Efficient approach for interest points detection in non-rigid shapes

Cristian José López Del Alamo^{*}, Luciano Arnaldo Romero Calla[†], Lizeth Joseline Fuentes Pérez[‡] * Universidad La Salle, Arequipa, Perú

* Escuela Profesional Ciencia de la Computación - Universidad Nacional de San Agustín, Arequipa, Perú

^{†‡} Instituto de Computação - Universidade Federal Fluminense, Niterói, Rio de Janeiro, Brasil

* clopez@ulasalle.edu.pe, [†] lromero@ic.uff.br, [‡] lfuentes@ic.uff.br

Abstract—Due to the increasing amount of data and the reduction of costs in 3D data acquisition devices, there has been a growing interest, in developing efficient and robust feature extraction algorithms for 3D shapes, invariants to isometric, topological and noise changes, among others. One of the key tasks for feature extraction in 3D shapes is the interest points detection; where interest points are salient structures, which can be used, instead of the whole object. In this research, we present a new approach to detect interest points in 3D shapes by analyzing the triangles that compose the mesh which represent the shape, in different way to other algorithms more complex such as Harris 3D or HKS. Our results and experiments of repeatability, confirm that our algorithm is stable and robust, in addition, the computational complexity is $O(n \log n)$, where *n* represents the number of faces of the mesh.

Keywords—3D interest points detection, key points, 3D Harris, HKS.

I. INTRODUCTION

En los recientes años, debido al incremento de dispositivos a bajo coste para la adquisición de datos de modelos 3D, se han desarrollado algoritmos para el análisis de modelos tridimensionales, sobretodo en el caso donde estos sufren transformaciones rígidas, como rotación y traslación, los cuales son invariantes desde el punto de vista extrínseco. Sin embargo, la naturaleza no es rígida, y las transformaciones que pueden sufrir pueden ser transformaciones no rígidas, como cambios isométricos, topológicos, presencia de ruido, entre otros.

Por otro lado, analizar o comparar modelos 3D con transformaciones no rígidas podría ser computacionalmente costoso, en particular, si los modelos están representados por mallas triangulares con gran número de vértices y aristas. En ese contexto, se requiere desarrollar técnicas para reducir los vértices y/o aristas de los modelos, manteniendo la mayor cantidad de información topológica y geométrica. Definir el concepto de puntos de interés es ambiguo, porque es necesario incorporar la percepción humana, en [1], se presentó una evaluación de desempeño de diferentes técnicas para encontrar puntos de interés, sobre una base de datos generada por humanos.

En la presente investigación, un punto de interés será definido como el nivel de protrusión de estructuras locales prominentes [2]; el método que se propone está basado en el análisis de los triángulos que conforman las mallas de los modelos 3D, y de secuencias de anillos para la reducción de los puntos de interés.

En los resultados se muestra que nuestra técnica es invariante a transformaciones no rígidas además de ser eficiente computacionalmente. Por otro lado, se realizan comparaciones de repetibilidad entre nuestra técnica y dos de las mejores encontradas en el estado del arte. (Harris3D [2] y HKS [3])

II. TRABAJOS RELACIONADOS

Se han desarrollado varias técnicas para detectar puntos de interés como *mesh saliency* [4], scale depend corners [5], *salient points* [6], *3D sift* [7], detección de puntos de interés basados en HKS [3], *3D Harris* [2]. Estas técnicas fueron comparadas en eficiencia y robustez en [1].

Encontrar puntos de interés en imágenes ha sido ampliamente estudiado, y se han desarrollado varios algoritmos para este fin; en una imagen, un punto de interés es un pixel con alta variación de intensidad respecto a sus vecinos; por otro lado, en modelos 3D, los puntos de interés son vértices localizados en zonas de alta protrusión; dada la relación conceptual entre puntos de interés en imágenes y modelos 3D, un método reciente para detectar puntos de interés en modelos 3D, es *Harris 3D*, el cual fue propuesto por [8] e implementado por [2]. Otro método fue propuesto por [9], quien definió el *Heat Kernel Signature* como una restricción del dominio temporal de la difusión de calor sobre una variedad de *Riemman*, la cual está relacionada con el operador de *Laplace Beltrami*.

II-A. Harris 3D

Harris and Stephens [10] propusieron un algoritmo para encontrar esquinas en imágenes bidimensionales. Este algoritmo analiza el cambio de intensidad de un píxel en relación a sus vecinos, de modo tal, que los píxeles con mayor promedio de cambio, son aquellos con mayor probabilidad de representar esquinas o bordes en las imágenes.

Sipiran y Bustos [2], propusieron una extensión del algoritmo de *Harris*, para que en lugar de encontrar puntos de interés en imágenes 2D, sea posible encontrar puntos de interés en mallas de objetos 3D. La idea de Sipiran y Bustos, es muy similar a la de Harris, solo que analizan vértices en lugar de analizar píxeles. Uno de los problemas a resolver en este tema, es como definir la vecindad; ya que no se trata de una imagen en un espacio 2D, por el contrario, ahora se tiene una nube de puntos en un espacio tridimensional, interconectados por aristas. Sipiran y Bustos, proponen utilizar k-anillos alrededor de un vértice.



Figura 1: k-anillos [2]

En la figura 1, el vértice v, es el nodo desde el cual se tomarán k-anillos, los nodos de color verde representan los vecinos de 1-anillo, los de color azul son vecinos 2-anillos, y los de color amarillo son los 3-anillos. Los vértices que pertenecen a estos anillos forman el grupo de vecinos de v, y son estos vecinos y el mismo v, los que serán analizados para evaluar si el vértice v proporciona una mayor deformación en la superficie, en relación a sus vecinos. De ser este el caso, vse considera un vértice con alta probabilidad de ser un punto de interés.

Por otro lado, dado que cada k-anillo representa una superficie discreta, y al igual que el algoritmo de Harris, se requiere encontrar el promedio de las derivadas en el punto v para analizar la variación de éste con respecto a sus vecinos, y dado, que esta submalla es discreta, se requiere aproximar una superficie continua, la cual se logra mediante la ecuación 1

$$z = f(x, y) = \frac{p_1}{2}x^2 + p_2xy + \frac{p_3}{2}y^2p_4x + p_5y + p_6$$
(1)

Como se requiere evaluar las derivadas en un punto v, sólo es necesario evaluar las derivadas de f(x,y) en ese punto. Sipiran propone integrar las derivadas en una vecindad Gausiana, para obtener el grado en que varían el punto v en relación a su vecindad. Las ecuaciones 2, 3 y 4 representan las derivadas con respecto a x, con respecto a y y con respecto a x y a y a la vez.

$$A = \frac{1}{\sqrt{2\pi\sigma}} \int_{R}^{2} e^{\frac{-(x^2+y^2)}{2\sigma^2}} f_x(x,y)^2 dx dy$$
(2)

$$B = \frac{1}{\sqrt{2\pi\sigma}} \int_{R}^{2} e^{\frac{-(x^{2}+y^{2})}{2\sigma^{2}}} f_{y}(x,y)^{2} dx dy$$
(3)

$$C = \frac{1}{\sqrt{2\pi\sigma}} \int_{R}^{2} e^{\frac{-(x^{2}+y^{2})}{2\sigma^{2}}} f_{x}(x,y) \cdot f_{y}(x,y)^{2} dx dy \qquad (4)$$
$$H = \begin{bmatrix} A & C \\ C & B \end{bmatrix}.$$

Donde H es el valor de *Harris 3D* para un vértice. Finalmente, se toman aquellos t vértices, cuyo valor absoluto de H son los mayores. Esos t vértices son los puntos de interés. En esta investigación utilizaremos 2-*ring*, tal como lo sugiere Sipiran.

II-B. HKS

Sea M una superficie bidimensional, cerrada y sin límites, embebida en un espacio tridimensional y sea p un punto en la superficie M al cual se le aplica una fuente de calor, el problema de encontrar la disipación de calor en el punto pluego de un tiempo t se resuelve mediante la ecuación de calor, cuya solución es conocida como *Heat Kernel*. Formalmente, se dice que si u(p,t) es el calor promedio en p luego de un tiempo t, entonces el *Heat Kernel* se define según la ecuación 5.

$$u(p,t) = \frac{\partial u}{\partial t} = \Delta u \tag{5}$$

Donde $\triangle u$ es el operador de Laplace Beltrami [11].

Sun *et al.* [9] propusieron el *Heat Kernel Signature*, como una restricción en el dominio del tiempo del *Heat Kernel*. La ecuación 6 representa difusión de calor de un vértice v en un tiempo t.

$$HKS(v,t) = \sum_{i=0}^{\infty} e^{-\lambda_i t} \phi_i^2(v)$$
(6)

En la ecuación 6, λ_i y $\phi_i(x)$ son los auto-valores y autovectores del operador Laplace Beltrami. Al tomar *n* valores contiguos de *t*, se obtiene una firma única, *n*-dimensional, para el vértice *v*.

Finalmente, un vértice es seleccionado como punto de interés, cuando para valores altos de tiempo, su firma es máxima respecto a sus vecinos [12].

III. CONCEPTOS PRELIMINARES

III-A. Anillo

Es el vecindario que rodea a un vértice del modelo. Dado un vértice v, el anillo de profundidad 1, $R_1(v)$, es el conjunto de vértices directamente conectados al vértice v [2].

$$R_1(v) = \{ v' \in V \mid \exists e(v', v) \}$$

donde e(v', v'), es la arista que conecta a los vértices v y v'.

III-B. Anillo de nivel k

El *Anillo* $R_k(v)$ de nivel de profundidad k con centro en el vértice v, está definido por:

$$R_k(v) = \{v' \in V' \mid |C(v', v)| = k\}$$

donde:

C(v', v), es el camino mínimo del vértice v' al v y |C(v', v)|, es el tamaño del camino C(v', v). Es importante mencionar el tamaño de una arista es siempre 1.



Figura 2: Metodología

III-C. Secuencia de Anillos

Una secuencia de anillos $SR_k(v)$ está definida por:

$$SR_k(v) = \bigcup_{i=1}^k R_k(v) \tag{7}$$

IV. METODOLOGÍA

La metodología del método propuesto, *Minimal area interest points (MAIP)*, se resume en la Figura 2.

IV-A. Detección de posibles puntos de interés

1) Cálculo de áreas: Sea M una malla triangular que representa el modelo, donde $v_1, v_2, v_3 \in \mathbb{R}^3$ es un triángulo en M. El área es definida como:

$$area = \frac{det(A)}{2} \tag{8}$$

donde

$$A = \begin{vmatrix} v_1(x) & v_1(y) & v_1(z) \\ v_2(x) & v_2(y) & v_2(z) \\ v_3(x) & v_3(y) & v_3(z) \end{vmatrix}$$

Luego, mediante la ecuación 8 computamos el área para cada triángulo en el modelo.

2) Selección de triángulos con áreas pequeñas: El algoritmo propuesto, toma en cuenta el hecho que la malla triangular debe adaptarse al modelo tridimensional. En zonas planas del modelo los triángulos suelen ser regulares, mientras que en zonas de alta protrusión, la malla debe adaptarse a la superficie y, por lo tanto, los triángulos en estas zonas son, por lo general, irregulares y más pequeños. En ese sentido, el algoritmo detecta las áreas de todos los triángulos del modelo, para luego ordenarlos de manera creciente. Los vértices que conforman los triángulos más pequeños conforman los posibles puntos de interés.

En la figura 3, se puede apreciar que las áreas pequeñas se encuentran localizadas en zonas de alta protrusión (oreja del caballo), y las zonas, donde las áreas de los triángulos son grandes, corresponden a zonas planas. La figura 4, muestra los puntos de interés para el modelo humano, con diferentes valores de t. Los puntos de interés están representados por puntos rojos.



Figura 3: Áreas del modelo

3) Mapear a posibles puntos de interés: Calculamos todos los vértices que conforman los triángulos seleccionados en la etapa anterior, de modo que todos esos vértices conforman los posibles puntos de interés.

IV-B. Detección de puntos de interés

En esta fase, se seleccionan todos los vértices de los triángulos con áreas pequeñas y menores a un umbral *t*. Sin embargo, el hecho que las zonas de alta protrusión estén representadas por una gran cantidad de triángulos con áreas pequeñas, genera un número elevado de posibles puntos de interés, entonces es necesario elegir un subconjunto menor de vértices.

1) Agrupamiento de posibles puntos de interés: Para elegir el subconjunto de posibles puntos de interés, se realiza un proceso de agrupamiento basado en la distancia geodésica entre ellos. Para cada posible punto de interés v se calcula una secuencia de anillos $SR_2(v)$, de modo que los grupos que se solapen, se unen para formar un solo grupo.

2) *Extracción de puntos de interés:* Finalmente, de cada grupo se selecciona el triángulo con menor área, de modo que los vértices de este forman parte del resultado final.

V. DISCUSIÓN Y EVALUACIÓN EXPERIMENTAL

En esta sección, se describen los experimentos y resultados. Se utilizó un *benchmark* estándar [13] y se aplicaron pruebas de repetibilidad para evaluar la calidad del método propuesto respecto otros del estado del arte.

V-A. Análisis del costo computacional

Sea n el número de triángulos en la malla que representa un modelo M, entonces el algoritmo tiene el siguiente costo computacional:



Figura 4: Modelos con puntos de interés para diferentes valores de t

- Hallar el área de un triángulo mediante su determinante O(1).
- Hallar el área de todos los triángulos del modelo O(n).
- Ordenar los triángulos según su área $O(n \log n)$.
- Seleccionar los posibles puntos de interés formados por los vértices de los *t* triángulos con menor área, tiene un costo en el peor caso de O(3t), y dado que t < n entonces $t \in O(n)$.
- Calcular SR₂(v), es decir hallar los anillos con distancia geodésica 2 de los vértices seleccionados y agruparlos tiene un costo computacional de O(p), donde p representa los posibles puntos de interés. Además, dado que p <= 3t entonces p ∈ O(3t) y dado que t <= n, se tiene que p ∈ O(n).
- Finalmente, extraer puntos de interés tiene un costó a los más de O(p), y por lo anterior $p \in O(n)$.

Por lo tanto, el costo computacional de MAIPD es $O(n \log n)$, donde *n* es el número de triángulos del modelo.

En comparación a *HKS* y *Harris 3D*, *MAIPD* es más eficiente, porque:

- *HKS*, calcula los auto valores y auto vectores del operador de *Laplace Beltrami*, lo cual representa un costo computacional de $O(n^3)$.
- *Harris 3D*, necesita ajustar una función cuadrática para cada conjunto de 2 anillos del modelo, lo cual representa un costo computacional de $O(n^2)$.

V-B. El conjunto de datos

En nuestros experimentos y, con el fin de evaluar nuestro método, se utilizaron los modelos del *benchmark* SHREC 2010 [13]. Esta base de datos esta compuesta por 3 modelos: humanos, perros y caballos, los cuales presentan simetría

extrínseca (modelos base). Estos modelos están representados por mallas de triángulos, las cuales tienen, aproximadamente, 10,000 – 50,000 vértices. Cada modelo, a su vez, tiene un conjunto de modelos obtenidos mediante la aplicación de transformaciones no rígidas sobre los modelos base. Las transformaciones aplicadas son isometría (*isometry*), micro agujeros (*micro holes*), agujeros grandes (*holes*), cambios topológicos (*topology*), ruido (*noise*), escala global (*global scale*) y local (*local scale*), y disminución de la resolución (*sampling*). Cada transformación fue aplicada en 5 niveles de intensidad, donde el nivel uno, implica una transformación con la intensidad más baja, mientras el número 5 implica una transformación con tas presentados de la 138 modelos.

V-C. Evaluación

Para la evaluación de nuestro método, se utilizó la metodología de [13], la cual permite medir el grado de repetibilidad de los puntos de interés detectados en los modelos transformados, en relación a los puntos de interés detectados en los modelos sin transformaciones.

Sea $F(Y) = \{y_k\}_k$, un conjunto de puntos de interés detectados por algún método, para medir la calidad de un algoritmo de detección de puntos de interés se utiliza el criterio de *repetibilidad*, para cada punto de interés $y_k \in F(Y)$, se obtiene su correspondiente punto x_k en X, de modo que se tiene un par $C_0(X,Y) = \{(x'_k, y_k)\}_{k=1}^{|Y|}$, donde y_k es un punto de interés en el modelo Y, y x'_k , es el punto correspondiente de y_k en el modelo X.

Un punto $y_k \in F(Y)$ se dice *repetible*, si en una bola geodésica de radio R al rededor del punto de correspondencia $x'_k : (x'_k, y_k) \in C_0(X, Y)$ contiene puntos de interés $x_j \in F(X)$.

El subconjunto $Fr(Y) \subset F(Y)$ de puntos repetibles esta dado por $F_{R,X}(Y) = \{y_k \in F(Y) : F(X) \cap B_R(x'_k) \neq \emptyset, (x'_k, y_k) \in$



Figura 5: Media y desviación estándar de los valores de repetibilidad de todas las transformaciones, en función al porcentaje de puntos de interés (t), en modelos de humanos.

 $C_0(X,Y)$, donde $B_R(x'_k) = \{x \in X : d_X(x,x'_k) \le R\}$ y d_X denotan la distancia de difusión geodésica en X.

La repetibilidad rep(Y,X) de F(Y) en X está definida como el porcentaje de características de F(Y) que son repetibles, $rep(X,Y) = \frac{F_{R,X}(Y)}{F(Y)}$.. Para un modelo transformado Y y su modelo correspondiente sin transformación X, la calidad de la detección de puntos de interés es medida como (rep(Y,X) + rep(X,Y))/2. El valor R = 5 fue utilizado en el *benchmark*. Este radio constituye aproximadamente el 1% del diámetro del modelo. Los puntos de interés que no tienen una correspondencia en el modelo sin transformación, son ignorados.

V-D. Resultados y comparación con otros métodos

Tabla I: Repetibilidad del algoritmo HKS2 para la detección de puntos de interés [2].

	Strength						
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG	
Holes	91.48	90.60	86.78	83.73	81.86	86.89	
Isometry	98.08	98.72	98.01	97.88	98.04	98.15	
Local Scale	98.08	94.83	90.09	83.05	78.31	88.87	
Micro Holes	98.08	96.69	96.00	95.52	94.87	96.23	
Noise	95.30	92.78	91.67	89.24	87.62	91.32	
Sampling	97.05	97.88	97.39	96.27	92.35	96.19	
Scale	99.36	99.36	98.50	97.90	97.68	98.56	
Shot Noise	98.08	96.22	93.39	90.45	87.32	93.09	
Topology	97.44	96.10	92.26	91.22	88.64	93.13	
Average	96.99	95.91	93.79	91.70	89.63	93.60	

Para los experimentos, se tomaron las mallas originales, es decir, no se aplicó ningún método para disminuir el número de

Tabla II: Repetibilidad del algoritmo HKS3 para la detección de puntos de interés [2].

	Strength	ı				
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG
Holes	80.54	79.00	75.25	72.10	69.99	75.38
Isometry	100.00	100.00	100.00	100.00	100.00	100.00
Local Scale	97.44	96.79	93.02	87.25	82.90	91.48
Micro Holes	100.00	100.00	98.15	96.58	95.64	98.07
Noise	100.00	95.19	93.16	89.37	85.77	92.70
Sampling	100.00	100.00	100.00	100.00	96.20	99.24
Scale	100.00	100.00	100.00	98.61	97.78	99.28
Shot Noise	100.00	95.30	90.03	82.10	74.38	88.36
Topology	94.44	90.38	87.45	88.70	85.76	89.35
Average	96.94	95.18	93.01	90.52	87.60	92.65

Tabla III: Repetibilidad del algoritmo H3D para la detección de puntos de interés [2].

	Strengt	h				
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG
Holes	94.62	94.43	94.10	94.01	93.81	94.19
Isometry	96.01	96.73	96.26	96.60	96.62	96.44
Local Scale	96.24	94.96	93.40	91.26	88.84	92.94
Micro Holes	96.01	96.01	95.98	95.96	95.95	95.98
Noise	93.09	92.58	91.59	90.33	88.79	91.28
Sampling	95.31	93.62	92.08	89.13	80.42	90.11
Scale	97.06	96.89	96.28	95.62	94.94	96.16
Shot Noise	96.03	95.66	95.00	93.83	92.79	94.66
Topology	96.01	95.97	95.82	95.73	95.71	95.85
Average	95.60	95.21	94.50	93.61	91.99	94.18

vértices del las mallas. La figura 7 muestra modelos de caballo con puntos de interés detectados con *MAIPD*, para todas las transformaciones de nivel 5.



Figura 6: Media y desviación estándar de los valores de repetibilidad de todas las transformaciones, en función al porcentaje de puntos de interés (t), en modelos de caballos.

Tabla IV: Repetibilidad de nuestra técnica con t = 1% para modelos de caballos. Promedio de puntos de interés encontrados: 17.

	Strength							
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG		
Holes	20.69	12.20	4.44	4.35	3.57	9.05		
Isometry	100.00	100.00	100.00	100.00	100.00	100.00		
Local Scale	100.00	78.57	58.82	20.83	12.50	54.15		
Micro Holes	100.00	85.71	73.33	56.25	52.94	73.65		
Noise	12.50	2.86	4.65	2.27	2.17	4.89		
Sampling	2.63	0.00	0.00	0.00	0.00	0.53		
Scale	100.00	100.00	100.00	100.00	100.00	100.00		
Shot Noise	85.71	85.71	85.71	85.71	85.71	85.71		
Topology	100.00	100.00	100.00	100.00	100.00	100.00		
Average	69.06	62.78	58.55	52.16	50.77	58.66		

Se realizaron pruebas para modelos de humanos y caballos, variando el parámetro $t \in [1, 50]$ y kr = 2, como se muestra en las Figuras 5 y 6.

La Figura 5, muestra la media y la desviación estándar de los valores de repetibilidad promedio de todas las transformaciones, en función al porcentaje de puntos de interés obtenidos de modelos de humanos. Se puede apreciar que los valores de repetibilidad más altos están entre t = 2 y t = 16y corresponden a las transformaciones *isometry*, *shot noise*, *micro holes*, *scale* y *topology*. El mayor valor de repetibilidad, se obtuvo con un t = 8, como se muestra en la Tabla VI, donde se observa que para todos los valores de repetibilidad, de todas las transformaciones y para cada nivel de intensidad, el número promedio de puntos de interés detectados fue de 94.

La Figura 6, muestra la media y la desviación estándar

Tabla V: Técnicas con la mejor precisión para cada transformación e intensidad, en modelos de caballos. HKS-Heat Kernel Signature. H3D-Harris 3D. MAIP usando t = 1 %.

	Strength						
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG	
Holes	H3D	H3D	H3D	H3D	H3D	H3D	
Isometry	MAIP	MAIP	MAIP	MAIP	MAIP	MAIP	
Local Scale	MAIP	HKS3	H3D	H3D	H3D	H3D	
Micro Holes	MAIP	HKS3	HKS3	HKS3	H3D	HKS3	
Noise	HKS3	HKS3	HKS3	H3D	H3D	HKS3	
Sampling	HKS3	HKS3	HKS3	HKS3	HKS3	HKS3	
Scale	MAIP	MAIP	MAIP	MAIP	MAIP	MAIP	
Shot Noise	HKS3	HKS2	H3D	H3D	H3D	H3D	
Topology	MAIP	MAIP	MAIP	MAIP	MAIP	MAIP	
Average	HKS2	HKS2	H3D	H3D	H3D	H3D	

de los valores de repetibilidad promedio de todas las transformaciones, en función al porcentaje de puntos de interés obtenidos de modelos de caballos. Se puede observar que los valores de repetibilidad son más altos cuando el parámetro t, es más pequeño; el mayor valor de repetibilidad, se obtuvo con un t = 1%, como se muestra en la Tabla IV, donde se aprecian los valores de repetibilidad de cada transformación con sus 5 intensidades; las transformaciones que obtuvieron los valores de repetibilidad más altos fueron: *isometry, shot noise, micro holes, scale* y *topology*, donde *isometry, scale* y *topology* alcanzaron el valor de repetibilidad promedio de 100% y se detectaron en promedio solamente 17 puntos de interés.

En las Tablas I, II y III se observan los valores de repetibilidad, obtenidos con los métodos Harris 3D [2], y dos variantes de *Heat Kernel Signature* (HKS2, HKS3) Las Tablas



Figura 7: Detección de puntos de interés en modelos de caballos para cada transformación, con nivel de intensidad 5 y t = 20%

Tabla VI: Repetibilidad de nuestra técnica con t = 8% para modelos de humanos. Promedio de puntos de interés encontrados: 94.

	Strength						
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG	
Holes	66.27	57.61	56.57	41.74	23.45	49.13	
Isometry	93.85	90.77	84.51	92.42	57.30	83.77	
Local Scale	31.45	12.40	3.70	1.54	0.71	9.96	
Micro Holes	98.44	96.88	95.38	95.38	98.44	96.90	
Noise	2.48	0.00	0.33	0.00	0.27	0.62	
Sampling	2.44	0.00	0.00	0.00	0.00	0.49	
Scale	95.38	96.88	92.42	98.44	95.38	95.70	
Shot Noise	92.42	93.85	95.38	92.42	86.76	92.17	
Topology	96.88	96.88	93.85	98.44	95.38	96.28	
Average	64.40	60.58	58.02	57.82	50.86	58.34	

V y VII, muestran los mejores resultados por transformación e intensidad entre los métodos propuestos HKS1, HKS2, H3D evaluados en [2] y el método propuesto *MAIPD* con kr = 2, en

Tabla VII: Técnicas con la mejor precisión para cada transformación e intensidad, en modelos de humanos. HKS-Heat Kernel Signature. H3D-Harris 3D. MAIP usando t = 8 %.

	Strength						
Transform	1	≤ 2	≤ 3	≤ 4	≤ 5	AVG	
Holes	H3D	H3D	H3D	H3D	H3D	H3D	
Isometry	HKS3	HKS3	HKS3	HKS3	HKS3	HKS3	
Local Scale	HKS2	HKS3	H3D	H3D	H3D	H3D	
Micro Holes	HKS3	HKS3	HKS3	HKS3	MAIP	HKS3	
Noise	HKS3	HKS3	HKS3	H3D	H3D	HKS3	
Sampling	HKS3	HKS3	HKS3	HKS3	HKS3	HKS3	
Scale	HKS3	HKS3	HKS3	HKS3	HKS3	HKS3	
Shot Noise	HKS3	HKS2	MAIP	H3D	H3D	H3D	
Topology	HKS2	MAIP	H3D	MAIP	H3D	MAIP	
Average	HKS2	HKS2	H3D	H3D	H3D	H3D	

modelos de humanos y de caballos respectivamente, se calculó la precisión promedio para cada transformación. En la Tabla VII, se puede apreciar que *MAIPD*, supera en promedio a las

demás técnicas en la transformación *topology*. De la Tabla V, se aprecia que *MAIPD*, supera a las otras técnicas en las transformaciones de *isometry*, *scale* y *topology*.

Por otro lado, es importante notar que, en las Figuras 5 y 6, tanto en la transformaciones *holes, noise* y *sampling*, nuestros resultados son inferiores; ésto se debe a que estas transformaciones generan fuertes modificaciones en la malla.

V-E. Ventajas y limitaciones del método propuesto

Luego de realizar los experimentos y las comparaciones respectivas, con los resultados de Harris 3D y HKS, podemos ver que la principal ventaja de nuestro método tiene que ver con su simplicidad y eficiencia en cuanto a costo computacional. Sin embargo, cuando se trata de mallas no adaptativas, donde las áreas de los triángulos son todas similares, el método falla. En estos casos, es posible aplicar una etapa de preprocesamiento, utilizando, por ejemplo, el algoritmo qslim [14] para realizar una simplificación de la malla manteniendo una mayor cantidad de vértices en zonas de alta protrusión y una menor cantidad de vértices en zonas planas. Es claro que aplicar esta etapa de preprocesamiento implica incrementar el costo computacional, sin embargo, las mallas no adaptativas, es decir, no simplificadas, tienen un gran número de vértices, lo cual hace que aplicar el método HKS sea prácticamente intratable debido al proceso de auto-descomposición del operador Laplace-Beltrami. Por otro lado, en el caso de Harris 3D, se hace necesario recalcular el radio adecuado de la vecindad de un vértice para analizar correctamente la curvatura y en ese sentido, estos dos métodos también son afectados desde el punto de vista de costo computacional.

VI. CONCLUSIONES

En esta investigación se presentó un nuevo método para detección de puntos de interés en modelos 3D.

Los experimentos confirman que, los triángulos con áreas más pequeñas, efectivamente corresponden a zonas de alta protrusión, y los vértices que conforman esos triángulos son considerados puntos de interés. Por otro lado, nuestro método es simple y eficiente, al requerir básicamente el cálculo de las áreas de los triángulos. Una ventaja importante es que no se requieren cálculos complejos.

En las Tablas IV y VI de la sección anterior, se observa que nuestro método es robusto a cambios topológicos, cambios isométricos, cambios de escala, así como a la baja presencia de ruido y hoyos pequeños.

Por otro lado, nuestros resultados son similares al de *Harris 3D* y *HKS*. Además, como se puede apreciar en la Tabla IV nuestro método presenta mejores resultados en las transformaciones: *micro holes, shot noise* y *topology*.

Es importante mencionar que la presencia de ruido en altos niveles, la reducción de vértices de la malla (*sampling*) y los hoyos; cambian la triangulación y decrementan la posibilidad de detectar puntos de interés con alta repetibilidad.

VII. TRABAJOS FUTUROS

Como se observa en los capítulos anteriores, un modelo pueden tener varios cientos de puntos de interés, sin embargo,

es posible agrupar puntos de interés geodésicamente cercanos, con el objetivo de obtener submallas representativas del modelo completo; de modo que el número de submallas es considerablemente menor que el número de puntos de interés. A estas submallas se les denomina componentes clave o *key componentes*, en tal sentido, en trabajos futuros se planea desarrollar un método para encontrar componentes clave mediante la agrupación de puntos de interés geodésicamente cercanos.

AGRADECIMIENTO

Agradecemos a la universidad La Salle, a la escuela profesional de Ciencias de la Computación de la Universidad Nacional de San Agustín y al grupo de investigación *Image Processing and Data Mining* (IPRODAM), por el apoyo en esta investigación.

REFERENCIAS

- [1] H. Dutagaci, C. P. Cheung, and A. Godil, "Evaluation of 3d interest point detection techniques via human-generated ground truth," *Vis. Comput.*, vol. 28, no. 9, pp. 901–917, Sep. 2012. [Online]. Available: http://dx.doi.org/10.1007/s00371-012-0746-4
- [2] I. Sipiran and B. Bustos, "Harris 3d: A robust extension of the harris operator for interest point detection on 3d meshes," *Vis. Comput.*, vol. 27, no. 11, pp. 963–976, Nov. 2011. [Online]. Available: http://dx.doi.org/10.1007/s00371-011-0610-y
- [3] J. Sun, M. Ovsjanikov, and L. Guibas, "A concise and provably informative multi-scale signature based on heat diffusion," in *Proceedings of the Symposium on Geometry Processing*, ser. SGP '09. Aire-la-Ville, Switzerland, Switzerland: Eurographics Association, 2009, pp. 1383–1392. [Online]. Available: http://dl.acm.org/citation.cfm?id=1735603.1735621
- [4] C. H. Lee, A. Varshney, and D. W. Jacobs, "Mesh saliency," ACM Trans. Graph., vol. 24, no. 3, pp. 659–666, Jul. 2005. [Online]. Available: http://doi.acm.org/10.1145/1073204.1073244
- [5] J. Novatnack and K. Nishino, "Scale-dependent 3d geometric features," in *Computer Vision*, 2007. ICCV 2007. IEEE 11th International Conference on, Oct 2007, pp. 1–8.
- [6] U. Castellani, M. Cristani, S. Fantoni, and V. Murino, "Sparse points matching by combining 3d mesh saliency with statistical descriptors." *Comput. Graph. Forum*, vol. 27, no. 2, pp. 643–652, 2008.
- [7] R. Ohbuchi, K. Osada, T. Furuya, and T. Banno, "Salient local visual features for shape-based 3d model retrieval," in *Shape Modeling and Applications, 2008. SMI 2008. IEEE International Conference on*, June 2008, pp. 93–102.
- [8] P. Glomb, "Detection of interest points on 3d data: Extending the harris operator," in *Computer Recognition Systems 3*. Springer, 2009, pp. 103–111.
- [9] J. Sun, M. Ovsjanikov, and L. Guibas, "A concise and provably informative multi-scale signature based on heat diffusion," in *Computer Graphics Forum*, vol. 28, no. 5. Wiley Online Library, 2009, pp. 1383– 1392.
- [10] E. Detector, "Chris harris and mike stephens plessey research hoke manor," United Kingdom, 1988.
- [11] A. Dubrovina and R. Kimmel, "Matching shapes by eigendecomposition of the laplace-beltrami operator," in *Proc. 3DPVT*, vol. 2, no. 3, 2010.
- [12] M. Ovsjanikov, J. Sun, and L. Guibas, "Global intrinsic symmetries of shapes," in *Computer Graphics Forum*, vol. 27, no. 5. Wiley Online Library, 2008, pp. 1341–1348.
- [13] I. Pratikakis, M. Spagnuolo, T. Theoharis, R. V. (editors, A. M. Bronstein, M. M. Bronstein, U. Castellani, A. Dubrovina, L. J. Guibas, R. P. Horaud, R. Kimmel, D. Knossow, E. V. Lavante, D. Mateus, M. Ovsjanikov, and A. Sharma, "Shree 2010: robust correspondence benchmark."
- [14] M. Garland, "Quadric-based polygonal surface simplification," Ph.D. dissertation, Pittsburgh, PA, USA, 1999, aAI9950005.