

Recherche d'objets 3D à partir de photos

Tarik Filali Ansary, Jean-Phillipe Vandeborre, Mohamed Daoudi

LIFL (UMR USTL/CNRS 8022)
GET / INT / TELECOM Lille 1
email: {filali, vandeborre, daoudi}@telecom-lille1.eu

Abstract

Dans cet article, nous proposons une méthode pour la recherche d'un modèle 3D à partir d'une ou plusieurs photos. Nous proposons une méthode de sélection "optimale" de vues 2D pour représenter un modèle 3D, et une approche probabiliste Bayésienne pour la recherche de modèles 3D à partir de photos ou de dessins utilisant ces vues. Le procédé de sélection des vues caractéristiques s'appuie sur un algorithme de classification adaptatif et utilise un modèle de distribution statistique de scores pour sélectionner le nombre optimal de vues. Nous introduisons également une approche Bayésienne pour évaluer la probabilité de correspondance entre la ou les vues requêtes et les modèles 3D. Nous présentons nos résultats sur la base de données Princeton (Princeton 3D Shape Benchmark database) composée de 1814 modèles 3D et avec 50 images requêtes (photographies, dessins, images synthétiques, etc.). Un moteur de recherche 3D en ligne sur le Web [3Dr] est disponible pour permettre au lecteur de tester notre approche. Ce moteur est, à notre connaissance, le premier à autoriser la recherche de modèles 3D à partir d'une ou plusieurs photographies ou dessins.

1. Introduction

Le développement des technologies 3D (scanners, logiciels de modélisation, etc.) fait que la création de modèles 3D est de plus en plus aisée. De plus, grâce à l'Internet, de nombreux modèles 3D sont téléchargeables gratuitement ou pour une somme modique. Tout ceci a pour conséquence un besoin croissant d'outils et de techniques efficaces pour indexer et retrouver des modèles 3D.

Récemment, des moteurs de recherche 3D ont vu le jour, comme le moteur de l'Université de Princeton (États-Unis) [FMK*03], celui de l'Université Nationale de Taïwan [CTSO03], le *Ogden IV system* au *National Institute of Multimedia Education* (Japon) [Suz01], le moteur de l'Université d'Utrecht (Pays-bas) [TV03] et celui de l'Université de Konstanze (Allemagne) [Vra03].

La recherche d'un modèle 3D dans une base de données à partir d'une vue, d'un dessin ou d'une photo est certainement le procédé de recherche le plus intuitif. Malgré cette simplicité apparente, il s'agit d'un problème scientifique majeur. L'idée principale de cette démarche peut être formulée ainsi : deux modèles 3D sont similaires s'ils se ressemblent

de différents points de vue. Par conséquent, les solutions proposées se fondent sur la mise en correspondance d'une ou plusieurs vues (photo, dessin, etc.) avec les modèles 3D qui y ressemblent.

Funkhouser et al. [FMK*03] utilisent ce type de similarité pour implanter une interface de requête basée sur un dessin 2D. En pré-traitement, chaque modèle 3D est décrit par 13 contours obtenus grâce à 13 vues prises à des angles de vue différents.

Chen et al. [CTSO03] utilisent cent projections orthographiques d'un objet et les décrivent par les moments de Zernike et les descripteurs de Fourier. Une accélération de la recherche est également obtenue par un procédé de rejet rapide des modèles non pertinents.

Pour un état de l'art très complet sur l'indexation de modèle 3D, le lecteur pourra se référer à Tangelder et Veltkamp [TV04].

A notre connaissance, aucun moteur de recherche 3D ne permet d'effectuer des recherche à partir d'une ou plusieurs photos. Dans cet article, nous proposons une méthode qui répond à ce problème. Le but de cette méthode est double :

fournir un algorithme de sélection d'un ensemble optimal de vues caractéristiques pour un modèle 3D donné, et proposer une méthode probabiliste Bayésienne pour l'indexation des modèles 3D à partir de ces vues. Dans la section 2, nous présentons les principes de notre méthode de sélection des vues caractéristiques. En section 3, nous exposons notre méthode probabiliste pour retrouver les modèles 3D à partir de photos. Puis, les résultats obtenus sur une base de 1814 modèles 3D (base de Princeton) et 50 photographies, et notre moteur de recherche de modèles 3D en ligne sont présentés avant de conclure.

2. Sélection des vues caractéristiques

Puisque nous nous appuyons sur les vues caractéristiques d'un modèle 3D pour l'indexation, il convient de commencer par la méthode de sélection des vues caractéristiques d'un modèle 3D.

Soit $D_b = \{M_1, M_2, \dots, M_N\}$ une collection composée de N modèles 3D. Chaque modèle 3D de cette collection doit être représenté par un ensemble de vues. Dans ce but, pour chaque modèle 3D de la collection, le processus consiste à générer un ensemble de vues initiales, puis à réduire cet ensemble de vues à celles, et seulement celles, qui le caractérisent au mieux. Ces vues sont appelées vues caractéristiques.

2.1. Ensemble initial des vues

Pour créer l'ensemble des vues initiales d'un modèle 3D de la collection, des vues (projections perspectives) sont calculées à partir de différents points de vue. Ces points de vue sont équi-répartis sur la sphère englobante de l'objet 3D grâce à une facétisation régulière en triangles de celle-ci. Dans notre implémentation, nous utilisons 320 vues initiales.

Ces vues représentent des silhouettes du modèles 3D, ce qui augmente l'efficacité et la robustesse de nos vues. Pour décrire chacune de ses vues 2D, 49 coefficients de moments de Zernike [KH90] sont utilisés. Grâce à ce descripteurs, la comparaison des images est robuste à la translation, à la rotation et à la mise à l'échelle.

2.2. Sélection des vues caractéristiques

Étant donné que chaque vue 2D est représentée par 49 coefficients de moments de Zernike, choisir un sous-ensemble de vues caractéristiques qui représente au mieux un modèle 3D (320 vues) est équivalent à choisir un sous-ensemble de X points pour représenter un ensemble initial de $N = 320$ points dans un espace à 49 dimensions. La résolution de ce problème nécessite une technique de classification.

Une des méthodes les plus utilisées pour la classification est l'algorithme des *K-means* [DH73]. Son intérêt réside dans sa simplicité et sa convergence vers un minima locale.

Par contre, l'inconvénient de cette méthode est l'obligation du choix *a priori* du nombre de classes K .

Le fait de vouloir adapter le nombre des vues caractéristique à la complexité géométrique de l'objet 3D rend l'utilisation de *K-means* inappropriée pour notre méthode. Pour résoudre ce problème, nous utilisons une méthode dérivée de *K-means*, où au lieu de choisir un nombre fixe de classes, nous fixons un intervalle où le nombre optimale de classes pourra être choisi. Dans notre implémentation, l'intervalle est de $[1, \dots, 40]$. Dans cet article, nous supposons que le nombre maximal de vues caractéristique d'un modèle 3D est 40. Ce nombre est un bon compromis entre la vitesse d'exécution, la taille du descripteur et la représentation du modèle 3D. Notons que les vues caractéristiques correspondent au centre des groupes formés par l'algorithme des *K-means*.

Dans la suite de cette section, nous présentons notre méthode de sélection des vues caractéristiques. Pour illustrer notre propos, les figures 1 et 2 donnent juste un exemple schématique dans un espace bi-dimensionnel, alors qu'en pratique l'espace possède 49 dimensions correspondant aux 49 coefficients des moments de Zernike.

Pour initialiser notre algorithme, nous commençons par désigner une vue aléatoirement comme vue caractéristique, ensuite nous déroulons l'algorithme des *K-means* ($K = 1$). Le centre du groupe est la vue caractéristique.

Pour ajouter de nouvelles vues caractéristiques, nous nous inspirons de l'idée des *X-means* [PM00]. Tout d'abord, pour chaque groupe de vues représenté par une vue caractéristique (figure 1(a)), nous choisissons les deux vues les plus éloignées dans cette classe (figure 1(b)), et nous déroulons un algorithme de *K-means local* (avec $K = 2$) avec comme vues de départ la paire de vues les plus éloignées choisie. Un *K-means local* signifie que seules les vues qui sont dans le groupe auquel appartient la vue caractéristique sont employées dans ce *K-means*.

Une fois que l'algorithme a désigné deux nouvelles vues caractéristique, une question se pose : est-ce que les deux nouvelles vues caractéristiques représentent mieux ce groupe de vues que la vue caractéristique originale seule ? Pour répondre à cette question, nous utilisons le critère informationnel BIC (Bayesian Information Criteria) [Sch78], qui nous donne un score de correspondance entre le modèle de représentation (en utilisant une ou deux vues caractéristiques) et l'ensemble des vues (figure 2(a)). Plus le score est élevé, meilleure est la représentation.

Selon les résultats du critère BIC, le modèle de représentation (une ou deux vues caractéristiques) avec le plus haut score BIC est choisi (figure 2(b)). Les groupes de vues qui ne sont pas bien représentées par une vue caractéristique auront ainsi droit à une plus grande attention, en augmentant le nombre des vues caractéristiques qui les représentent.

Nous continuons d'alterner entre la sélection de nouvelles

vues caractéristiques et le déroulement de l'algorithme des *K-means* jusqu'à ce que la limite supérieure pour le nombre de vues caractéristique (40) soit atteinte. Pendant ce processus, nous sauvegardons l'ensemble des vues caractéristiques ayant le plus haut score BIC.

Cet ensemble de vues caractéristique ayant le plus grand score BIC sera celui choisi pour représenter le modèle 3D [FAVD07].




Figure 1: *K-means local sur chaque partie avec $K = 2$.*




Figure 2: *Sélection des vues représentatives (une ou deux vues) qui ont le plus haut score BIC.*

3. Approche probabiliste pour l'indexation 3D

L'idée principale de notre approche probabiliste est que toutes les vues d'un modèle 3D n'ont pas la même importance. Il y a des vues qui représentent mieux le modèle 3D que d'autres. D'autre part, les objets simples (par exemple un cube ou une sphère) peuvent être à la base d'objets plus complexes, ainsi ils ont une plus grande probabilité d'apparition.

Dans cette section, nous présentons notre approche probabiliste qui tient compte des remarques précédemment citées.

Chaque modèle 3D de la collection D_b est représenté par un ensemble de vues de caractéristique $V = \{V_1, V_2, \dots, V_C\}$, avec C le nombre des vues caractéristiques. À chaque vue caractéristique correspond un ensemble de vues représentées appelées V_r .

Comme nous l'avons mentionné précédemment, nous voulons retrouver les modèles 3D qui correspondent à une

Algorithm 1 Algorithme de sélection des vues caractéristiques.

Nombre de vues caractéristiques, $K = 1$

tantque Nombre des vues caractéristique < 40 **faire**

Appliquer l'algorithme des *K-means* sur toutes les vues (les centres de départ sont les vues caractéristiques).

Calculer le score BIC, et sauvegarder l'ensemble des vues caractéristique si le score BIC est supérieur.

pour tout groupe de vue **faire**

Choisir les deux vues les plus éloignées dans le groupe.

Appliquer l'algorithme des *K-means* sur le groupe (avec $K = 2$).

Choisir le modèle de représentation avec le plus grand score BIC (entre l'utilisation de la vue caractéristique originale ou les deux nouvelles).

fin pour

fin tantque

Sélectionner l'ensemble des vues caractéristiques ayant le plus grand score BIC.

ou plusieurs photos requêtes. Nous supposons que dans une requête $Q = \{I_1, I_2, \dots, I_K\}$ toutes les K images représentent le même objet. Soit une requête Q , nous souhaitons retrouver le modèle $M_i \in D_b$ qui est le plus similaire à la requête Q . Ce modèle est celui qui a la probabilité $P(M_i|Q)$ la plus élevée. Sachant qu'une requête se compose d'une ou plusieurs images, $P(M_i|Q)$ peut s'écrire :

$$P(M_i|Q) = \frac{1}{K} \sum_{k=1}^K P(M_i|I_k),$$

Avec K le nombre d'images dans la requête Q . Soit H l'ensemble de toutes les hypothèses de correspondance entre l'image requête I_k et un modèle M_i , $H = \{h_1^k \vee h_2^k \vee \dots \vee h_N^k\}$. Une hypothèse h_p^k signifie que la vue p du modèle 3D correspond à l'image requête I_k . Le signe \vee représente l'opérateur logique *ou*. Notons que si une hypothèse h_p^k est vraie, toutes les autres hypothèses sont fausses. $P(M_i|I_k)$ peut être exprimée par $P(M_i|H^k)$. Nous avons :

$$P(M_i|H^k) = \sum_{j=1}^N P(M_i, V_{M_i}^j | h_j^k)$$

La somme $\sum_{j=1}^N P(M_i, V_{M_i}^j | h_j^k)$ peut être réduite à la seule hypothèse vraie $P(M_i, V_{M_i}^j | H_j^k)$. En effet, la conception de notre algorithme, qui sélectionne des vues caractéristiques différentes, fait qu'une image de la requête Q peut correspondre seulement à une seule vue caractéristique du modèle M_i . Nous choisissons la vue caractéristique avec la probabilité maximale.

$$P(M_i|Q) = \sum_{k=1}^K \frac{1}{K} \text{Max}_j(P(M_i, V_{M_i}^j | h_j^k)) \quad (1)$$

En utilisant le théorème de Bayes, nous avons :

$$P(M_i, V_{M_i}^j | h_j^k) = \frac{P(h_j^k | V_{M_i}^j | M_i) P(M_i)}{P(h_j^k)}. \quad (2)$$

Nous avons aussi :

$$P(h_j^k | V_{M_i}^j | M_i) = P(h_j^k | V_{M_i}^j, M_i) P(V_{M_i}^j | M_i), \quad (3)$$

et,

$$P(h_j^k) = \sum_{i=1}^N \sum_{j=1}^{\hat{v}} P(h_j^k | V_{M_i}^j, M_i) P(V_{M_i}^j | M_i) P(M_i). \quad (4)$$

En utilisant (1), (2), et (3) on obtient :

$$P(M_i, V_{M_i}^j | h_j^k) = \quad (5)$$

$$\frac{P(h_j^k | V_{M_i}^j, M_i) P(V_{M_i}^j | M_i) P(M_i)}{\sum_{i=1}^N \sum_{j=1}^{\hat{v}} P(h_j^k | V_{M_i}^j, M_i) P(V_{M_i}^j | M_i) P(M_i)}.$$

Enfin,

$$P(M_i | Q) = \sum_{k=1}^K \frac{1}{K} \quad (6)$$

$$\text{Max}_j \left(\frac{P(h_j^k | V_{M_i}^j, M_i) P(V_{M_i}^j | M_i) P(M_i)}{\sum_{i=1}^N \sum_{j=1}^{\hat{v}} P(h_j^k | V_{M_i}^j, M_i) P(V_{M_i}^j | M_i) P(M_i)} \right).$$

Comme mentionné avant, tous les modèles tridimensionnels dans la collection n'ont pas la même probabilité d'apparition. La conception de notre algorithme de choix des vues caractéristiques fait que plus un modèle tridimensionnel est simple, plus le nombre de ses vues caractéristiques est petit. Pour modéliser le fait que plus le nombre de vues d'un modèle M_i est grand, plus la probabilité du modèle est petite, nous estimons $P(M_i)$, la probabilité pour observer un modèle tridimensionnel M_i , par :

$$P(M_i) = \frac{e^{(-\alpha N(V_{M_i})/N(V))}}{\sum_{i=1}^N e^{(-\alpha N(V_{M_i})/N(V))}}, \quad (7)$$

Où $N(V_{M_i})$ est le nombre de vues caractéristiques du modèle M_i , $N(V)$ est le nombre de vues caractéristiques total pour l'ensemble des modèles 3D de la collection D_b . α est un coefficient qui réduit l'effet des petites valeurs de l'exponentiel dans $P(M_i)$.

D'autre part, il y a des vues qui contiennent plus d'informations que d'autre. Nous supposons que plus le nombre de vues représentées $N(Vr_{M_i}^j)$ par une vue caractéristique $V_{M_i}^j$ est grand, plus cette vue caractéristique est importante et plus l'information qu'elle contient sur le modèle tridimensionnel est grande. Ainsi, nous avons défini $P(V_{M_i}^j | M_i)$ la probabilité d'observer la vue caractéristique j du modèle M_i par :

$$P(V_{M_i}^j | M_i) = \frac{e^{(BN(Vr_{M_i}^j)/N(Vr_{M_i}))}}{\sum_{j=1}^{\hat{v}} (e^{(BN(Vr_{M_i}^j)/N(Vr_{M_i}))})}, \quad (8)$$

Où $N(Vr_{M_i}^j)$ est le nombre des vues représentées par la vue caractéristique j du modèle M_i , $N(Vr_{M_i})$ est le nombre total des vues représentées par le modèle M_i . Le coefficient β est utilisé pour réduire l'effet des petites valeurs de la probabilité des vues. Nous utilisons les valeurs $\alpha = \beta = 1/100$ qui donnent les meilleurs résultats pendant nos expériences [3Dr].

La valeur $P(h_j^k | V_{M_i}^j, M_i)$ correspond à la probabilité que, sachant que nous observons la vue caractéristique j du modèle M_i , cette vue correspond à l'image k de la requête Q :

$$P(h_j^k | V_{M_i}^j, M_i) = \frac{e^{-D(I_k, V_{M_i}^j)}}{\sum_{j=1}^{\hat{v}} e^{-D(I_k, V_{M_i}^j)}}, \quad (9)$$

Où $D(I_k, V_{M_i}^j)$ est la distance euclidienne entre les coefficients des moments de Zernike de l'image k de la requête Q et $V_{M_i}^j$ la j ème vue caractéristique du modèle tridimensionnel M_i .

Pour résumer, dans cette section nous avons présenté notre cadre Bayésien de recherche de modèle 3D qui prend en compte le nombre de vues caractéristiques du modèle et de l'importance (quantité de l'information) de ses vues.

4. Résultats expérimentaux et moteur de recherche 3D en ligne

Dans cette section, nous présentons le processus expérimental et les résultats que nous avons obtenus. Les algorithmes que nous avons décrits dans les sections précédentes ont été développés en utilisant le langage C++ et la bibliothèque *OpenInventor* de TGS. Le système se compose d'un algorithme de sélection des vues caractéristique et d'un procédé de recherche en ligne.

Dans notre méthode, la taille de chaque modèle a été normalisé de sorte que la distance euclidienne moyenne entre les points sur sa surface et le centre de masse soit 0.5. Ensuite, tous les modèles ont été normalisés pour la translation en déplaçant leur centre de la masse à l'origine du repère global.

La sélection des vues caractéristiques prend environ 18 secondes par modèle sur un PC doté d'un Pentium IV 2.4 GHz et 2 Go RAM. Dans le processus en ligne, la comparaison d'une image requête à la collection des 1814 modèles 3D prend environ 1 seconde.

Pour évaluer notre méthode, nous avons utilisé la base de comparaison de descripteurs 3D *Princeton Shape Benchmark database* (PSB) [Pri04] couramment utilisée dans la communauté d'indexation de forme 3D. *Princeton Shape Benchmark database*, apparue en 2004, est une base de données de 1814 modèles 3D collectés sur l'Internet. Il existe plusieurs classifications données aux objets dans la base de données. Pendant nos expériences nous avons employé la classification la plus fine, composée de 161 classes. La plupart des classes contiennent des objets avec une fonction par-

ticulière (par exemple voitures). Cependant, il y a également des cas où des objets avec la même fonction sont répartis dans différentes classes selon leurs formes (par exemple, tables rondes et tables rectangulaires).

En utilisant notre méthode, le nombre moyen des vues caractéristiques pour la base PSB est de 23 vues par modèle. La taille moyenne pour décrire un modèle 3D est de 1 113 octets.

Pour évaluer les algorithmes que nous avons présentés dans les sections précédentes, nous avons choisi 50 images à partir d'Internet. Les images correspondent à 10 classes de la base PSB : avions, bicyclettes, chaises, chiens, pistolets, marteaux, humains bras levés, hélicoptères, pots de fleurs et épées. Les images se composent de six croquis, de six images synthétisées et de 38 vraies photos de différentes tailles.

Comme les photos requêtes sont comparées aux vues caractéristiques des modèles 3D, une étape de pré-traitement est nécessaire. L'extraction des moments de Zernike des vues caractéristiques et des images requêtes est comme suit :

1. Transformer l'image requête en une image de niveaux de gris.
2. Obtenir l'image de contour à partir de l'image de niveaux de gris en utilisant le *filtre de Canny* [Can86] et la binariser de telle sorte que les frontières de l'objet soit composées de pixels blanc.
3. Normaliser l'image binarisée pour obtenir l'invariance à la mise à échelle.
4. Faire correspondre l'origine de l'image à l'origine de l'objet pour obtenir l'invariance à la translation.
5. Extraire les coefficients des moments de Zernike à partir du second ordre jusqu'au douzième.



Figure 3: Deux images-requêtes et leurs images de contours correspondantes.

La Figure 3 montre deux images de la base de données d'images-requêtes et de leurs images de contours correspondantes. Dans nos tests, nous utilisons des images avec un arrière plan simple. Ce problème peut être partiellement résolu en utilisant un algorithme de segmentation plus sophistiqué, mais ceci n'est pas le sujet de cet article.

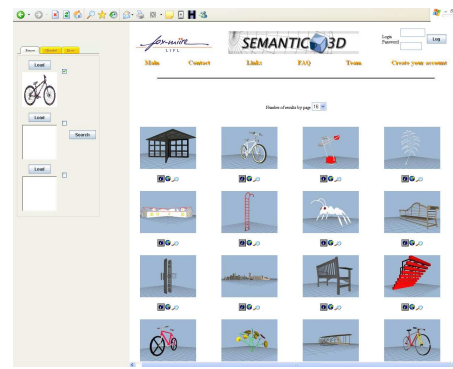


Figure 4: Résultats de la recherche avec une photo.

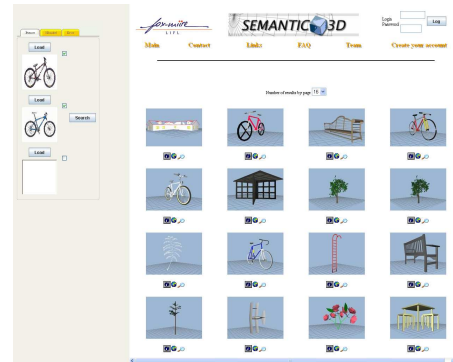


Figure 5: Résultats de la recherche avec deux photos.

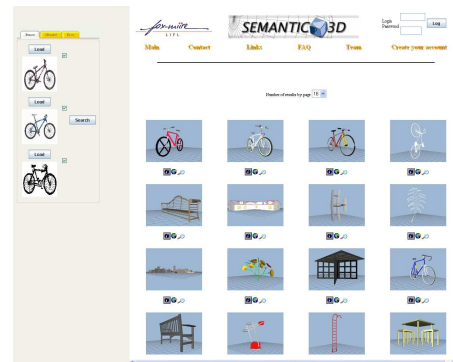


Figure 6: Résultats de la recherche avec trois photos.

Les figures 4, 5 et 6 présentent les résultats d'une requête utilisant respectivement, une, deux et trois images d'une bicyclette. Le côté gauche des figures représente les images requêtes et le côté droit représente les 16 premiers modèles 3D retournés par notre moteur de recherche. Des sept modèles 3D représentant une bicyclette dans la base de données, trois sont dans les seize modèles 3D retournés par la requête utilisant une seule photo (figure 4). Ce nombre augmente

à quatre sur sept quand nous utilisons deux images (figure 5). En utilisant trois images (figure 6) nous avons retrouvé cinq des sept modèles 3D dans les seize premiers résultats retournés.

Pour une analyse plus fine des performances, une étude en terme de courbe Rappel/Précision est maintenant présentée. Deux critères sont utilisés pour calculer cette courbe: Le *Rappel* qui représente le nombre de réponses positives obtenues au rang N sur le nombre d'éléments de la classe de l'objet requête Q , et la *Précision* qui représente le nombre de réponses positives au rang N sur le nombre total de réponses obtenues A . Ceci peut être noté de la façon suivante :

$$\text{Rappel} = N/Q, \text{Précision} = N/A,$$

Pour chacune des 10 classes d'images, nous présentons cinq courbes Rappel/Précision moyenne correspondante à l'utilisation d'une, deux, trois, quatre et cinq images.

Les figures 7 à 16 présentent les courbes Rappel/Précision pour les dix classes d'images. Notons que l'utilisation d'un nombre plus grand d'images dans la requête améliore la précision des résultats.

Dans les figures 9, 10, 11, le gain en précision est de 26% en utilisant deux images au lieu d'une. Le gain peut être jusqu'à 78% en utilisant quatre images au lieu d'une suivant comme l'illustre la figure 15. De façon générale, notre méthode fonctionne tout à fait bien sur un dessin, des images de synthèse (ou vues du modèles 3D), ou des photos.

Pour expérimenter nos algorithmes et pour tester la validité de nos résultats, nous avons développé un moteur de recherche 3D accessible publiquement en ligne. Notre moteur de recherche est accessible à partir de n'importe quel dispositif ayant un navigateur Web (PC, PDA, Smart-Phone, etc.) [3Dr].

5. Conclusion

Dans cet article, nous avons présenté une méthode d'indexation de modèles 3D basée sur la similarité entre des vues caractéristiques 2D. Pour cela, nous proposons une méthode de sélection optimale des vues caractéristiques – en pratique de 1 à 40 vues – pour un modèle 3D qui dépend de la complexité du modèle en question. Nous proposons également une approche probabiliste basée sur ces vues pour retrouver des modèles 3D à partir d'une ou plusieurs photos. Nos expériences ont été conduites sur la base de données de l'Université de Princeton (*Princeton Shape Benchmark Database*) composée de 1814 modèles 3D. Les courbes Rappel/Précision présentées sur un ensemble de 50 photos réparties en 10 classes montrent les très bons résultats de notre approche. Le gain de précision en utilisant plus d'une photo atteint jusqu'à 78%.

Les applications de ce travail sont nombreuses : navigation dans des catalogues de modèles 3D, recherche de modèles CAO pour l'industrie automobile, etc. Enfin, pour démontrer les performances de nos méthodes, nous avons

développé un moteur de recherche de modèles 3D accessible en ligne [3Dr].

6. Remerciements

Ce travail est soutenu par le réseau d'excellence européen Delos No. 507618 – <http://www.delos.info>.

References

- [3Dr] Fox-miire 3D retrieval system. <http://www-rech.telecom-lille1.eu/3dretrieval>.
- [Can86] CANNY J. F.: A computational approach to edge detection. *IEEE Trans. Pattern Analysis and Machine Intelligence* 8, 6 (1986), 679–698.
- [CTSO03] CHEN D. Y., TIAN X. P., SHEN Y. T., OUYOUNG M.: On visual similarity based 3D model retrieval. In *Eurographics* (2003), vol. 22, pp. 223–232.
- [DH73] DUDA R. O., HART P. E.: Pattern classification and scene analysis. *John Wiley and Sons* (1973).
- [FAVD07] FILALI ANSARY T., VANDEBORRE J.-P., DAOUDI M.: A bayesian 3d search engine using adaptive views clustering. *IEEE Trans. on Multimedia* (January 2007).
- [FMK*03] FUNKHOUSER T., MIN P., KAZHDAN M., HADERMAN A., DOBKIN D., JACOBS D.: A search engine for 3D models. *ACM Transactions on Graphics* 22, 1 (2003), 83–105.
- [KH90] KHOTANZAD A., HONG Y. H.: Invariant image recognition by Zernike moments. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 12, 5 (May 1990), 489–497.
- [PM00] PELLEG D., MOORE A.: X-means: Extending k-means with efficient estimation of the number of clusters. In *International Conference on Machine Learning* (2000), pp. 727–734.
- [Pri04] Princeton shape benchmark, 2004. <http://shape.cs.princeton.edu/benchmark>.
- [Sch78] SCHWARZ G.: Estimating the dimension of a model. *The Annals of Statistics* 6 (1978), 461–464.
- [Suz01] SUZUKI M. T.: A search engine for polygonal models to support development of. 3d e-learning applications. In *In The Tenth International World Wide Web Conference Poster Proceedings* (2001), pp. 182–183.
- [TV03] TANGELDER J. W., VELTKAMP R. C.: Polyhedral model retrieval using weighted point sets. In *International Conference on Shape Modeling and Applications* (2003), pp. 119–131.
- [TV04] TANGELDER J. W. H., VELTKAMP R. C.: A survey of content-based 3D shape retrieval methods. In *IEEE Shape Modeling International* (2004), pp. 145–156.
- [Vra03] VRANIC D. V.: An improvement of rotation invariant 3D shape descriptor based on functions on concentric spheres. In *IEEE International Conference on Image Processing* (2003), pp. 757–760.




Figure 7: Courbes Rappel/Précision et les images-requêtes pour la classe avions.




Figure 8: Courbes Rappel/Précision et les images-requêtes pour la classe bicyclettes.




Figure 9: Courbes Rappel/Précision et les images-requêtes pour la classe chaises.




Figure 10: Courbes Rappel/Précision et les images-requêtes pour la classe chiens.




Figure 11: Courbes Rappel/Précision et les images-requêtes pour la classe pistolets.



Figure 12: Courbes Rappel/Précision et les images-requêtes pour la classe marteaux.




Figure 13: Courbes Rappel/Précision et les images-requêtes pour la classe humains.




Figure 14: Courbes Rappel/Précision et les images-requêtes pour la classe hélicoptères.



Figure 15: Courbes Rappel/Précision et les images-requêtes pour la classe pots de fleurs.




Figure 16: Courbes Rappel/Précision et les images-requêtes pour la classe épées.