariant signatures for surfaces**. *IEEE Transactions on pattern analysis and machine intelligence* 25, 10 (2003), 1285–1295.
- [116] TABIA, H., LAGA, H., PICARD, D., AND GOSSELIN, P.-H. **Covariance descriptors for 3D shape matching and retrieval**. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (2014), pp. 4185–4192.
- [117] OHBUCHI, R., OSADA, K., FURUYA, T., AND BANNO, T. **Salient local visual features for shape-based 3D model retrieval**. In *Shape Modeling and Applications, 2008. SMI 2008. IEEE International Conference on* (2008), IEEE, pp. 93–102.
- [118] TABIA, H., PICARD, D., LAGA, H., AND GOSSELIN, P.-H. **Compact vectors of locally aggregated tensors for 3D shape retrieval**. In *Eurographics workshop on 3D object retrieval* (2013).
- [119] PAPADAKIS, P., PRATIKAKIS, I., THEOHARIS, T., PASSALIS, G., AND PERANTONIS, S. **3D Object Retrieval using an Efficient and Compact Hybrid Shape Descriptor**. In *Eurographics Workshop on 3D object retrieval* (2008).
- [120] DUTAGACI, H., CHEUNG, C. P., AND GODIL, A. **Evaluation of 3D Interest Point Detection Techniques**. In *Proceedings of the 4th Eurographics Conference on 3D Object Retrieval* (Aire-la-Ville, Switzerland, Switzerland, 2011), 3DOR '11, Eurographics Association, pp. 57–64.
- [121] YANG, Y., LIN, H., AND ZHANG, Y. **Content-based 3-D model retrieval : A survey**. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)* 37, 6 (2007), 1081–1098.

- [122] BIMBO, A. D., AND PALA, P. **Content-based retrieval of 3D models**. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)* 2, 1 (2006), 20–43.
- [123] TANGELDER, J. W., AND VELTKAMP, R. C. **A survey of content based 3D shape retrieval methods**. In *Shape Modeling Applications, 2004. Proceedings (2004)*, IEEE, pp. 145–156.
- [124] BUSTOS, B., KEIM, D. A., SAUPE, D., SCHRECK, T., AND VRANIĆ, D. V. **Feature-based similarity search in 3D object databases**. *ACM Computing Surveys (CSUR)* 37, 4 (2005), 345–387.
- [125] OVSJANIKOV, M., BRONSTEIN, A. M., BRONSTEIN, M. M., AND GUIBAS, L. J. **Shape google : a computer vision approach to isometry invariant shape retrieval**. In *Computer Vision Workshops (ICCV Workshops), 2009 IEEE 12th International Conference on (2009)*, IEEE, pp. 320–327.
- [126] QU, L., ZHAO, G., YAO, B., AND LI, Y. **Visual tracking with genetic algorithm augmented logistic regression**. *Signal, Image and Video Processing* (2017), 1–8.
- [127] KENNEDY, J. **Particle swarm optimization**. In *Encyclopedia of machine learning*. Springer, 1995, pp. 760–766.
- [128] DU, K.-L., AND SWAMY, M. **Particle swarm optimization**. In *Search and Optimization by Metaheuristics*. Springer, 2016, pp. 153–173.
- [129] DU, K.-L., AND SWAMY, M. **Ant Colony Optimization**. In *Search and Optimization by Metaheuristics*. Springer, 2016, pp. 191–199.
- [130] LADGHAM, A., HAMDAR, F., SAKLY, A., AND MTIBAA, A. **Fast MR brain image segmentation based on modified Shuffled Frog Leaping Algorithm**. *Signal, Image and Video Processing* 9, 5 (2015), 1113–1120.
- [131] WU, G., QIU, D., YU, Y., PEDRYCZ, W., MA, M., AND LI, H. **Superior solution guided particle swarm optimization combined with local search techniques**. *Expert Systems with Applications* 41, 16 (2014), 7536–7548.
- [132] WANG, S.-C., AND YEH, M.-F. **A modified particle swarm optimization for aggregate production planning**. *Expert Systems with Applications* 41, 6 (2014), 3069–3077.
- [133] WAN, J., WANG, D., HOI, S. C. H., WU, P., ZHU, J., ZHANG, Y., AND LI, J. **Deep learning for content-based image retrieval : A comprehensive study**. In *Proceedings of the 22nd ACM international conference on Multimedia (2014)*, ACM, pp. 157–166.
- [134] HINTON, G. E., OSINDERO, S., AND TEH, Y.-W. **A fast learning algorithm for deep belief nets**. *Neural computation* 18, 7 (2006), 1527–1554.
- [135] SALAKHUTDINOV, R., AND LAROCHELLE, H. **Efficient learning of deep Boltzmann machines**. In *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics (2010)*, pp. 693–700.
- [136] JI, S., XU, W., YANG, M., AND YU, K. **3D convolutional neural networks for human action recognition**. *IEEE transactions on pattern analysis and machine intelligence* 35, 1 (2013), 221–231.
- [137] HINTON, G., DENG, L., YU, D., DAHL, G. E., MOHAMED, A.-R., JAITLY, N., SENIOR, A., VANHOUCHE, V., NGUYEN, P., SAINATH, T. N., AND OTHERS. **Deep neural networks for acoustic modeling in speech recognition : The shared views of four research groups**. *IEEE Signal Processing Magazine* 29, 6 (2012), 82–97.

TABLE DES FIGURES

2.1	Représentation d'un maillage triangulaire.	9
2.2	Le vecteur de coordonnées différentielles au niveau d'un sommet se rapproche de : la direction normale et la courbure moyenne [57].	12
2.3	Illustration des angles cotangents (α_{ij} et β_{ij}) et demi-tangents (θ_{ij}^1 et θ_{ij}^2), région de Voronoï Ω_i du sommet s_i	13
2.4	Un modèle d'Eléphant et sa matrice Laplacienne creuse associée en utilisant le poids demi-tangent. Les éléments non nuls de la matrice sont représentés en bleu.	14
2.5	Visualisation des quatre premières fonctions propres (non triviales) de l'opérateur LB. De gauche à droite : un modèle de grenouille 3D codé en couleur par les valeurs des première, deuxième, troisième et quatrième fonctions propres.	15
2.6	Le vecteur de Fiedler fournit un ordre naturel pour ordonner les sommets d'un maillage. Les lignes bleues correspondent aux iso-valeurs de la première fonction propre. Nous montrons ici comment l'ordre induit par le tri des sommets par valeurs croissantes suit naturellement la forme de l'objet, même si elle n'est pas rectiligne.	16
2.7	Types de descripteurs de formes 3D [68].	17
2.8	(a) Propagation de la chaleur, ($p_t(s_i, s_j)$) à partir d'un point spécifié sur le coude de la forme humaine au reste de la forme pour un temps t donné. (b) Représentation de la signature du noyau de chaleur acquise par la diagonale de la matrice du noyau de chaleur. Comme il est indiqué, la chaleur augmente lorsque la couleur passe du noir au rouge. En outre, les valeurs maximales et minimales des courbures gaussiennes se rapportent, respectivement, à la quantité élevée et faible du $p_t(s, s)$	19
2.9	Illustration de la signature moyenne de chaleur (HMS) sur un modèle d'une main humaine [15]. La Figure (a) montre les six segments de la main en utilisant PCMS. La Figure (b) illustre la distribution HMS à travers la surface de maillage d'un modèle d'une main humaine.	20
2.10	Le descripteur de diffusion de chaleur calculé pour différents modèles [53]. Les valeurs du descripteur calculées pour les points sont représentées par une carte de couleurs graduée de la plus faible valeur en bleu à la plus importante valeur en rouge.	21

3.1	Illustration sur le modèle Centaure. L'AGPS reste similaire sous diverses poses et perturbations puisque le descripteur est quasi invariant aux déformations isométriques et semi-rigides et au bruit. La recherche de forme est simplement réalisée en utilisant la similarité d'histogramme après la quantification d'AGPS sur tous les points du maillage. Dans toutes nos figures, les couleurs bleues et rouges représentent les faibles et importantes valeurs calculées par AGPS pour tous les points de la forme.	27
3.2	Pipeline du cadre de recherche de formes basé sur TSASR [2].	29
3.3	Vue d'ensemble du descripteur SID pour une seule caractéristique. En haut à gauche : deux intersections de sphères avec des rayons différents. En bas à gauche : courbes d'intersection paramétrées correspondantes. En haut à droite : plusieurs intersections agrégées. En bas à droite : transformation de domaine fréquentiel donnant une représentation d'image 2D compacte [98].	30
3.4	Le plongement AGPS sur deux modèles (a , f) qui subissent plusieurs types de transformations (b–j). Déformations colonne par colonne du (b , g) au (e , j) sont ; changement de pose, un nouveau changement de pose, gonflement et ajout de bruit, respectivement ; les vues agrandies montrent la différence entre les formes avant et après l'ajout de bruit.	32
3.5	La signature de point globale avancée AGPS (s) effectué pour les 50 plus petites valeurs propres sur les modèles de l'Araignée, la main, et l'Icosaèdre. Les valeurs d'AGPS (s) augmentent à mesure que la couleur passe du bleu au rouge.	33
3.6	Consistance de la méthode de détection des maxima locaux (points rouges) basée sur AGPS. Le nombre de points d'intérêts détectés est 10, 6 et 5 respectivement pour chaque pose du modèle d'Eléphant, de Chat et d'homme.	35
3.7	En haut : la distribution de l'énergie en fonction du nombre de valeurs propres. Pour les $k = 50$ couples propres, le nombre j utilisé pour représenter les formes de gauche à droite est $j = 1, 3, 4, 8$ et $j = 20$, respectivement. Le premier point de la courbe qui atteint un seuil de 98% de l'énergie suggère que $j = 8$ comme nombre minimal de valeurs propres qui doit être utilisé pour une représentation consistente de forme sur le plan perceptuel. En bas : la comparaison entre l'AGPS normalisés pour un certain nombre de valeurs propres utilisées. On observe que l'écart entre les deux courbes devient marginal dès que $j = 8$	38
3.8	Exemples de formes de SHREC-2012 (en haut) et SHREC-2015 (en bas).	39
3.9	A gauche : les points caractéristiques détectés sur quatre poses du modèle de femme. A droite : Les valeurs normalisées des points caractéristiques basées sur leur AGPS tracées en fonction de leur indice. La couleur de chaque point projeté sur le plan 2D correspond à la couleur du point détecté sur la forme associée.	39
3.10	Résultat d'AGPS contre le changement topologique. La figure de gauche montre les modèles de référence. Les courts-circuits topologiques sont rajoutés dans les modèles à droite.	40

3.11 Exemples de récupération de formes utilisant le descripteur AGPS comme vecteur de caractéristiques. Les formes 3D dans la première colonne sont des requêtes d'entrée, et celles de droite sont les six premiers résultats récupérés pour chaque requête. Les modèles récupérés sont classés de gauche à droite en fonction de l'ordre croissant de dissimilarité.	41
3.12 Courbes précision-rappel pour la comparaison des descripteurs sous la base de données combinée.	43
3.13 Exemples de formes 3D à partir de la base de donnée McGill. Seules deux formes articulées sont représentées dans chacune des 10 classes d'objets.	44
3.14 Courbes P/R de notre méthode (AGPS) et six autres approches évaluées pour les parties articulées de la base de données McGill [112].	45
3.15 Détection de points saillants par plusieurs approches. De gauche à droite : vérité terrain, AGPS, Mesh Saliency, Salient points, 3D-Harris, 3D-SIFT et SD-corners.	46
3.16 Évaluation de la performance de six descripteurs sur l'ensemble B de la base de données (43 modèles, 16 sujets). Erreur de faux négatifs (côté gauche) et erreur de faux positifs (côté droit) de tous les algorithmes. Relevé de terrain obtenu avec $\sigma = 0.03$ et $n = 2$	47
4.1 Illustration des filtres passe-bas ($e^{-\lambda_k t}$) du HKS appliqués au spectre de forme. Nous montrons les fréquences 20, 30, 40, 50, 60, 70, 80, 90 et 100, respectivement.	51
4.2 Illustration des filtres passe-bande ($f_E(\lambda_k)$) du WKS appliqués au spectre de forme. Nous montrons les fréquences 20, 30, 40, 50, 60, 70, 80, 90 et 100, respectivement.	51
4.3 Comparaison de la signature du noyau d'onde (deuxième colonne) et de la signature optimisée du noyau d'onde (troisième colonne) sur deux poses du modèle d'éléphant (première colonne) en trois points différents (marqués en <i>rouge</i> , <i>vert</i> , et <i>bleu</i>). Les lignes pleines et pointillées représentent respectivement la forme en haut et en bas. Chaque signature est calculée sur $e = 100$ échelles d'énergie.	53
4.4 La distribution de l'onde sur une échelle d'énergie croissante. Les couleurs vont du bleu (valeurs basses) au rouge (valeurs élevées). Les valeurs d'onde sur chaque point de la forme changent en fonction du paramètre d'énergie dans WKS (s, e)	55
4.5 Signature du noyau d'onde en trois points différents. La distribution des ondes dans l'énergie correspond au comportement montré dans la Figure 4.4.	55
4.6 Optimisation par essaim de particules : le déplacement des essaims.	56
4.7 Organigramme de la méthode proposée.	57
4.8 Affichage de formes 3D à partir de la base de donnée SHREC-2015.	59

4.9	En haut : Points caractéristiques détectés sur les quatre poses de l'Armadillo. (a-b) : Evolution de MPSO pour déterminer $\widehat{\alpha}_{opt}$. (c-d) : Plongement CMDS des points caractéristiques en fonction de leur WKS pour $\alpha = 7$ et en fonction de leur OWKS (s, e_1) pour $\widehat{\alpha}_{opt} = 14.03$. La couleur de chaque point projeté sur le plan 2D correspond à la pose à partir de laquelle il est pris.	60
4.10	Résultat de la classification des formes. La projection CMDS des similitudes de forme calculées en utilisant, respectivement de gauche à droite, le WKS et l'OWKS.	61
4.11	Courbes P/R moyennes de notre descripteur OWKS par rapport aux autres approches appliqués sur la base de donnée SHREC-2015.	64
5.1	Représentation 3D de l'os carpien gauche pour un homme en bonne santé.	69

LISTE DES TABLES

3.1	AGPS et autres méthodes de plongement spectral et signatures de formes.	31
3.2	Temps de calculs pour AGPS et GPS sur un ordinateur de 2 GHz, 2 Duo CPU et 3G RAM. Les troisième, quatrième, cinquième et sixième colonnes montrent le temps (en seconde) de construction de la matrice Laplacienne, la résolution des paires propres, le calcul de l'AGPS et du GPS à tous les points avec $k = 50$.	37
3.3	Résultats de recherche pour le modèle de la Lunette et du Poulpe utilisant notre algorithme, GPS, HKS et HMS. La couleur jaune indique les récupérations correctes.	42
3.4	Résultats de correspondances AGPS. Chaque objet est comparé à tous les autres objets de la base de données SHREC-2012 et SHREC-2015. Chaque cellule montre la mesure de similarité moyenne $d_c(H_1, H_2)$ entre deux objets.	42
3.5	Comparaison des résultats de récupération par notre méthode (dernière rangée) avec l'état de l'art sur l'ensemble de la base de données combinée. Les chiffres en gras indiquent les meilleurs résultats de récupération.	43
3.6	Résultats de correspondances AGPS. Chaque objet est comparé à tous les autres objets de la base de données McGill. Chaque cellule montre la mesure de similarité moyenne $d_c(H_1, H_2)$ entre deux objets.	44
3.7	Comparaison des résultats de récupération de notre méthode (première rangée) avec l'état de l'art sur la base de données McGill. Les chiffres en gras indiquent les meilleurs résultats de récupération.	45
4.1	Valeurs des paramètres recommandées pour MPSO.	58
4.2	Temps de calculs pour WKS et OWKS sur un ordinateur de 2 GHz, 2 Duo CPU et 3G RAM. Les troisième, quatrième, cinquième et sixième colonnes montrent le temps (en seconde) de construction de la matrice Laplacienne, la résolution des paires propres, le calcul du WKS et du OWKS à tous les points avec $k = 300$.	59
4.3	Comparaison entre les valeurs de la fonction fitness et les valeurs de la variance avant et après l'optimisation.	61
4.4	Comparaison entre les distances inter-classe et intra-classe avant et après l'invocation de MPSO. Contrairement à WKS, OWKS conduit à une faible dispersion intra-classe et une grande dispersion extra-classe.	61

- 4.5 Résultats de recherche pour deux modèles de références (Lunette et Poulpe) par notre méthode OWKS, WKS, GPS et HKS. La couleur jaune de la forme indique les récupérations correctes. 62
- 4.6 Correspondance avant et après l'optimisation de WKS, sous SHREC-2015. Chaque forme est mise en correspondance avec toutes les autres formes de la base de données. Chaque cellule montre la mesure de dissimilarité entre deux formes sélectionnées dans la base de données. La plus petite valeur correspond au meilleur appariement. 63
- 4.7 Résultats de récupération par notre méthode (dernière ligne) comparée à l'état de l'art sur la base de données SHREC-2015. Les chiffres en gras indiquent les meilleurs résultats de récupération. 64

Résumé :

Cette thèse porte sur la reconnaissance et l'appariement de formes 3D pour des systèmes intelligents de vision par ordinateur. Elle décrit deux contributions principales à ce domaine. La première contribution est une implémentation d'un nouveau descripteur de formes construit à la base de la géométrie spectrale de l'opérateur de Laplace-Beltrami ; nous proposons une signature de point globale avancée (AGPS). Ce descripteur exploite la structure intrinsèque de l'objet et organise ses informations de manière efficace. De plus, AGPS est extrêmement compact puisque seulement quelques paires propres étaient nécessaires pour obtenir une description de forme précise. La seconde contribution est une amélioration de la signature du noyau d'onde ; nous proposons une signature du noyau d'onde optimisée (OWKS). La perfectionnement est avec un algorithme heuristique d'optimisation par essaim de particules modifié pour mieux rapprocher une requête aux autres formes appartenant à la même classe dans la base de données. L'approche proposée améliore de manière significative la capacité discriminante de la signature. Pour évaluer la performance de l'approche proposée pour la récupération de forme 3D non rigide, nous comparons le descripteur global d'une requête aux descripteurs globaux du reste des formes de l'ensemble de données en utilisant une mesure de dissimilarité et trouvons la forme la plus proche. Les résultats expérimentaux sur différentes bases de données de formes 3D standards démontrent l'efficacité des approches d'appariement et de récupération proposées par rapport aux autres méthodes de l'état de l'art.

Mots-clés : Descripteur spectral, Reconnaissance de formes, Appariement de formes, Recherche par forme clef

Abstract:

This thesis concerns recognition and matching of 3D shapes for intelligent computer vision systems. It describes two main contributions to this domain. The first contribution is an implementation of a new shape descriptor built on the basis of the spectral geometry of the Laplace-Beltrami operator; we propose an Advanced Global Point Signature (AGPS). This descriptor exploits the intrinsic structure of the object and organizes its information in an efficient way. In addition, AGPS is extremely compact since only a few eigenpairs were necessary to obtain an accurate shape description. The second contribution is an improvement of the wave kernel signature; we propose an optimized wave kernel signature (OWKS). The refinement is with a modified particle swarm optimization heuristic algorithm to better match a query to other shapes belonging to the same class in the database. The proposed approach significantly improves the discriminant capacity of the signature. To assess the performance of the proposed approach for nonrigid 3D shape retrieval, we compare the global descriptor of a query to the global descriptors of the rest of shapes in the dataset using a dissimilarity measure and find the closest shape. Experimental results on different standard 3D shape benchmarks demonstrate the effectiveness of the proposed matching and retrieval approaches in comparison with other state-of-the-art methods.

Keywords: Spectral descriptor, Shape recognition, Shape matching, Dissimilarity measure, Shape retrieval

The logo for the SPIM (École doctorale SPIM) consists of the letters 'S', 'P', 'I', and 'M' in a large, white, sans-serif font. The 'S' is stylized with a thick, orange horizontal bar behind it.