

Une approche pour la catégorisation des objets 3D basée sur la théorie des fonctions de croyance

Hedi Tabia¹

Mohamed Daoudi²

Jean-Philippe Vandeborre²

Olivier Colot¹

¹ Université Lille Nord de France / LAGIS - FRE CNRS 3303 / Université Lille 1, France.

e-mail : hedi.tabia@telecom-lille1.eu ; olivier.colot@univ-lille1.fr

² TELECOM Lille 1 / Institut TELECOM / LIFL UMR CNRS 8022 / Université de Lille 1, France.

e-mail : mohamed.daoudi@lifl.fr ; jean-philippe.vandeborre@telecom-lille1.eu

Résumé

Le groupement des objets 3D en catégories significatives est un problème très important dans le traitement des formes 3D. En introduisant une nouvelle technique de classification basée sur les fonctions de croyance, nous réussissons à catégoriser les objets 3D. Cette technique comporte deux étapes. Une première étape d'apprentissage, où les objets 3D d'une même catégorie sont traités et où un ensemble des parties représentatives de ces objets est construit, et une deuxième étape d'étiquetage, où des objets inconnus sont classifiés par catégorie. Le classifieur a été conçu et évalué sur une base de données de 400 objets 3D. Notre système atteint un taux de bonne reconnaissance de l'ordre de 85%.

Mots clefs

Catégorisation, classification, objets 3D, fonctions de croyance.

1 Introduction

L'indexation d'objet 3D est un sous-domaine très important de la vision par ordinateur et du multimédia. De nombreuses organisations ont d'importantes collections d'objets 3D sous format numérique disponibles pour un accès en ligne. L'organisation de ces collections en catégories dans le but de l'indexation est indispensable. Ces dernières années, de nombreux systèmes ont été proposés pour la recherche d'informations 3D.

Par exemple, Kazhdan et al. [1] décrivent une approche générale basée sur les harmoniques sphériques. Antini et al. [2] présentent une approche basée sur les corrélogrammes de courbures. Filali et al. [3] proposent une adaptation du k-plus proche voisin pour choisir les points de vue caractéristiques d'un modèle 3D.

Contrairement à l'indexation 3D où les objets sont comparés deux à deux, la classification 3D, qui consiste à affecter un objet requête à une catégorie, reste encore un problème ouvert. Peu de contributions telles que [4, 5] ont abordé ce problème. Leurs méthodes sont basées sur un classifieur Bayésien et sont limitées à des données très spécifiques.

Notre travail aborde le problème de catégorisation avec une approche basée sur les parties. Elle consiste à capturer un modèle compact d'une catégorie en construisant un ensemble de parties représentatives des différents objets dans cette catégorie. Dans ce but, les objets d'une même catégorie sont segmentés en plusieurs parties. Nous insistons ici sur le fait que nos parties sont des caractéristiques locales des objets et sont représentées par des descripteurs invariants.

Une fois que les parties provenant des objets de la même catégorie sont extraites, nous construisons un ensemble des parties représentatives. Cet ensemble nous permet de représenter tous les objets dans cette catégorie. Un moyen simple de construire cet ensemble est l'utilisation de techniques de quantification. Dans ce papier, nous utilisons une variante crédibiliste de k-plus proches voisins. Les centroïdes des clusters résultants servent comme des parties représentatives de notre catégorie. Ce processus est réitéré pour toutes les catégories dans l'ensemble d'apprentissage.

L'étiquetage des objets inconnus est réalisé par l'étiquetage de leurs parties associées. Ici, nous supposons qu'un objet appartient à une catégorie donnée lorsque la plupart de ses parties appartiennent à la même catégorie. Afin d'atteindre cet objectif, nous utilisons la théorie des fonctions de croyance. Plus précisément, chaque partie de l'objet à étiqueter est considérée comme une source d'informations fournissant certaines hypothèses concernant la catégorie d'appartenance de cet objet. En se basant sur ce raisonnement, les parties de l'objet sont comparées avec les parties représentatives d'une catégorie donnée et un ensemble de masses de croyance est calculé. À la suite de l'examen de chaque partie d'objet, on obtient un ensemble de *Basic Belief Assignments* (BBAs) qui peuvent être combinées en utilisant la règle de combinaison de Dempster pour former une BBA synthétisant une croyance finale concernant la catégorie de l'objet entier.

La suite du papier est organisée comme suit : dans la section 2, la phase d'apprentissage est présentée. Puis, dans la section 3, la phase de l'étiquetage est détaillée. La section 4 présente les résultats expérimentaux. La conclusion est présentée à la section 5.

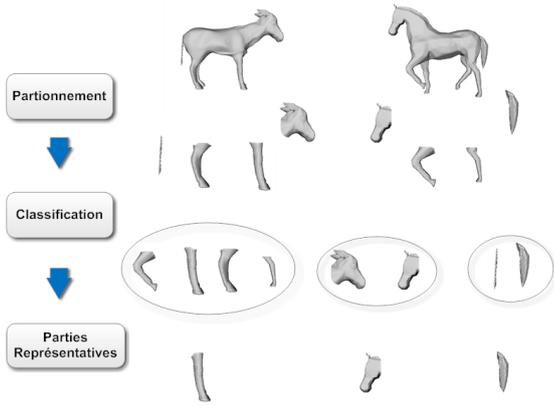


Figure 1 – L’architecture du système d’apprentissage : Etant donnée une catégorie d’objets 3D, le système permet de construire un ensemble de parties représentatives. Les objets 3D dans cette figure sont issus de la catégorie “animal” de la base SHREC07.

2 Modèle d’une catégorie

A partir d’un ensemble d’objets 3D d’apprentissage, la méthode que nous proposons pour construire le modèle de chaque catégorie est basée sur l’hypothèse suivante : “les objets 3D appartenant à la même catégorie possèdent les mêmes parties”. Plus précisément, nous supposons que chaque catégorie peut être représentée par un ensemble de parties représentatives, avec lesquelles les objets dans cette catégorie peuvent être décrits. Dans cette section, nous mettons l’accent sur la construction de cet ensemble pour chaque catégorie. La figure 1 présente les différentes étapes du processus d’apprentissage. Elle montre trois étapes principales : (1) partitionnement des objets 3D ; (2) classification des parties ; (3) calcul des parties représentatives.

2.1 Partitionnement d’objet 3D

Notre but est d’extraire les parties d’objets d’une même catégorie. Ces parties seront ensuite utilisées pour trouver les parties représentatives ainsi que le modèle de la catégorie. Il faut bien noter que le partitionnement peut être sémantique ou non. Il y a plusieurs manières de partitionner un objet 3D. La façon la plus simple se base sur l’échantillonnage des points. La technique consiste à sélectionner un ensemble de sommets du maillage 3D et à associer à chaque point de l’échantillon une sous-partie de l’objet. Pour notre analyse, nous utilisons la technique des points les plus éloignés [6]. Pour calculer cet échantillonnage, Peyré et Cohen ont proposé un algorithme basé sur le Fast Marching [7].

Après le partitionnement des objets, les parties sont représentées par des descripteurs locaux qui décrivent leur géométrie. La performance de tout classifieur dépend fortement de la capacité discriminante des descripteurs. Choisir le bon descripteur est crucial. Les descripteurs doivent être

suffisamment riches pour discriminer entre les différentes parties, et en même temps ils doivent être invariants sous les différentes transformations que peut subir une forme. Nous présentons ici quelques descripteurs qui peuvent être utilisés dans notre analyse.

- **GD2** : Le GD2 est une distribution locale des distances géodésiques. Il a été utilisé par Osada et al. [8] pour la reconnaissance des formes 3D en mesurant les distances euclidiennes entre des points de surface tirés aléatoirement.
- **Gcords** : Le descripteur des cordes géodésiques est défini comme une distribution de distances géodésiques d’un point source à un ensemble de points. Ce descripteur est une extension de la distribution de cordes euclidiennes introduite par Paquet et Rioux. [9].
- **HSI** : Histogramme d’indices de forme. L’indice de forme, d’abord introduit par Koendrink et al. [10], est défini comme une fonction de deux courbures principales sur la surface 3D.

2.2 Parties représentatives

Dans cette section, nous proposons une méthode pour trouver des parties représentatives de chaque catégorie. Le but de la méthode consiste à rechercher une partition stable dans l’ensemble $P^C = \{P_1, \dots, P_N\}$ (l’ensemble de toutes les parties dans une catégorie donnée C) vis-à-vis d’une règle de décision \mathbb{R} . La règle de décision utilisée est une extension aux fonctions de croyance de l’algorithme des plus proches voisins qui a été introduit par Zouhal et Denoeux [11]. Cet algorithme consiste à construire à partir d’un ensemble d’apprentissage $L = \{(P_i, \omega_i), i = 1, \dots, n\}$ une fonction \mathbb{R} par la méthode classique des k plus proches voisins. Dans sa version initiale, chaque voisin de P dans L est considéré comme une source d’informations quantifiant le degré de croyance sur l’appartenance du vecteur P à une classe dans $\Omega = \{\omega_i\}_{i=1, \dots, n}$ (dans notre cas P désigne une partie). Ainsi, une fonction de croyance m_k est directement construite en utilisant les informations apportées par les vecteurs P_k situés dans le voisinage du vecteur inconnu P par :

$$m_k(\omega_k) = \chi e^{(-\gamma_k D^2)}$$

$$m_k(\Omega) = 1 - m_k(\omega_k) \quad (1)$$

$$m_k(A) = 0 \quad \forall A \in 2^\Omega \setminus \{\Omega, \{\omega_k\}\}$$

où D est la distance au vecteur P_k , χ un paramètre d’affaiblissement et γ_k est un paramètre de la classe ω_k déterminé par un processus d’optimisation proposé par Zouhal et Denoeux [11]. La masse de croyance allouée au singleton $\{\omega_k\}$ est donc un affaiblissement de la distance entre P et P_k . Les fonctions de croyance obtenues pour chaque voisin sont ensuite fusionnées sous la forme d’une fonction de croyance m définie sur Ω par la règle de combinaison de Dempster. Enfin, la décision quant à l’étiquetage de la partie P est prise en analysant la fonction de probabilité pignistique déduite à partir de m .

La règle de discrimination \mathbb{R} ainsi construite permet d'introduire un algorithme itératif qui consiste à construire une suite de partitions crédales de P^C étant donné un nombre de classes. A partir d'une partition aléatoire initiale, chaque vecteur à classer est tiré aléatoirement dans P^C et est ensuite classé par la règle de décision \mathbb{R} . L'itération se termine lorsqu'une partition stable est obtenue c'est-à-dire lorsque l'on n'observe aucun changement dans l'attribution des étiquettes. Le nombre de classes à l'itération initiale est fixé par le nombre d'individus dans P^C , ce qui permet d'obtenir un algorithme non paramétrique. Dans les itérations suivantes, le nombre de classes est réduit naturellement par l'attribution des vecteurs à une classe dans Ω . Ainsi l'algorithme obtenu peut être déroulé de la manière décrite dans l'Algorithme 1.

La partition finale obtenue est une partition crédale, c'est-à-dire que chaque partie est caractérisée par une fonction de croyance qui quantifie le degré d'appartenance. Il est à noter que le problème du conflit qui peut apparaître lors de la combinaison des fonctions de croyance devient crucial et qu'il doit être résolu avec un opérateur adéquat. Dans notre cas, nous avons opté pour l'utilisation d'un opérateur purement conjonctif.

Algorithme 1 : Classification des parties d'objets 3D d'une même catégorie

- 1: Chaque partie dans P^C est considérée comme une classe. Ω est initialisé comme : $\Omega = \{\omega_1, \dots, \omega_N\}$. N est le nombre des parties dans P^C .
 - 2: **repeat**
 - 3: Ordonner aléatoirement les parties dans P^C .
 - 4: **for all** P_i dans P^C en respectant l'ordre **do**
 - 5: Calculer m_k (pour chaque k -plus proche voisin de P_i)
 - 6: Calculer m_i par combinaison des m_k utilisant la règle de Dempster
 - 7: Calculer $BetP$ la probabilité pignistique induite par m_i
 - 8: Changer l'étiquette de P_i dans Ω
 - 9: **end for**
 - 10: Analyser et réduire le nombre de classes dans Ω
 - 11: **until** Obtention d'une partition stable de Ω
-

Une fois le processus de regroupement des parties terminé, nous calculons le centroïde de chaque cluster. Les centroïdes ainsi déterminés présentent les parties représentatives de la catégorie C . Dans ce papier, une partie représentative est notée par R .

3 Etiquetage d'un nouvel objet 3D

Pendant le processus d'étiquetage, chaque catégorie d'objets 3D est considérée comme un ensemble de parties représentatives. L'étiquetage des objets 3D inconnus est réalisé par l'étiquetage de leurs parties associées. Un objet appartient à une catégorie donnée lorsque la plupart de ses parties appartiennent à la même catégorie. Dans cette

Similarity	C_1	C_2	...	C_J
P_1	$S(P_1, C_1)$	$S(P_1, C_2)$...	$S(P_1, C_J)$
P_2	$S(P_2, C_1)$	$S(P_2, C_2)$...	$S(P_2, C_J)$
...
P_I	$S(P_I, C_1)$	$S(P_I, C_2)$...	$S(P_I, C_J)$

Tableau 1 – Similarités entre parties 3D et catégories d'objets 3D.

section, nous mettons l'accent sur la mise en correspondance entre les parties d'un objet inconnu et les parties représentatives de chaque catégorie ainsi que l'étiquetage de l'objet 3D en entier. Soit O un objet 3D à classer. On suppose que O est composé de N parties $\{P_i\}_{1 \leq i \leq N}$. Disposant de J catégories $\Omega_C = \{C_j\}_{1 \leq j \leq J}$. Une catégorie C_j est représentée par n_j parties représentatives $\{R_{jr}\}_{1 \leq r \leq n_j}$

3.1 Mise en correspondance des parties 3D

La relation entre une partie 3D P_i et une catégorie donnée C_j est calculée en se basant sur la théorie des fonctions de croyance. Notre idée consiste à considérer les parties représentatives $\{R_{jr}\}_{1 \leq r \leq n_j}$ comme des sources indépendantes donnant des informations concernant cette relation. Plus formellement, nous définissons une fonction de masse m_{ij} , qui quantifie le degré de croyance donné à l'hypothèse " P_i correspond à C_j ".

P_i correspond à C_j si P_i tend vers une partie représentative de C_j . Dans le cas contraire, nous considérons que P_i correspond à $\overline{C_j}$ (le complément de C_j dans Ω_c). Ainsi la masse m_{ij} peut s'écrire sous la forme :

$$\begin{aligned}
 m_{ij}(C_j) &= \mu \cdot S(P_i, C_j) \\
 m_{ij}(\overline{C_j}) &= \mu \cdot (1 - S(P_i, C_j)) \\
 m_{ij}(\Omega_c) &= 1 - \mu
 \end{aligned} \tag{2}$$

$S(P_i, C_j) = e^{-D(P_i, R_{P_i})}$ est une fonction de la distance entre la partie P_i et sa plus proche partie représentative R_{P_i} dans la catégorie C_j . μ est un coefficient d'affaiblissement associé à la catégorie C_j . La table 1 montre les similarités $S(P_i, C_j)$ sous forme d'une matrice où les lignes représentent les parties de l'objet inconnu et les colonnes représentent les J catégories.

À la suite de l'examen de chaque catégorie, on obtient J BBAs comme le montre la table 2. Ces masses peuvent être combinées en utilisant la règle de combinaison de Dempster pour former une BBA m_i synthétisant une croyance définitive sur l'attachement de P_i à chaque catégorie. La table 3 montre la BBA résultante m_i .

3.2 Etiquetage de l'objet 3D

Afin d'obtenir une décision finale sur la catégorie de l'objet entier, toutes les masses m_i $i \in [1..I]$ sont combinées en utilisant la règle de Dempster de combinaison. Ainsi le processus d'étiquetage d'un objet inconnu peut se résumer dans l'algorithme 2.

BBA	C_1			...			C_J		
P_i	$m_{i1}(C_1)$	$m_{i1}(C_1)$	$m_{i1}(\Omega_c)$	$m_{iJ}(C_J)$	$m_{iJ}(C_J)$	$m_{iJ}(\Omega_c)$

Tableau 2 – Modélisation d'une partie avec une masse de croyance.

BBA	C_1	...	C_J	$\{C_1, C_2\}$...	Ω_c	Φ
P_i	$m_i(C_1)$...	$m_i(C_J)$	$m_i(\{C_1, C_2\})$...	$m_i(\Omega_c)$	$m_i(\Phi)$

Tableau 3 – La distribution finale de la masse de croyance pour une partie P_i .

Algorithm 2 : Etiquetage d'un objet requête

- 1: Données : Etant donné J catégories $\Omega_c = \{C_j\}_{1 \leq j \leq J}$. Chaque catégorie est représentée par n_j parties représentatives $\{R_{jr}\}_{1 \leq r \leq n_j}$. Etant donné un objet inconnu O .
 - 2: Partitionner O en N parties $\{P_i\}_{1 \leq i \leq N}$.
 - 3: **for all** P_i dans $\{P_i\}_{1 \leq i \leq N}$ **do**
 - 4: **for all** C_j dans Ω_c **do**
 - 5: Trouver la partie représentative R_{P_i} la plus proche de P_i .
 - 6: Calculer m_{ij} (g to eq.2).
 - 7: **end for**
 - 8: Calculer m_i par combinaison des masses m_{ij} en utilisant la règle de combinaison de Dempster
 - 9: **end for**
 - 10: Calculer m par combinaison des m_i en utilisant la règle de combinaison de Dempster
 - 11: Dédire les probabilités pignistiques induites par m
 - 12: Etiqueter O suivant les probabilités pignistiques.
-

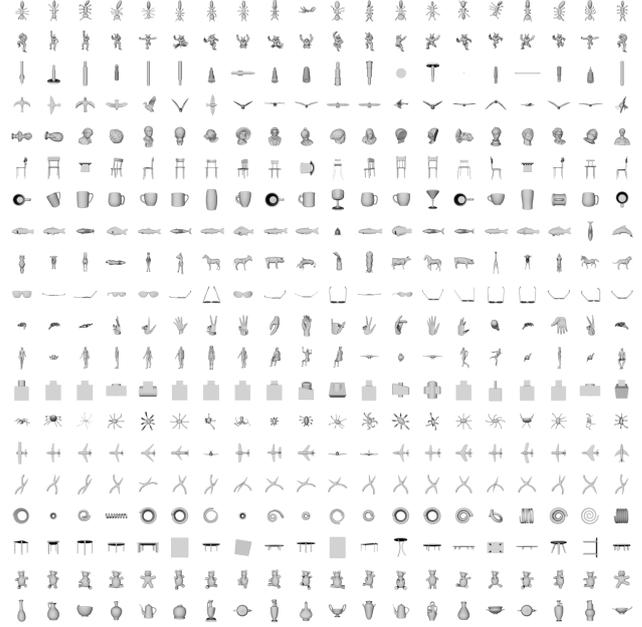


Figure 2 – Aperçu sur la base d'objets 3D SHREC07.

4 Résultats expérimentaux

Dans cette section, nous présentons les résultats expérimentaux, la base de données et l'évaluation. Les algorithmes que nous avons décrits dans les sections précédentes ont été développés avec MATLAB. Le système se compose d'une phase off-ligne pour l'apprentissage, où les parties représentatives de chaque catégorie sont extraites et une phase on-ligne pour l'étiquetage. Au cours de nos expériences, nous évaluons notre méthode selon deux points de vue. Qualitativement, nous présentons quelques résultats sous forme d'une matrice de confusion. Quantitativement, nous comparons le taux de bonne reconnaissance de notre méthode avec le classifieur bayésien Huber et al.[4]. En outre, nous évaluons le taux de bonne reconnaissance de notre classifieur en fonction des descripteurs utilisés.

4.1 Description de la base SHREC07

La base a été proposée par Marini et al. [12] dans le cadre de la compétition SHREC07 pour l'indexation des objets 3D. Les objets de cette base présentent des variations diverses allant du changement de pose, jusqu'à des transformations non-rigides au sein d'une même classe en passant par des modifications topologiques. La figure 2 montre la base de données SHREC07.

4.2 Résultats de la catégorisation

D'un point de vue qualitatif, la figure 3 montre une matrice de confusion. Les lignes de cette matrice correspondent à des parties extraites d'un objet requête correspondant à un modèle humain 3D. Les colonnes de cette matrice correspondent aux différentes catégories indiquées dans les lignes de la figure 2 (dans le même ordre). La brillance de chaque élément (i, j) , dans cette matrice, est proportionnelle à la similarité entre les parties et les catégories. Les éléments d'une couleur froide représentent les meilleures correspondances, tandis que les éléments de couleur plus chaude indiquent une mauvaise correspondance. On remarque, dans cette visualisation, que les parties de l'objet humain ont tendance à converger vers la catégorie 12 qui correspond à celle des humains dans la figure 2. Ces résultats confirment notre hypothèse que les objets 3D dans la même catégorie partagent les mêmes parties.

La figure 4 montre une deuxième matrice de confusion. Les lignes de cette matrice représentent un ensemble d'objets 3D requêtes (les objets correspondent à la dernière colonne de la figure 2) et les colonnes représentent les catégories présentées par les lignes de la figure 2. La brillance des

éléments sur la diagonale de la matrice montre l'efficacité de notre classifieur.

Plus quantitativement, le tableau 4 montre les résultats de comparaison entre notre classifieur crédibiliste et le classifieur bayésien [4] (GD2 a été utilisé comme descripteur de parties dans cette comparaison). Notre classifieur a montré respectivement un taux de bonne reconnaissance de 89,6 % et 81,25% sur les données d'apprentissage et les données de test. Ce qui veut dire 84% de taux de bonne reconnaissance sur l'ensemble de la base entière. L'utilisation d'un classificateur bayésien [4] ne rapporte que 66,63% de taux de bonne reconnaissance.

En plus de l'utilisation du descripteur GD2, nous avons également testé les descripteurs HSI et Gcords. Le taux de bonne reconnaissance du classifieur basé sur HSI et Gcords n'a pas dépassé 69%, tandis qu'avec GD2 nous avons réussi à atteindre 84%. Ces résultats montrent l'efficacité de GD2 et son pouvoir discriminant dans la description des formes 3D. Une combinaison des GD2 et HSI donne un meilleur taux de bonne reconnaissance que GD2. La table 5 présente les résultats de la classification en fonction de ces descripteurs à la fois indépendants et d'autres combinés. La combinaison est basée sur la distance moyenne.

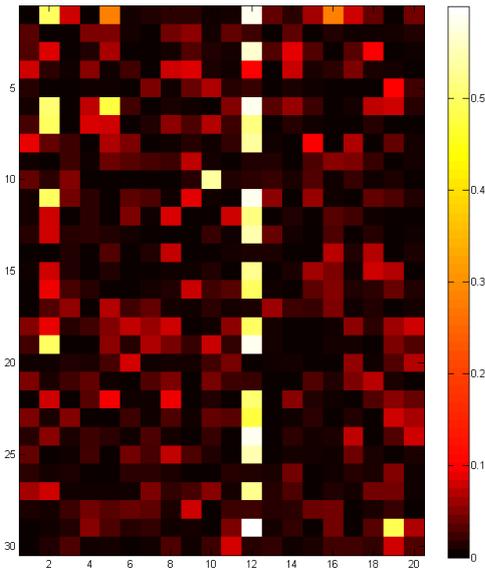


Figure 3 – Matrice de confusion des parties d'un objet humain en fonction de l'ensemble des catégories d'apprentissage. Les lignes présentent les parties requêtes. Les colonnes présentent les catégories d'objets. (GD2 a été utilisé comme descripteur de parties dans cette comparaison)

4.3 Base d'apprentissage

Les performances de la classification dépendent de la taille de l'ensemble d'apprentissage : Plus cet ensemble est important, plus la performance de classification augmente. La table 6 compare le taux de bonne reconnaissance de la classification (basée sur le descripteur GD2) en fonction de

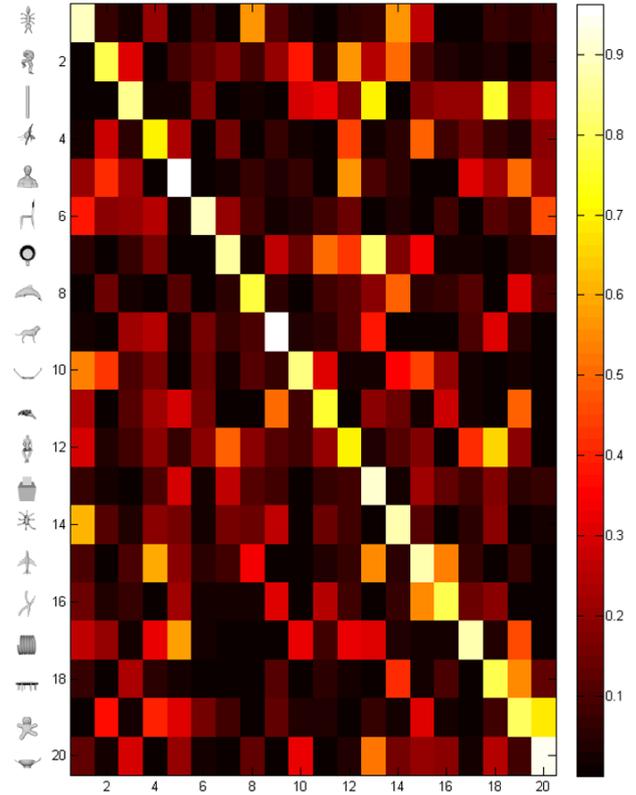


Figure 4 – Matrice de confusion d'un exemple de catégorisation d'objets 3D. Les lignes correspondent à des objets requêtes. Les colonnes présentent les catégories d'objets. (GD2 a été utilisé comme descripteur de parties dans cette comparaison)

la taille de l'ensemble d'apprentissage. Nous pouvons remarquer que l'augmentation de l'ensemble d'apprentissage améliore le taux de bonne reconnaissance de la classification.

5 Conclusion

Dans ce papier, nous avons présenté une nouvelle méthode pour catégoriser les objets 3D. Cette méthode se base sur la théorie des fonctions de croyance. Le processus de catégorisation est totalement automatisé. Il comporte deux étapes différentes. Une étape d'apprentissage qui consiste à trouver le modèle d'une catégorie, comporte de même deux étapes : 1) partitionnement d'objet et 2) la construction des parties représentatives. La deuxième étape est l'étiquetage d'un objet inconnu dans lequel les fonctions de croyance ont été également utilisées. Le classifieur a été évalué sur une base de données de 400 modèles 3D. Notre système réussit à atteindre un taux de bonne reconnaissance de classification dépassant le 84%.

Références

- [1] M. Kazhdan, T. Funkhouser, et S Rusinkiewicz. Rotation invariant spherical harmonic representation of

Base de test	Taille de la base	Notre méthode	
		Taux de bonne reconnaissance (%)	classifieur bayésien Taux de bonne reconnaissance (%)
Base d'apprentissage	100	89.6	68.9
Base de test	300	81.25	65.5
Base entière	400	84	66.63

Tableau 4 – *Resultats de classification en fonction des classifieurs.*

Test	GD2	HSI	Gcords	GD2-HSI	GD2-Gcords	HSI-Gcords
Base d'apprentissage	89.6	68.3	71.6	91.2	90.2	80.4
Base de test	81.25	67.25	67.6	83.3	81.5	74.3
Base entière	84	67.6	68.9	85.9	84.4	76.33

Tableau 5 – *Le taux de bonne reconnaissance de classification en fonction des descripteurs utilisés.*

Apprentissage Taille	Test Taille	Taux de bonne reconnaissance %
100	400	84%
150	400	84.2%
200	400	85.6%
300	400	87.5%
400	400	88.1%

Tableau 6 – *Résultats de classification en fonction de la taille de la base d'apprentissage.*

3d shape descriptors. *Geometry Processing, Aachen, Germany*, 2003.

- [2] G. Antini, S. Berretti, A. Del Bimbo, et P. Pala. Retrieval of 3d objects using curvature correlograms. Dans *IEEE International Conference on Multimedia & Expo*, July 2005.
- [3] T. Filali Ansary, M. Daoudi, et J-P. Vandeborre. A bayesian 3D search engine using adaptive views clustering. *IEEE Transactions on Multimedia*, 9(1) :78–88, January 2007.
- [4] D. Huber, A. Kapuria, R. Donamukkala, et M. Hebert. Parts-based 3d object classification. Dans *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2004.
- [5] R. Donamukkala, D. Huber, A. Kapuria, et M. Hebert. Automatic class selection and prototyping for 3-d object classification. *3-D Digital Imaging and Modeling (3DIM)*, 2005.
- [6] T-F. Gonzalez. Clustering to minimize the maximum intercluster distance. *Theoretical Computer Science*, 1985.
- [7] G. Peyre et L-D. Cohen. Geodesic remeshing using front propagation. *International Journal of Computer Vision*, 69 :145–156, 2006.
- [8] R. Osada, T. Funkhouser, B. Chazelle, et D. Dobkin. Shape distributions. *ACM Transactions on Graphics*, 21(4) :807–832, 2002.
- [9] E. Paquet et M. Rioux. Nefertiti : a query by content system for three-dimensional model and image databases management. *Image and Vision Computing*, 17 :157–166, 1999.

- [10] J. Koenderink et A. van Doorn. Surface shape and curvature scales. *Image and Vision Computing*, 10 :557–565, 1992.
- [11] L-M. Zouhal et T. Denoeux. An evidence-theoretic k-nn rule with parameter optimization. *IEEE Transactions on Systems*, 28 :263–271, May 1998.
- [12] S. Marini, L. Paraboschi, et S. Biasotti. Shape retrieval contest 2007 : Partial matching track. *SHREC (in conjunction with IEEE Shape Modeling International)*, pages 13–16, 2007.