



Heat Kernel Signature pour la sélection et la classification d'objets - application aux géo-modèles 3D

François Meunier, Christophe Marsala, Laurent Castanié

► To cite this version:

François Meunier, Christophe Marsala, Laurent Castanié. Heat Kernel Signature pour la sélection et la classification d'objets - application aux géo-modèles 3D. La 5ème édition des journées “ Big Data Mining and Visualization ”, Jun 2016, Metz, France. hal-01368249

HAL Id: hal-01368249

<https://hal.sorbonne-universite.fr/hal-01368249>

Submitted on 21 Sep 2016

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Heat Kernel Signature pour la sélection et la classification d'objets

- application aux géo-modèles 3D

François Meunier^{*,**} Christophe Marsala^{*} Laurent Castanié^{**}

^{*}Sorbonne Universités, UPMC Univ Paris 06, CNRS, LIP6 UMR 7606, 4 place Jussieu 75005 Paris

^{**}Total Exploration-Production, Tour Coupole, La Défense, 2 Place Jean Millier, 92078 Paris

1 Contexte et objectifs

Dans le cadre de la prospective pétrolière à Total, les géologues créent, à partir d'images sismiques reconstituées grâce à des ondes acoustiques envoyées dans le sol, un géo-modèle 3D censé représenter les principales couches et failles de la zone. Ce géo-modèle est ensuite, en fonction des phénomènes que l'on y trouve, classé selon les ensembles pertinents auxquels il se rattache. Notre objectif est d'aider l'utilisateur dans cette classification.

Il existe à l'heure actuelle de nombreuses méthodes visant à extraire des descripteurs d'objets 3D. Néanmoins, les méthodes actuelles Alexandre (2012) ne permettent pas de comprendre quelles sous-parties d'un objet pourraient être discriminantes et pourquoi elles le seraient Shaiek (2013).

2 Approche proposée

Dans ce travail, nous proposons une méthode basée sur l'adaptation des *time series shapelets* de Ye et Keogh (2009) aux structures 3D irrégulières. Pour ce faire, il est d'abord nécessaire d'extraire des sous-parties de l'objet. Ces sous-parties sont extraites aléatoirement, l'étude de Wistuba et al. (2015) permettant d'affirmer que la précision n'est pas dégradée lors d'une sélection non exhaustive des candidats. Par la suite, de ces extraits sont issus des descripteurs d'objets 3D les décrivant au mieux. Dans cette représentation, il n'est pas envisageable de mesurer la proximité des points par une distance Euclidienne en raison de l'irrégularité du maillage. C'est la raison pour laquelle notre choix s'est porté sur le *Heat Kernel Signature* (HKS), descripteur local utilisé pour la première fois par Sun et al. (2009), adapté aux réseaux de neurones profonds (deep learning) par Fang et al. (2015), et invariant selon l'isométrie et robuste aux changements géométriques (échelle, rotation, etc...).

Une fois les attributs extraits, il convient de chercher à sélectionner les plus pertinents pour la classification en cours. Cela est réalisé grâce au test de *Fisher*, qui est, d'après nos propres tests et ceux, plus anciens, de Siou (2011), plus rapide et plus performant que celui, plus classique, de la maximisation de gain à base de calcul d'entropie.

La dernière étape de l'apprentissage est d'apprendre ces caractéristiques pour pouvoir utiliser l'expérience emmagasinée. Des forêts aléatoires sont donc utilisées, et le nombre d'arbre est fixé par validation croisée au sein du jeu d'apprentissage.

3 Résultats expérimentaux

Notre méthode a été testée sur les données libres du Princeton Shape Benchmark (¹PSB).

Les résultats montrent que notre méthode devient plus performante que la méthode globale à partir de 300 extraits, et est plus rapide en dessous de 600 extraits. De plus, ces derniers ne correspondant qu'à une partie du véritable objectif de cet algorithme (exhiber à l'utilisateur des sous-parties discriminantes pour l'aider à la compréhension de la classification), le vrai critère de réussite n'est pas quantifiable. Cela nécessite pour être évalué une mise en pré-production au sein du métier ciblé afin de se confronter aux besoins des géologues. Bien que n'ayant eu le temps de tester sur des jeux de données suffisamment variés ainsi que de comparer avec des méthodes existantes, les résultats obtenus semblent relativement bons, l'apprentissage n'ayant eu lieu que sur un nombre très restreint d'objets 3D.

Le point fort de la méthode, outre sa faculté à justifier ses prédictions, semble être la bonne capacité à apprendre sur un faible nombre d'éléments. De plus, la prise en compte de seulement certaines sous-parties de l'objet permet de rendre l'algorithme plus rapide que s'il s'était agi d'une méthode globale.

4 Conclusion et perspectives

Nous avons, dans cette étude, proposé une nouvelle méthode de classification d'objets 3D avec, chose inédite, justification de cette dernière par exhibition des éléments les plus discriminants. A la croisée des techniques employées pour les séries temporelles et le traitement d'image, notre méthode vise à aider le géologue à mieux comprendre les zones clefs pour comprendre un ensemble géologique. Cette nouvelle méthode pourrait être appliquée à d'autres contextes.

Références

- Alexandre, L. A. (2012). 3D Descriptors for Object and Category Recognition : a Comparative Evaluation. In *Workshop on Color-Depth Camera Fusion in Robotics at the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Vilamoura, Portugal.
- Fang, Y., J. Xie, G. Dai, M. Wang, F. Zhu, T. Xu, et E. Wong (2015). 3D Deep Shape Descriptor. pp. 2319–2328.
- Shaiek, A. (2013). *3D object recognition with points of interest*. Theses, Ecole Nationale Supérieure des Mines de Paris.

1. <http://shape.cs.princeton.edu/benchmark/> accessed on 2016/04/07.

- Siou, L. K. A. (2011). *Modélisation des crues de bassins karstiques par réseaux de neurones. Cas du bassin du Lez (France)*. Ph. D. thesis, Université de Montpellier II.
- Sun, J., M. Ovsjanikov, et L. Guibas (2009). A Concise and Provably Informative Multi-scale Signature Based on Heat Diffusion. pp. 1383–1392.
- Wistuba, M., J. Grabocka, et L. Schmidt-Thieme (2015). Ultra-Fast Shapelets for Time Series Classification. *CoRR abs/1503.05018*.
- Ye, L. et E. Keogh (2009). Time Series Shapelets : A New Primitive for Data Mining. In *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD '09, New York, NY, USA, pp. 947–956. ACM.

Summary

This article proposes a new approach for supervised classification of 3D objects. In particular, it gives a justification to the results as discriminant extracted sub-surfaces using the *Heat Kernel Signature* and the *Fisher test*. For Total, this need for classification is initially applied to large 3D structures geological basins, the relevant elements depending on sub-parts.