

# MATCHING 3D EFICIENTE USANDO DESCRIPTORES LOCALES



## BENAMÍN BUSTOS

Profesor Asociado Departamento de Ciencias de la Computación, Universidad de Chile. Director del Grupo de Investigación PRISMA e Investigador Joven en el Núcleo Milenio Centro de Investigación de la Web Semántica. Doctor en Ciencias Naturales, Universidad de Konstanz, Alemania (2006); Magister en Ciencias mención Computación (2002) e Ingeniero Civil en Computación (2001), Universidad de Chile. Líneas de investigación: Bases de Datos Multimedia, Búsqueda por Similitud, Recuperación de Información Multimedia basada en Contenido.  
bebustos@dcc.uchile.cl

**ESTE TRABAJO DE INVESTIGACIÓN FUE REALIZADO EN CONJUNTO CON IVÁN SPIRÁN (SECCIÓN INGENIERÍA INFORMÁTICA, PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ), JAKUB LOKOC Y TOMAS SKOPAL (SIRET RESEARCH GROUP, FACULTY OF MATHEMATICS AND PHYSICS, CHARLES UNIVERSITY IN PRAGUE) [SLB+].**

El matching de objetos 3D ha sido un área de investigación muy activa en los últimos años. Esto se debe principalmente a la mayor disponibilidad de escáneres 3D de bajo costo, por ejemplo el Microsoft Kinect, y a que hay muchas áreas de aplicación práctica que se benefician de la investigación en esta área, por ejemplo patrimonio cultural, arqueología, medicina, industria del entretenimiento, biología, manufactura industrial, y biometría, entre otras. Es por esto que cualquier avance en la calidad y eficiencia de los algoritmos de matching 3D puede tener un impacto directo en todos los dominios mencionados.

Los primeros métodos de matching 3D propuestos en la literatura [BKS+05] se enfocaron en calcular un descriptor, llamado vector característico, que es un vector en  $\mathbb{R}^d$  que describe globalmente un modelo 3D. Estos vectores característicos pueden utilizarse, por ejemplo, para implementar un motor de búsqueda por similitud de objetos 3D, que permite encontrar modelos 3D cuya geometría es similar a otro modelo 3D, el objeto de consulta. A esto se le conoce como el problema de matching global. Dada la naturaleza de estos descriptores para objetos

3D, a los que denominaremos “descriptores globales”, no permiten resolver desafíos interesantes del área como el problema de matching parcial. En este nuevo problema, lo que se quiere resolver es: dado una parte de un modelo 3D, por ejemplo obtenida a través de un escaneo parcial de un objeto, encontrar los objetos relevantes en una colección de datos. La gran diferencia de este nuevo problema es que ahora solo se cuenta con información parcial para realizar la búsqueda, lo que dificulta el uso de descriptores globales.

Recientemente, una gran parte de la investigación en el área se ha concentrado en definir “descriptores locales” para modelos 3D, que toman en consideración características locales de los modelos para calcular muchos vectores característicos, no solo uno como en el caso de los descriptores globales. Esto permite tener descripciones de zonas acotadas del modelo 3D, y no requieren conocer el modelo completo para calcular estos atributos. La Figura 1, a continuación, muestra un esquema de cómo se puede resolver el problema de matching parcial 3D usando descriptores locales. En la práctica, los descriptores locales han mostrado ser más eficaces que los descriptores globales para resolver el problema del matching parcial de modelos 3D.

En general, la mayoría de los trabajos científicos en el área se han enfocado en proponer algoritmos eficaces de matching 3D. Sin embargo, con respecto al tema de la eficiencia, es decir algoritmos que puedan resolver rápidamente el problema, no ha habido muchas propuestas. Es para



FIGURA 1. MATCHING PARCIAL 3D USANDO DESCRIPTORES LOCALES.

esto que muchas de las técnicas actuales de matching 3D basadas en descriptores locales tienen problemas para resolver el problema en colecciones grandes de objetos 3D. Este problema se evidenció durante la realización del benchmark estándar "SHREC'13 Track: Large-Scale Partial Shape Retrieval Using Simulated Range Images" [SMB+13], en donde varios equipos participaron en la tarea de resolver matching parcial en modelos 3D en una colección grande (para el área) de modelos 3D. Para este benchmark, se inscribieron diez equipos que querían hacer competir sus algoritmos de matching parcial, y el plazo para enviar los resultados era de un mes. Sin embargo, para el final del benchmark sólo dos equipos pudieron entregar resultados. El resto de los equipos tuvo que retirarse porque sus algoritmos eran demasiado lentos para el tamaño del conjunto de datos y tenían problemas para manejar las vistas parciales de los modelos. Esto mostró que era relevante estudiar el tema de la eficiencia del matching 3D, en particular usando descriptores locales que son los más adecuados para resolver el problema del matching parcial, dado que para el futuro solo cabe esperar que las colecciones de modelos 3D sigan creciendo en tamaño.

En el Proyecto Fondecyt 1140783, "Efficient 3D Shape Matching Using Local Descriptors" desarrollamos algoritmos para resolver el problema descrito. En este artículo se describe un método basado en el enfoque métrico para búsqueda por similitud, que permite realizar el matching parcial de modelos 3D en forma eficiente.

## CONCEPTOS BÁSICOS

A continuación se introducen los conceptos relevantes para entender el algoritmo propuesto de matching parcial de modelos 3D.

### HEAT KERNEL SIGNATURES

El proceso de difusión de calor sobre un manifold compacto  $S$  se rige por la ecuación del calor:

$$\Delta_S(x, t) = -\frac{\partial u(x, t)}{\partial t}$$

donde  $\Delta_S$  es el operador de Laplace-Beltrami de  $S$  y  $u(x, t)$  es la distribución del calor sobre  $S$  en el tiempo  $t$ . La solución a esta ecuación es  $K_t(x, y)$ , denominado el kernel de calor. Ésta es una solución con una fuente puntual de calor en  $x$ , e intuitivamente corresponde a la cantidad de calor transferido de  $x$  a  $y$  en el tiempo  $t$ . Para un manifold compacto, el kernel de calor se puede expresar como los valores y vectores propios del operador de Laplace-Beltrami:

$$K_t(x, y) = \sum_{i=0}^{\infty} e^{-\lambda_i t} v_i(x) v_i(y)$$

donde  $\lambda_i$  es el  $i$ -ésimo valor propio y  $v_i(\cdot)$  es el  $i$ -ésimo vector propio correspondiente a un punto dado. Sun et al. [SOG09] demostraron formalmente que el kernel de calor tiene propiedades

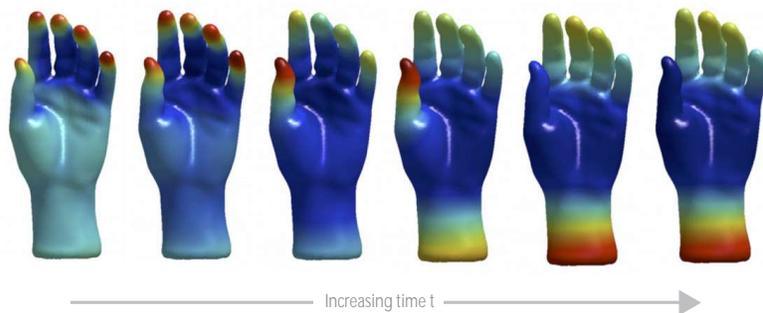


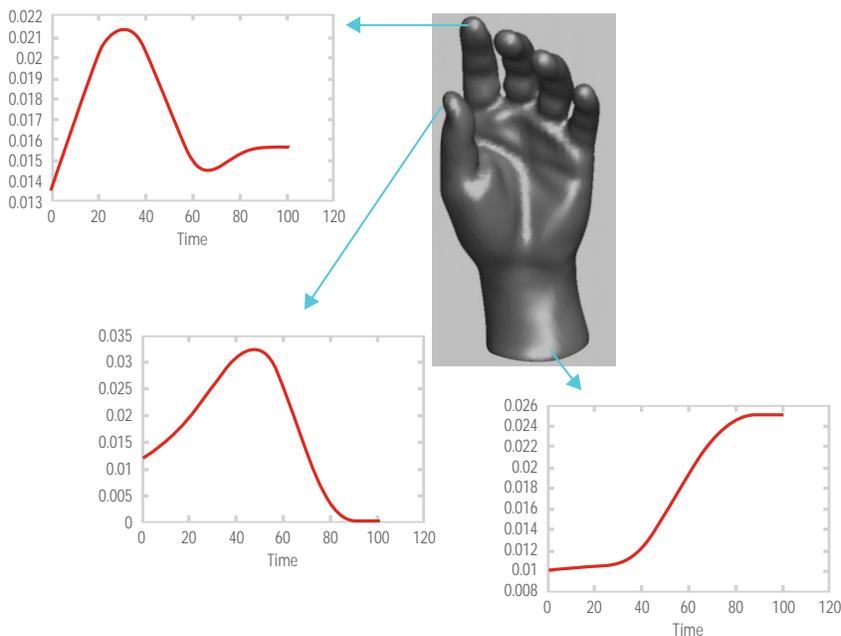
FIGURA 2. DISTRIBUCIÓN DEL CALOR EN EL TIEMPO. LOS COLORES VAN DESDE EL AZUL (VALORES BAJOS) AL ROJO (VALORES ALTOS). EL VALOR DE CALOR EN CADA PUNTO CAMBIA DE ACUERDO A LOS PARÁMETROS EN  $K_t(x, x)$ .

interesantes, por ejemplo es estable a perturbaciones en la superficie del modelo 3D.

Para obtener un descriptor usando el kernel de calor se calcula el valor  $K_t(x, x)$  con lo que se obtiene la distribución de calor en el tiempo  $t$  para cada punto en la superficie del modelo. La Figura 2 muestra un ejemplo de cómo cambia la distribución del calor en un modelo a través del tiempo. En la práctica, el descriptor denominado Heat Kernel Signature se obtiene calculando  $hks_t(x) = K_t(x, x)$  para  $n$  valores distintos de  $t$ , obteniéndose un descriptor  $n$ -dimensional.

$$hks(x) = \langle hks_{t_1}(x), hks_{t_2}(x), \dots, hks_{t_n}(x) \rangle$$

La Figura 3 muestra un ejemplo de la distribución del calor en el tiempo para distintos puntos en un modelo 3D. A partir de estos valores se construye el descriptor Heat Kernel Signature previamente descrito.



**FIGURA 3.** HEAT KERNEL SIGNATURES PARA TRES PUNTOS DIFERENTES EN EL MODELO. NOTE QUE LA DISTRIBUCIÓN DEL CALOR EN EL TIEMPO CORRESPONDE AL COMPORTAMIENTO ILUSTRADO EN LA FIGURA 2.

## FIRMAS DE CARACTERÍSTICAS Y LA SIGNATURE QUADRATIC FORM DISTANCE

Beecks et al. [BUS10] propusieron la Signature Quadratic Form Distance (SQFD) como una medida flexible para comparar objetos multimedia. Una característica particular de esta función de distancia es que un objeto puede ser representado usando múltiples características. Adicionalmente, la comparación entre dos conjuntos de características puede realizarse incluso si ambos conjuntos poseen distinto número de características.

Suponga que un modelo 3D  $P$  se representa por un conjunto de características  $F = \{f_i\}$ ,  $f_i \in FS$ , donde  $FS$  es un espacio de características de dimensión arbitraria. Suponga además que existe un *clustering* de  $F: C_1, \dots, C_n$ , donde cada  $C_i$  es el centroide de cada *cluster* y que tiene asociado un peso  $w_i$ , que corresponde

a la fracción del total de puntos en dicho *cluster*. La firma de características  $S^P$  se define como:

$$S^P = \{(C_i^P, w_i^P), i = 1, \dots, n\}$$

Note que el tamaño de  $S^P$  depende de su partición local en *clusters* y que esto es variable entre los distintos modelos 3D. Por esto, la firma de características de un modelo 3D puede tener un número distinto de tuplas con respecto a otros modelos.

Dadas dos firmas de características  $S^P = \{(C_i^P, w_i^P), i = 1, \dots, n\}$  y  $S^Q = \{(C_j^Q, w_j^Q), j = 1, \dots, m\}$ , y una función de similitud positiva semidefinida  $sim: FS \times FS \rightarrow \mathbb{R}$ , la Signature Quadratic Form Distance se define como:

$$SQFD(S^P, S^Q) = \sqrt{(w^P | - w^Q) \cdot A_{sim} \cdot (w^P | - w^Q)^T}$$

donde la notación  $(w^P | - w^Q)$  corresponde a la concatenación de los vectores de pesos, y  $A_{sim} \in \mathbb{R}^{(n+m) \times (n+m)}$  es la matriz de similitud entre centroides de  $S^P$  y  $S^Q$ , definida como:

$$a_{i,j} = \begin{cases} sim(C_i^P, C_j^P) & \text{si } i \leq n \text{ y } j \leq n \\ sim(C_{i-n}^Q, C_j^P) & \text{si } i > n \text{ y } j \leq n \\ sim(C_i^P, C_{j-n}^Q) & \text{si } i \leq n \text{ y } j > n \\ sim(C_{i-n}^Q, C_{j-n}^Q) & \text{si } i > n \text{ y } j > n \end{cases}$$

La Figura 4 muestra la composición de la matriz de similitud  $A_{sim}$ . Por último, como medida de similitud en este trabajo se utiliza  $sim(C^i, C^j) = e^{-\alpha d^2(C^i, C^j)}$ , con  $\alpha = 0.9$  y  $d$  es la distancia Euclidiana.

$$A_{sim} = \begin{matrix} & \begin{matrix} S^P & S^Q \end{matrix} \\ \begin{matrix} S^P \\ S^Q \end{matrix} & \begin{bmatrix} \text{sim}(c_i^P, c_j^P) & \text{sim}(c_i^P, c_{j-n}^Q) \\ \text{sim}(c_{i-n}^Q, c_j^P) & \text{sim}(c_{i-n}^Q, c_{j-n}^Q) \end{bmatrix} \end{matrix}$$

FIGURA 4.

LA MATRIZ DE SIMILITUD SE COMPONE DE CUATRO BLOQUES. LOS BLOQUES DE INTRADEPENDENCIA (ARRIBA IZQUIERDA Y ABAJO DERECHA) CONTIENEN LA SIMILITUD ENTRE CENTROIDES DENTRO DE LA MISMA FIRMA. LOS BLOQUES DE INTERDEPENDENCIA (ARRIBA DERECHA Y ABAJO IZQUIERDA) CONTIENEN LA SIMILITUD ENTRE CENTROIDES DE DISTINTAS FIRMAS.

## MATCHING 3D USANDO DESCRIPTORES LOCALES

La idea general del algoritmo de matching de modelos 3D usando descriptores locales se puede resumir en los siguientes puntos:

1. Calcular los Heat Kernel Signatures para puntos en la superficie del modelo 3D.
2. Realizar un proceso de *clustering* sobre los descriptores calculados, lo que permite obtener la firma de características por cada modelo 3D.
3. Usar la SQFD como medida de distancia para implementar el matching a través de búsquedas por similitud.

Nuestra propuesta consiste en tres métodos distintos para calcular las firmas de los modelos 3D.

### PRIMER MÉTODO: CALCULAR LA FIRMA SOBRE TODOS LOS VÉRTICES DEL MODELO 3D (SQFD-ALL)

Éste es el método más directo para implementar el algoritmo propuesto. Por cada vértice del modelo 3D, es decir, para todos los puntos de la malla, se calcula su descriptor Heat Kernel Signature, los que conforman el espacio de descriptores *FS*. Luego, se realiza el proceso de *clustering* sobre todos estos descriptores, lo que permite calcular la firma por cada modelo 3D. Por último, se utiliza la SQFD como función de distancia para realizar las búsquedas por similitud.

### SEGUNDO MÉTODO: CALCULAR LA FIRMA SOBRE LOS PUNTOS DE INTERÉS DEL MODELO 3D (SQFD-IP)

En este método ya no se utilizan todos los puntos de la malla para calcular la firma, sino que solo se consideran los puntos identificados como puntos de interés. La hipótesis detrás de este método es que no necesariamente todos los puntos de la malla producen un espacio de descriptores suficientemente discriminativo, por lo que el algoritmo de matching se beneficiaría al utilizar sólo un subconjunto de los puntos. Como algoritmo detector de puntos de interés en ma-

llas 3D utilizaremos el algoritmo Harris 3D [SB11], escogiendo como puntos de interés el 1% del total de puntos de la malla. Esto tiene como ventaja adicional que el proceso de clustering se agiliza, dado que ahora se realiza solo sobre el 1% de los datos.

### TERCER MÉTODO: CALCULAR LA FIRMA SOBRE CLUSTERS DE PUNTOS DE INTERÉS (SQFD-CLUSTER)

Este método se basa en el hecho que los puntos de interés detectados por el algoritmo Harris 3D tienden a formar *clusters*. Esto permite, por ejemplo, eliminar puntos de interés aislados que no pertenecen a ningún *cluster*, dado que estos puntos pueden haber sido identificados como de interés pero en realidad son producto de ruido en la malla. Los *clusters* no se identifican directamente en el espacio 3D, sino que en el espacio geodésico de la superficie de la malla. En este espacio, las distancias se miden como el camino más corto recorrido a través de la superficie para llegar de un punto a otro. Esto permite encontrar *clusters* de puntos de interés que son invariantes a transformaciones no-rígidas de la malla. La Figura 5 muestra un ejemplo de los *clusters* de puntos de interés calculados para distintos modelos 3D.

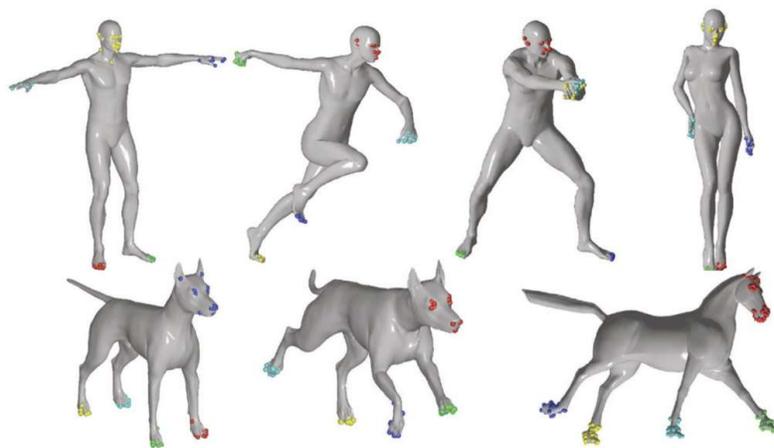


FIGURA 5.  
CLUSTERS DE PUNTOS DE INTERÉS EN DISTINTOS MODELOS 3D.

Luego, se procede a calcular la firma del objeto 3D. Por cada *cluster*, se calcula el Heat Kernel Signature para cada punto interés perteneciente a dicho *cluster*. La firma se compone de los centroides de los descriptores por cada *cluster*, y el peso asociado a cada centroide es proporcional al número de puntos de interés en su *cluster*.

## EVALUACIÓN EXPERIMENTAL

Para hacer la evaluación de los métodos propuestos, construimos un set de datos a partir de dos datasets ocupados en benchmarking de búsqueda y recuperación de modelos 3D: el TOSCA dataset [BBK08] y el Sumner dataset [SP04]. La Figura 6 muestra la comparación experimental entre los tres métodos propuestos. Se observa que el tercer método (SQFD-Cluster) es el que obtiene un mejor desempeño en términos de eficacia. Esto nos indica que el calcular las firmas a partir de *clusters* en el espacio geodésico permite captar información espacial en el descriptor, que luego es muy útil al momento de realizar el proceso de matching.

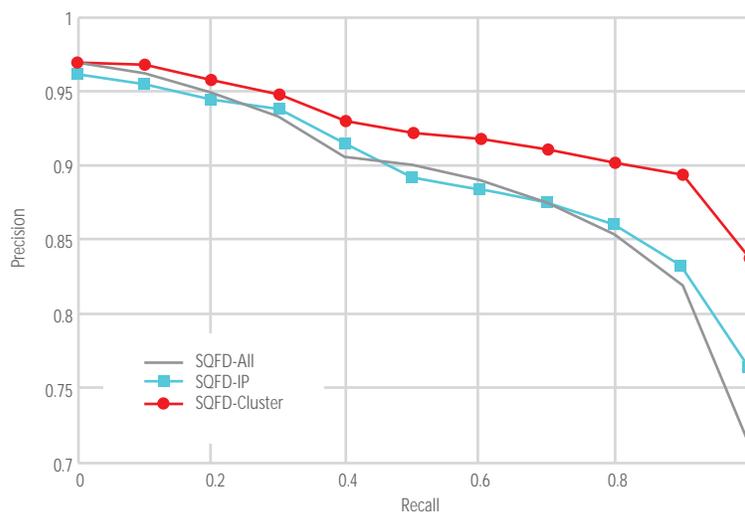


FIGURA 6. GRÁFICO *PRECISION VERSUS RECALL* COMPARANDO LOS TRES MÉTODOS PROPUESTOS (MIENTRAS MÁS ARRIBA, MEJOR).

Comparado con otros algoritmos no supervisados de matching del estado del arte, el método SQFD-Cluster obtiene una mejor eficacia. Por último, cabe destacar que dado que la distancia SQFD es una métrica, es posible utilizar técnicas de indexamiento para agilizar la eficiencia del

proceso de matching. En nuestros experimentos, utilizando una técnica simple de indexación conocido como las tablas de pivotes [ZAD+10], pudimos reducir el tiempo del matching a un 3-5% comparado con el matching sin indexamiento, sin afectar la eficacia del método.

## CONCLUSIONES

EN ESTE TRABAJO SE DESARROLLARON TRES MÉTODOS PARA CALCULAR DESCRIPTORES LOCALES 3D, CON EL OBJETIVO DE IMPLEMENTAR ALGORITMOS DE MATCHING PARCIAL. EXPERIMENTALMENTE SE OBSERVA QUE EL MEJOR MÉTODO ES AQUEL QUE CALCULA LOS DESCRIPTORES LOCALES SOBRE *CLUSTERS* DE PUNTOS DE INTERÉS. ADICIONALMENTE, EL USO DE LA SQFD COMO MEDIDA DE DISTANCIA PARA REALIZAR EL MATCHING PERMITE UTILIZAR TÉCNICAS DE INDEXAMIENTO PARA ACELERAR EL PROCESO DE MATCHING. ■

## REFERENCIAS

- [SLB+] Iván Sipirán, Jakub Lokoc, Benjamín Bustos, and Tomas Skopal. Scalable 3D shape retrieval using local features and the Signature Quadratic Form Distance. To appear in The Visual Computer. Springer.
- [BKS+05] Benjamín Bustos, Daniel Keim, Dietmar Saupe, Tobias Schreck, and Dejan Vranic. Feature-based similarity search in 3D object databases. ACM Computing Surveys, 37(4):345-387. ACM Press, 2005.
- [SMB+13] Iván Sipirán, Rafael Meruane, Benjamín Bustos, Tobias Schreck, Henry Johan, Bo Li, and Yijuan Lu. SHREC'13 Track: Large-scale partial shape retrieval using simulated range images. In Proc. 6th Eurographics Workshop on 3D Object Retrieval (3DOR'13), pages 81-88. Eurographics Association, 2013.
- [SOG09] Jian Sun, Maks Ovsjanikov, and Leonidas Guibas. A Concise and Provably Informative Multi-Scale Signature Based on Heat Diffusion. Computer Graphics Forum 28(5), 2009.
- [BUS10] Christian Beecks, Merih Seran Uysal, and Thomas Seidl. Signature Quadratic Form Distance. In Proc. ACM International Conference on Image and Video Retrieval (CIVR'10), pages 438-445. ACM, 2010.
- [SB11] Iván Sipirán and Benjamín Bustos. Harris 3D: A robust extension of the Harris operator for interest point detection on 3D meshes. The Visual Computer, 27(11):963-976. Springer, 2011.
- [BBK08] Alexander Bronstein, Michael Bronstein, and Ron Kimmel. Numerical Geometry of Non-Rigid Shapes, 1 edn. Springer, 2008.
- [SP04] Robert Sumner, and Jovan Popovic. Deformation transfer for triangle meshes. ACM Transactions on Graphics 23(3):399-405. ACM, 2004.
- [ZAD+10] Pavel Zezula, Giuseppe Amato, Vlatislav Dohnal, and Michal Batko. Similarity Search: The Metric Space Approach. Springer, 2010.