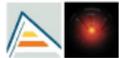


Detección de regiones de interés visuales basada en la teoría de la información

Presentada por *Pablo Suau*
Dirigida por *Dr. Francisco Escolano*

Programa *Ingeniería Informática y Computación*
Dpto. de Ciencia de la Computación e Inteligencia Artificial
Escuela Politécnica Superior
Universidad de Alicante



Contenido

- 1 Introducción y objetivos
- 2 Extracción de características visuales
- 3 El algoritmo Scale Saliency
- 4 Filtrado Bayesiano previo al Scale Saliency
- 5 Scale Saliency multidimensional
- 6 Conclusiones



Contenido

- 1 **Introducción y objetivos**
- 2 Extracción de características visuales
- 3 El algoritmo Scale Saliency
- 4 Filtrado Bayesiano previo al Scale Saliency
- 5 Scale Saliency multidimensional
- 6 Conclusiones



Introducción y objetivos

Objetivo principal: mejora de la eficiencia de la extracción de características visuales basada en teoría de la información



Introducción y objetivos

Objetivo principal: mejora de la eficiencia de la extracción de características visuales basada en teoría de la información

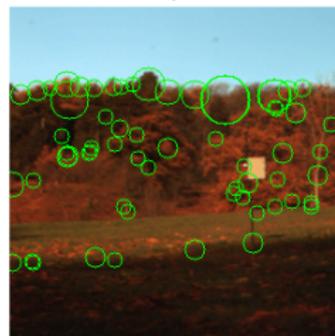
- Regla para descartar regiones no informativas que no serán procesadas



Introducción y objetivos

Objetivo principal: mejora de la eficiencia de la extracción de características visuales basada en teoría de la información

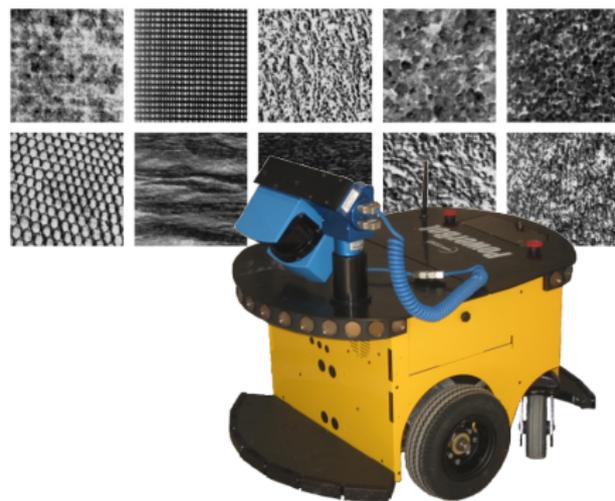
- Regla para descartar regiones no informativas que no serán procesadas
- Generalización para el procesamiento eficiente de datos multidimensionales



Introducción y objetivos

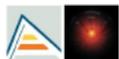
Objetivo principal: mejora de la eficiencia de la extracción de características visuales basada en teoría de la información

- Regla para descartar regiones no informativas que no serán procesadas
- Generalización para el procesamiento eficiente de datos multidimensionales
- Aplicaciones prácticas



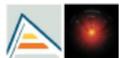
Contenido

- 1 Introducción y objetivos
- 2 Extracción de características visuales**
- 3 El algoritmo Scale Saliency
- 4 Filtrado Bayesiano previo al Scale Saliency
- 5 Scale Saliency multidimensional
- 6 Conclusiones



Extracción de características visuales

- Selección de los componentes clave de una imagen
- Representación dispersa de la imagen
- Información adicional
- Entrada para procesos de visión de alto nivel
 - Estéreo
 - Categorización/reconocimiento
 - Robótica



Evolución de las características visuales

■ Primeros métodos

- Extracción de aristas [Marr and Hildreth, 1980] [Canny, 1986] [Deriche, 1987]
- Puntos de interés
 - Basados en geometría [Asada and Brady, 1986] [Deriche and Faugeras, 1990]
 - Basados en gradientes de intensidad [Moravec, 1977] [Rohr, 1990] [Harris and Stephens, 1988]



Evolución de las características visuales

- Invarianza a escala
 - El espacio de escalas [Witkin, 1983] [Yuille and Poggio, 1986], [Koenderink and Richards, 1988]
 - Regiones isotrópicas [Lindeberg, 1998]



Evolución de las características visuales

■ Invarianza a escala

- El espacio de escalas [Witkin, 1983] [Yuille and Poggio, 1986], [Koenderink and Richards, 1988]
- Regiones isotrópicas [Lindeberg, 1998]
 - Harris-Laplace [Mikolajczyk and Schmid, 2001]



Evolución de las características visuales

■ Invarianza a escala

- El espacio de escalas [Witkin, 1983] [Yuille and Poggio, 1986], [Koenderink and Richards, 1988]
- Regiones isotrópicas [Lindeberg, 1998]
 - Harris-Laplace [Mikolajczyk and Schmid, 2001]
 - Scale Saliency [Kadir and Brady, 2001]



Evolución de las características visuales

- Invarianza afín



Evolución de las características visuales

- Invarianza afín [Mikolajczyk and Schmid, 2002]



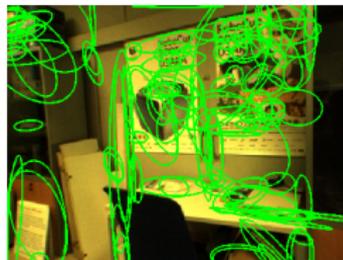
Evolución de las características visuales

- Invarianza afín [Mikolajczyk and Schmid, 2002] [Mikolajczyk and Schmid, 2004]



Evolución de las características visuales

- Invarianza afín [Mikolajczyk and Schmid, 2002] [Mikolajczyk and Schmid, 2004] [Matas et al., 2004]



Evolución de las características visuales

- Invarianza afín [Mikolajczyk and Schmid, 2002] [Mikolajczyk and Schmid, 2004] [Matas et al., 2004] [Tuytelaars and Gool, 2004]



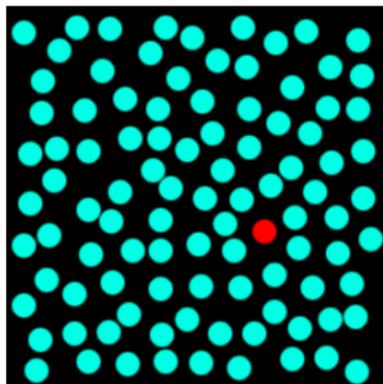
Contenido

- 1 Introducción y objetivos
- 2 Extracción de características visuales
- 3 El algoritmo Scale Saliency**
- 4 Filtrado Bayesiano previo al Scale Saliency
- 5 Scale Saliency multidimensional
- 6 Conclusiones



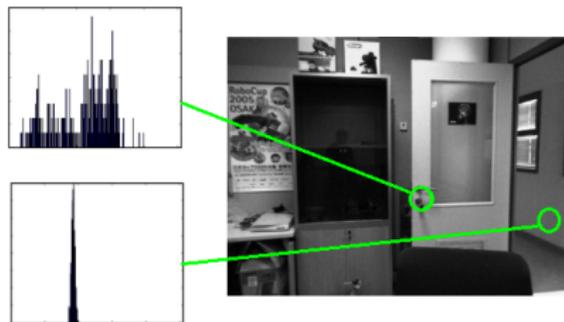
Scale Saliency

- Todo el trabajo de esta tesis basado en el algoritmo **Scale Saliency** [Kadir and Brady, 2001]
 - Detección de regiones de la imagen visualmente distinguibles (localmente)
 - Basado en la Teoría de la Información
 - Generalización invariante a escala del método propuesto por Gilles [Gilles, 1998]



El algoritmo de Gilles

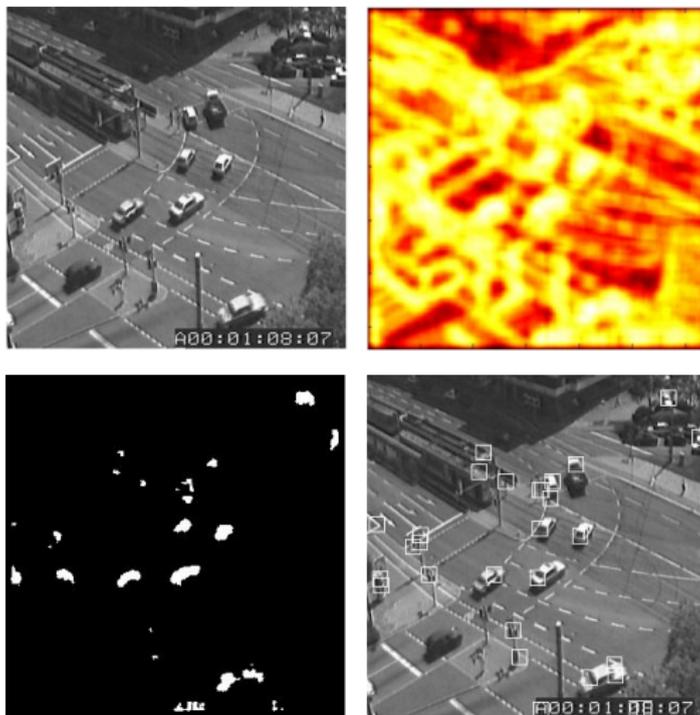
- Relacionó la Teoría de la Información con la extracción de características visuales
- Características visuales: regiones impredecibles de la imagen
- **Entropía de Shannon** como medida de impredecibilidad



$$H_{D,R_x} = - \sum_i P_{D,R_x}(d_i) \log_2 P_{D,R_x}(d_i)$$

El algoritmo de Gilles

■ Ejemplo



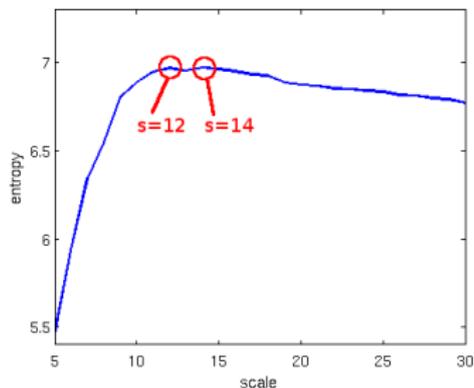
El algoritmo de Gilles

- Limitaciones del algoritmo
 - Escala fija
 - Sensible a ruido
 - Selecciona regiones no distinguibles (texturas)



El algoritmo Scale Saliency

- Búsqueda tanto en el espacio de la imagen como en el espacio de escalas
 - Aumento isotrópico del tamaño de R_x (escala)



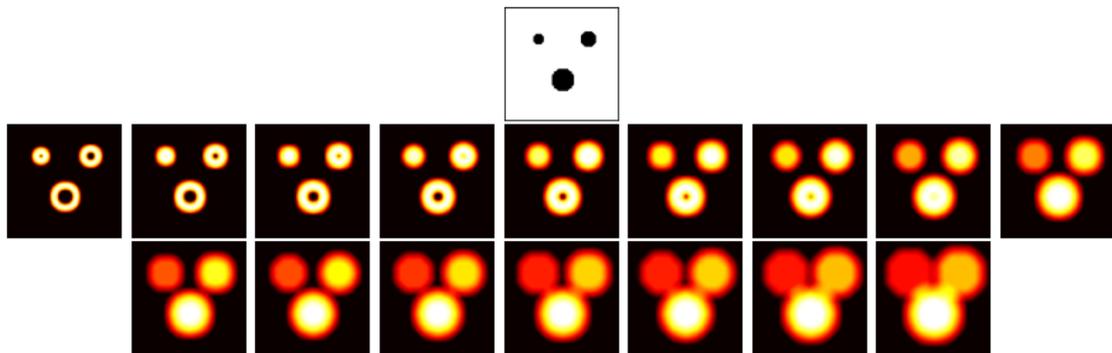
El algoritmo Scale Saliency

- Establecer un rango de escalas entre s_{min} y s_{max}



El algoritmo Scale Saliency

- Establecer un rango de escalas entre s_{min} y s_{max}
- $$H_D(s, x) = - \sum_{d \in D} P_{d,s,x} \log_2 P_{p,s,x}$$



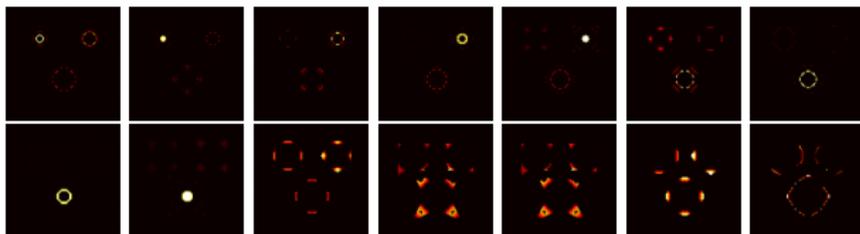
El algoritmo Scale Saliency

- Establecer un rango de escalas entre s_{min} y s_{max}
- $$H_D(s, x) = - \sum_{d \in D} P_{d,s,x} \log_2 P_{p,s,x}$$
- $$S_P = \{s : H_D(s-1, x) < H_D(s, x) > H_D(s+1, x)\}$$



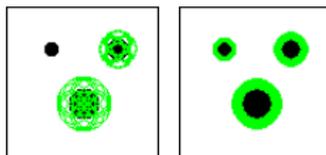
El algoritmo Scale Saliency

- Establecer un rango de escalas entre s_{min} y s_{max}
- $$H_D(s, x) = - \sum_{d \in D} P_{d,s,x} \log_2 P_{p,s,x}$$
- $$S_P = \{s : H_D(s-1, x) < H_D(s, x) > H_D(s+1, x)\}$$
- $$W_D = \frac{s^2}{2s-1} \sum_{d \in D} |P_{d,s,x} - P_{d,s-1,x}|$$



El algoritmo Scale Saliency

- Establecer un rango de escalas entre s_{min} y s_{max}
- $H_D(s, x) = - \sum_{d \in D} P_{d,s,x} \log_2 P_{p,s,x}$
- $S_P = \{s : H_D(s-1, x) < H_D(s, x) > H_D(s+1, x)\}$
- $W_D = \frac{s^2}{2s-1} \sum_{d \in D} |P_{d,s,x} - P_{d,s-1,x}|$
- $Y_D(s_p, x) = H_D(s_p, x) W_D(s_p, x)$



El algoritmo Scale Saliency

- Establecer un rango de escalas entre s_{min} y s_{max}
- $H_D(s, x) = - \sum_{d \in D} P_{d,s,x} \log_2 P_{p,s,x}$
- $S_P = \{s : H_D(s-1, x) < H_D(s, x) > H_D(s+1, x)\}$
- $W_D = \frac{s^2}{2s-1} \sum_{d \in D} |P_{d,s,x} - P_{d,s-1,x}|$
- $Y_D(s_p, x) = H_D(s_p, x) W_D(s_p, x)$
- Supresión de no máximos



Contenido

- 1 Introducción y objetivos
- 2 Extracción de características visuales
- 3 El algoritmo Scale Saliency
- 4 Filtrado Bayesiano previo al Scale Saliency**
- 5 Scale Saliency multidimensional
- 6 Conclusiones



Introducción

- El **tiempo de ejecución** del algoritmo Scale Saliency es **el más alto**

Hipótesis

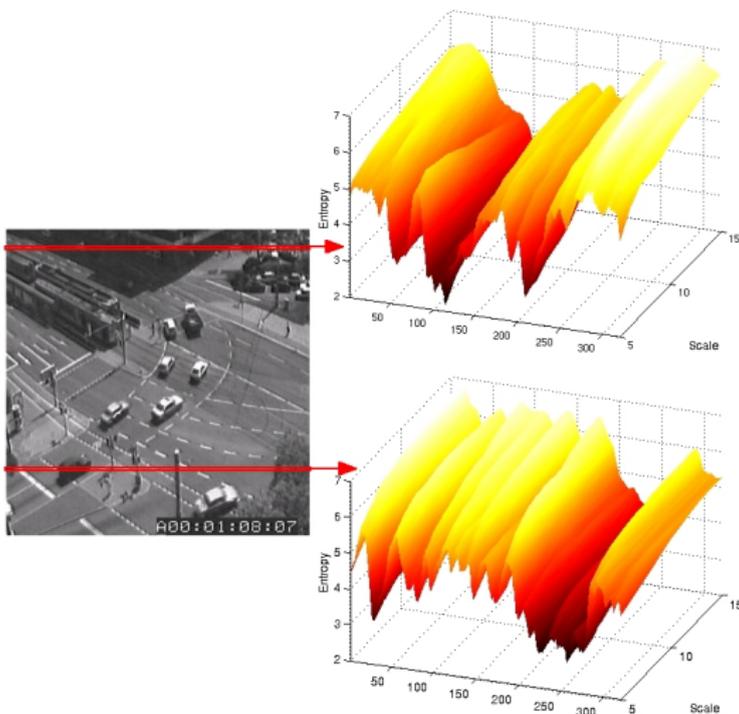
Las regiones de la imagen que no son de interés (homogéneas) en escalas altas, tampoco lo serán en escalas bajas

- Filtrado de regiones con poca probabilidad de contener características de interés (*previo* al Scale Saliency)



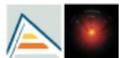
Análisis de la entropía en el espacio de escalas

■ Entropía en el espacio de escalas



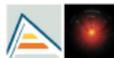
Análisis de la entropía en el espacio de escalas

- p_x : probabilidad de que x sea parte de las características de interés
 - $H_D(s_{max}, x) \uparrow$ y $H_D(s_{min}, x) \uparrow \rightarrow p_x \uparrow\uparrow$
 - $H_D(s_{max}, x) \uparrow$ o $H_D(s_{min}, x) \uparrow \rightarrow p_x \uparrow$
 - $H_D(s_{max}, x) \downarrow$ y $H_D(s_{min}, x) \downarrow \rightarrow p_x \downarrow$



Análisis de la entropía en el espacio de escalas

- Análisis utilizando el conjunto de images *Object Categories* del *Visual Geometry Group*



Análisis de la entropía en el espacio de escalas

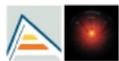
- Análisis utilizando el conjunto de images *Object Categories* del *Visual Geometry Group*

$$f_3 = \frac{h_{min}}{H_{min}}$$

$$f_5 = \frac{h_{max}}{H_{max}}$$

$$f_7 = \frac{h^*}{H_{min}}$$

$$f_9 = \frac{h^*}{H_{max}}$$



Análisis de la entropía en el espacio de escalas

- Análisis utilizando el conjunto de imágenes *Object Categories* del *Visual Geometry Group*

- Correlación

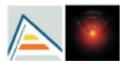
$$f_3 = \frac{h_{min}}{H_{min}}$$

$$f_5 = \frac{h_{max}}{H_{max}}$$

$$f_7 = \frac{h^*}{H_{min}}$$

$$f_9 = \frac{h^*}{H_{max}}$$

	f_3	f_5	f_7	f_9
f_3	1	0.8153	0.8326	0.8278
f_5	0.8153	1	0.9917	0.9960
f_7	0.8326	0.9917	1	0.9942
f_9	0.8278	0.9969	0.9942	1



Análisis de la entropía en el espacio de escalas

- Análisis utilizando el conjunto de images *Object Categories* del *Visual Geometry Group*

- Correlación

$$f_3 = \frac{h_{min}}{H_{min}}$$

$$f_5 = \frac{h_{max}}{H_{max}}$$

$$f_7 = \frac{h^*}{H_{min}}$$

$$f_9 = \frac{h^*}{H_{max}}$$

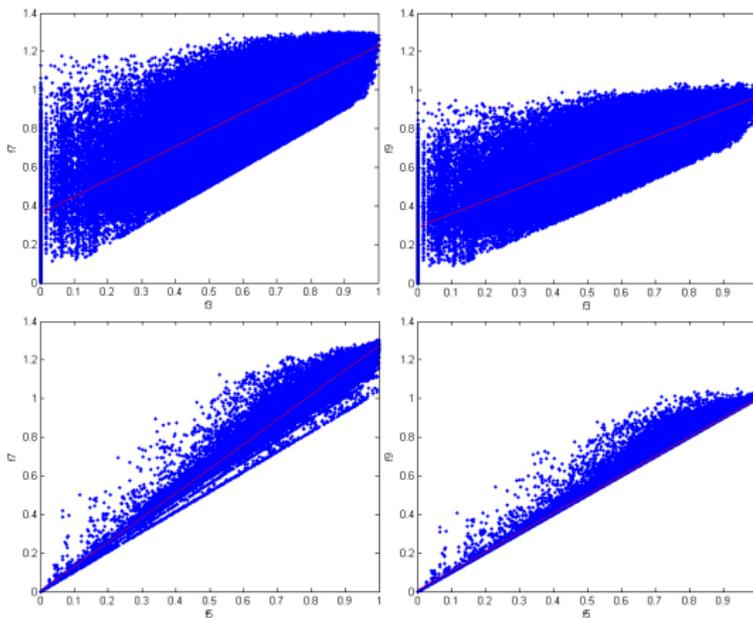
	f_3	f_5	f_7	f_9
f_3	1	0.8153	0.8326	0.8278
f_5	0.8153	1	0.9917	0.9960
f_7	0.8326	0.9917	1	0.9942
f_9	0.8278	0.9969	0.9942	1

- Correlación múltiple (f_3 y f_5 como variables independientes)
 - $f_7 \rightarrow 0.9926$
 - $f_9 \rightarrow 0.9964$



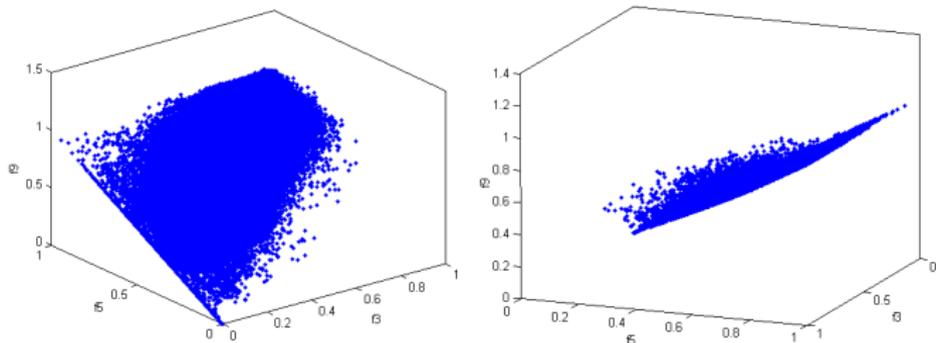
Análisis de la entropía en el espacio de escalas

■ Relación entre las variables analizadas



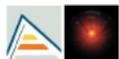
Análisis de la entropía en el espacio de escalas

■ Relación entre las variables analizadas



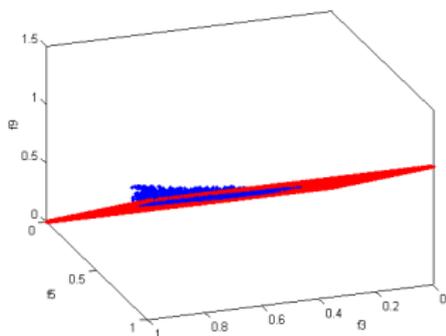
Análisis de la entropía en el espacio de escalas

- El límite inferior forma el plano $f_9 = s_x f_3 + s_y f_5 + d$



Análisis de la entropía en el espacio de escalas

- El límite inferior forma el plano $f_9 = s_x f_3 + s_y f_5 + d$



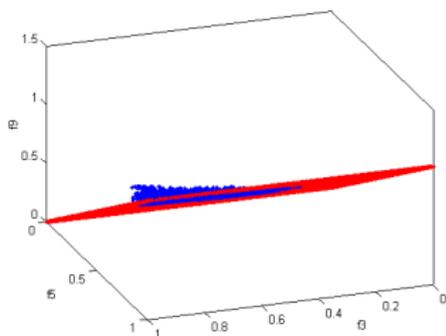
$$s_x = 0$$

$$s_y = 1.01$$

$$d = 0.015$$

Análisis de la entropía en el espacio de escalas

- El límite inferior forma el plano $f_9 = s_x f_3 + s_y f_5 + d$

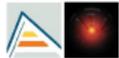


$$s_x = 0$$

$$s_y = 1.01$$

$$d = 0.015$$

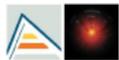
- h^* depende de h_{min} y h_{max}
- El límite inferior de h^* depende de h_{max}
- Conclusión:** p_x depende en gran medida de $H_D(s_{max}, x)$



Una primera solución de filtrado

Primer algoritmo de filtrado

- 1 Calcular la entropía local H_D de cada píxel x en la escala s_{max}
- 2 Establecer un umbral de entropía normalizada $\sigma \in [0, 1]$
- 3
$$X = \left\{ x : \frac{H_D(x, s_{max})}{\max_x \{H_D(x, s_{max})\}} > \sigma \right\}$$
- 4 Aplicar el algoritmo Scale Saliency sólo a los píxeles $x \in X$



Una primera solución de filtrado

- El parámetro σ es crítico

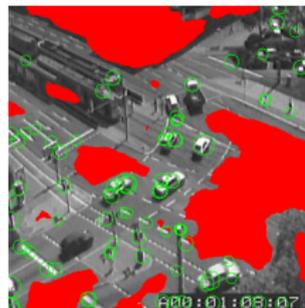
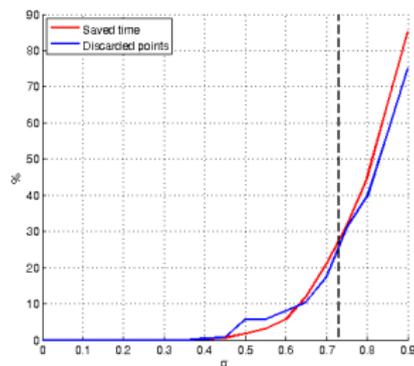


$\sigma = 0.73$

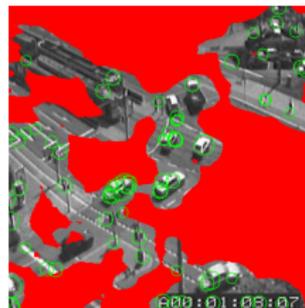
$\sigma = 0.82$

Una primera solución de filtrado

- El parámetro σ es crítico



$\sigma = 0.73$



$\sigma = 0.82$

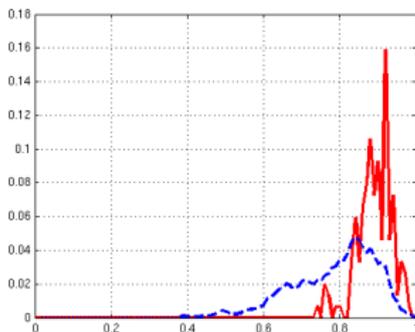
Una primera solución de filtrado

- El parámetro σ es crítico
- El máximo σ sin error obtenido mediante análisis estadístico [Konishi et al., 2003]



Una primera solución de filtrado

- El parámetro σ es crítico
- El máximo σ sin error obtenido mediante análisis estadístico [Konishi et al., 2003]
- Definición de las distribuciones $P(\theta|on)$ y $P(\theta|off)$



Una primera solución de filtrado

- El parámetro σ es crítico
- El máximo σ sin error obtenido mediante análisis estadístico [Konishi et al., 2003]
- Definición de las distribuciones $P(\theta|on)$ y $P(\theta|off)$
- Problemas
 - El máximo σ sin error solamente puede ser obtenido **a posteriori**
 - Este valor es válido para **una única** imagen



Filtrado Bayesiano e información de Chernoff

Hipótesis

Las imágenes pertenecientes a una misma categoría comparten ciertas propiedades → La entropía normalizada de sus características de interés se encontrará en el mismo rango

- Aprendizaje de un umbral σ general para una categoría de imágenes
 - Estimación de las distribuciones $P(\theta|on)$ y $P(\theta|off)$ a partir de un conjunto de entrenamiento



Filtrado Bayesiano e información de Chernoff

- La técnica anterior tan solo debería ser aplicada a un conjunto *homogéneo* de imágenes
- Información de Chernoff como medida de *homogeneidad*

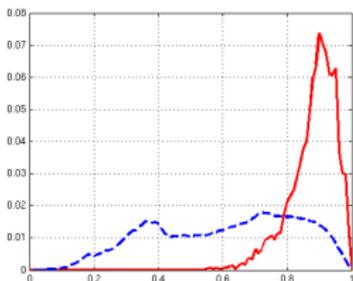
$$C(P, Q) = - \min_{0 \leq \lambda \leq 1} \log \left(\sum_{j=1}^J P^\lambda(y_j) Q^{1-\lambda}(y_j) \right)$$



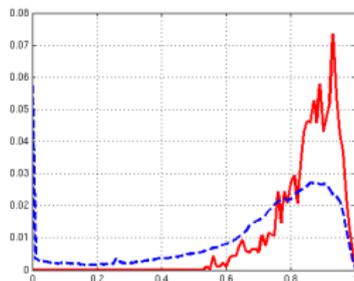
Filtrado Bayesiano e información de Chernoff

- La técnica anterior tan solo debería ser aplicada a un conjunto *homogéneo* de imágenes
- Información de Chernoff como medida de *homogeneidad*

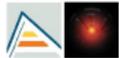
$$C(P, Q) = - \min_{0 \leq \lambda \leq 1} \log \left(\sum_{j=1}^J P^\lambda(y_j) Q^{1-\lambda}(y_j) \right)$$



airplanes_side $\rightarrow C(P_{on}, P_{off}) = 0.40$



camel $\rightarrow C(P_{on}, P_{off}) = 0.14$



Filtrado Bayesiano e información de Chernoff

- *log-likelihood test* como **medida de interés** de un píxel [Konishi et al., 2003]

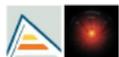
$$\log \frac{P(\theta|on)}{P(\theta|off)} > T$$

- El umbral T debe satisfacer la siguiente restricción [Cazorla and Escolano, 2003]

$$-D(P(\theta|off)||P(\theta|on)) < T < D(P(\theta|on)||P(\theta|off))$$

- siendo $D(p||q)$ la **divergencia de Kullback-Leibler** entre dos distribuciones p y q

$$D(p||q) = \sum_{j=1}^J p(y_j) \log \left(\frac{p(y_j)}{q(y_j)} \right)$$



Filtrado Bayesiano e información de Chernoff

- Diferentes resultados según el valor de T
 - $T \downarrow$ filtro conservador: buen equilibrio entre número de píxeles filtrados y error
 - $T \uparrow$ mayor número de píxeles filtrados, menor tiempo de ejecución, mayor error
 - La probabilidad de error decrece exponencialmente con $C(P(\theta|on), P(\theta|off))$
- Relación entre la información de Chernoff y el rango de valores de T (dado por la divergencia de Kullback-Leibler)



Filtrado Bayesiano e información de Chernoff

Entrenamiento - selección de un umbral para una categoría

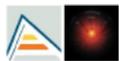
- 1 Estimar $P(\theta|on)$ y $P(\theta|off)$ a partir de un conjunto de entrenamiento
- 2 Si el valor de $C(P(\theta|on), P(\theta|off))$ es bajo
 - La categoría no es suficientemente homogénea \rightarrow dividir en dos o más subcategorías y repetir
- 3 Seleccionar un umbral en el rango
 - $D(P(\theta|off)||P(\theta|on)) < T < D(P(\theta|on)||P(\theta|off))$
 - El error aumentará con T según el valor de $C(P(\theta|on), P(\theta|off))$



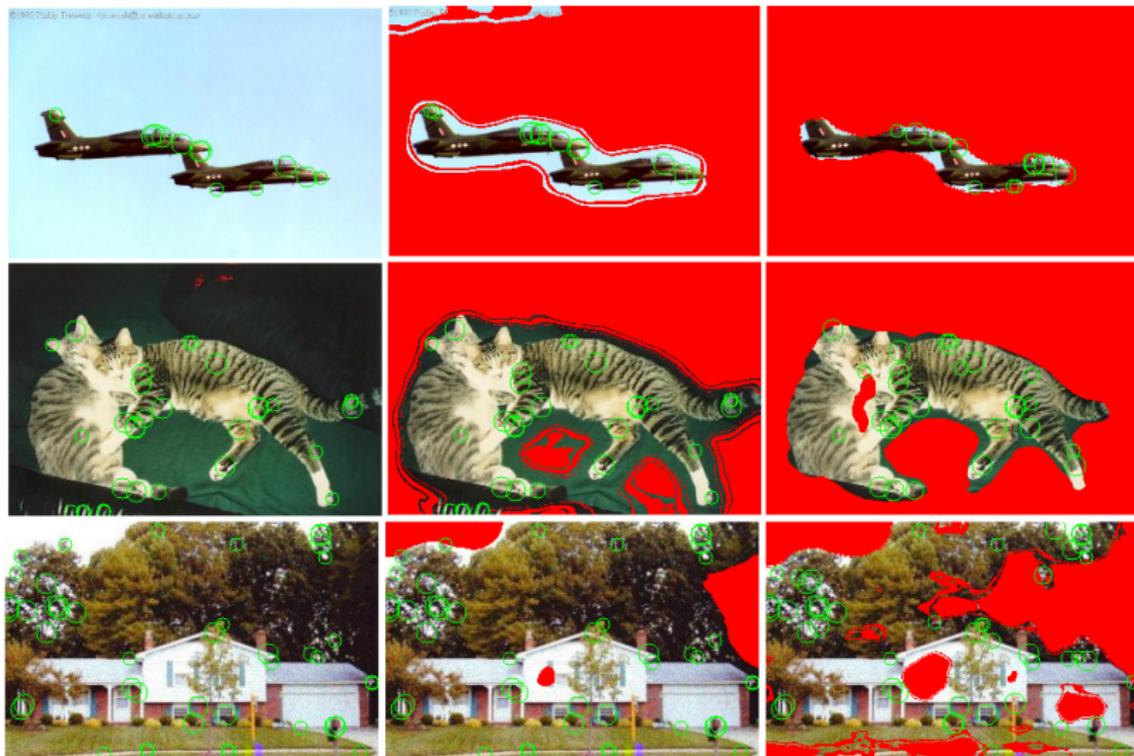
Filtrado Bayesiano e información de Chernoff

Filtrado de una imagen

- 1 Calcular la entropía normalizada $\theta_x = \frac{H_D(x, s_{max})}{\max_x \{H_D(x, s_{max})\}}$ para cada píxel x en la escala s_{max}
- 2 Seleccionar los puntos a procesar $X = \left\{ x \mid \log \frac{P(\theta_x|on)}{P(\theta_x|off)} > T \right\}$ según el umbral T para la categoría a la que pertenece la imagen de entrada
- 3 Aplicar el algoritmo Scale Saliency a los píxeles $x \in X$

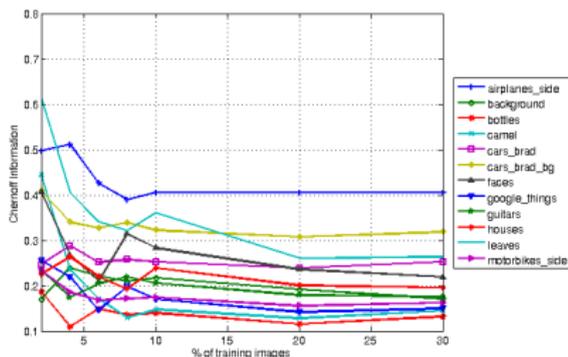


Resultados experimentales



Resultados experimentales

- Límites del entrenamiento
 - Información de Chernoff como medida de calidad de un clasificador [Konishi et al., 2003]



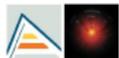
Resultados experimentales

- Efecto en el filtrado de los parámetros del algoritmo Scale Saliency



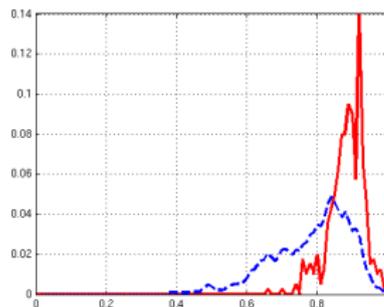
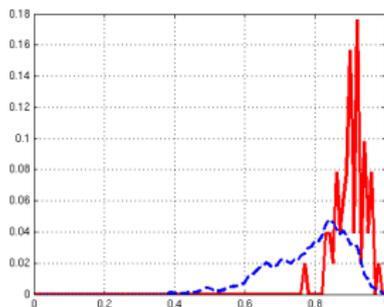
Resultados experimentales

- Efecto en el filtrado de los parámetros del algoritmo Scale Saliency
 - Número de regiones de interés



Resultados experimentales

- Efecto en el filtrado de los parámetros del algoritmo Scale Saliency
 - Número de regiones de interés
 - Influye en $P(\theta|on)$ y $P(\theta|off)$ para una imagen



Resultados experimentales

- Efecto en el filtrado de los parámetros del algoritmo Scale Saliency
 - Número de regiones de interés
 - Influye en $P(\theta|on)$ y $P(\theta|off)$ para una imagen
 - No grandes cambios en $P(\theta|on)$ y $P(\theta|off)$ de una categoría



Resultados experimentales

- Efecto en el filtrado de los parámetros del algoritmo Scale Saliency
 - Número de regiones de interés
 - Influye en $P(\theta|on)$ y $P(\theta|off)$ para una imagen
 - No grandes cambios en $P(\theta|on)$ y $P(\theta|off)$ de una categoría
 - Rango de escalas
 - Parámetro clave



Resultados experimentales

- Efecto en el filtrado de los parámetros del algoritmo Scale Saliency
 - Número de regiones de interés
 - Influye en $P(\theta|on)$ y $P(\theta|off)$ para una imagen
 - No grandes cambios en $P(\theta|on)$ y $P(\theta|off)$ de una categoría
 - Rango de escalas
 - Parámetro clave
 - Los resultados de filtrado mejoran si se adapta al conjunto de datos



Aplicación: localización robótica



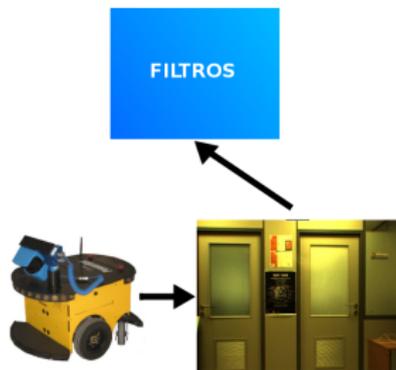
Aplicación: localización robótica



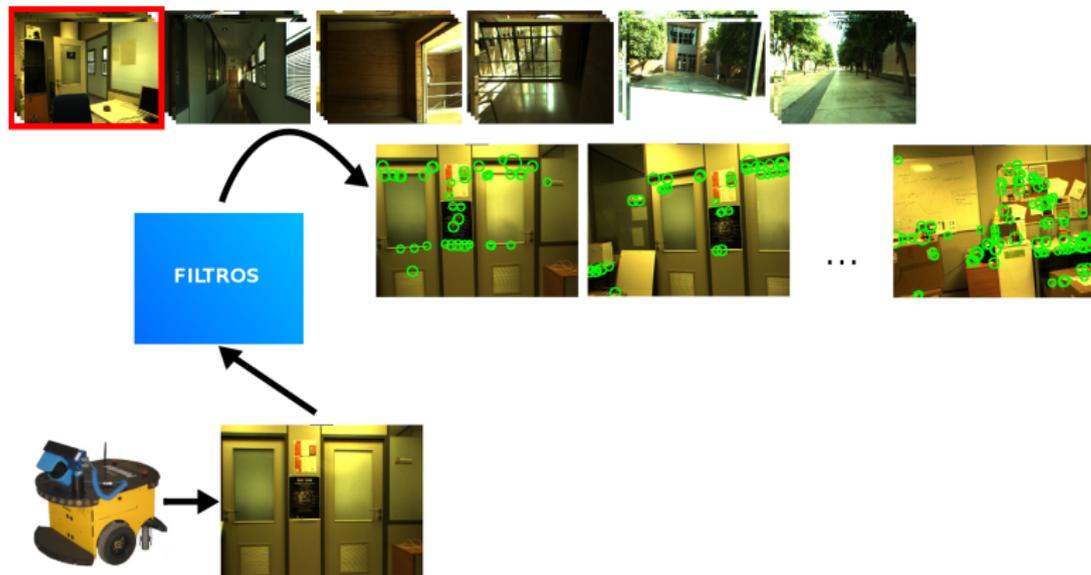
Aplicación: localización robótica



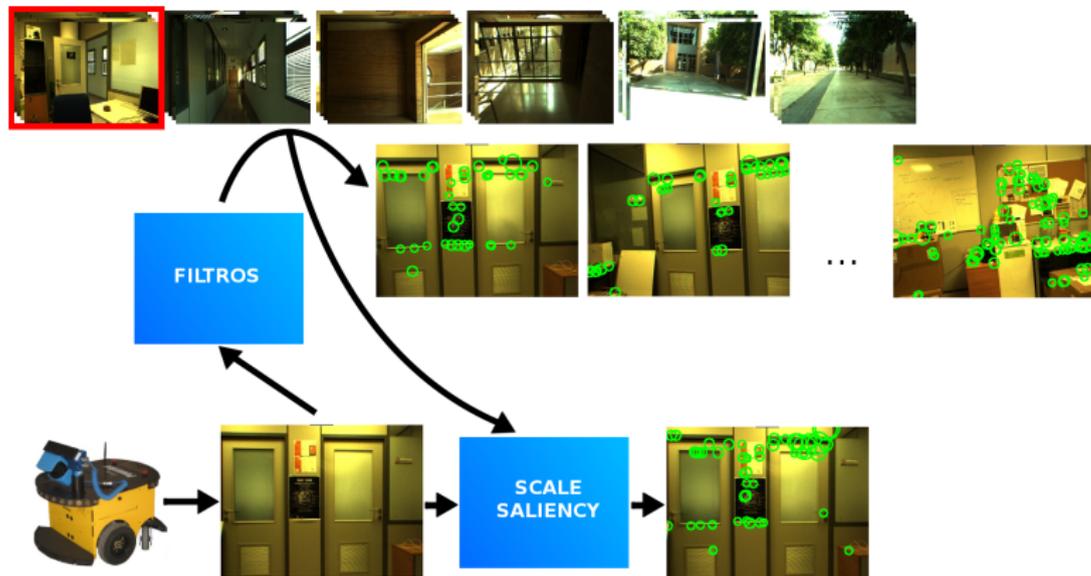
Aplicación: localización robótica



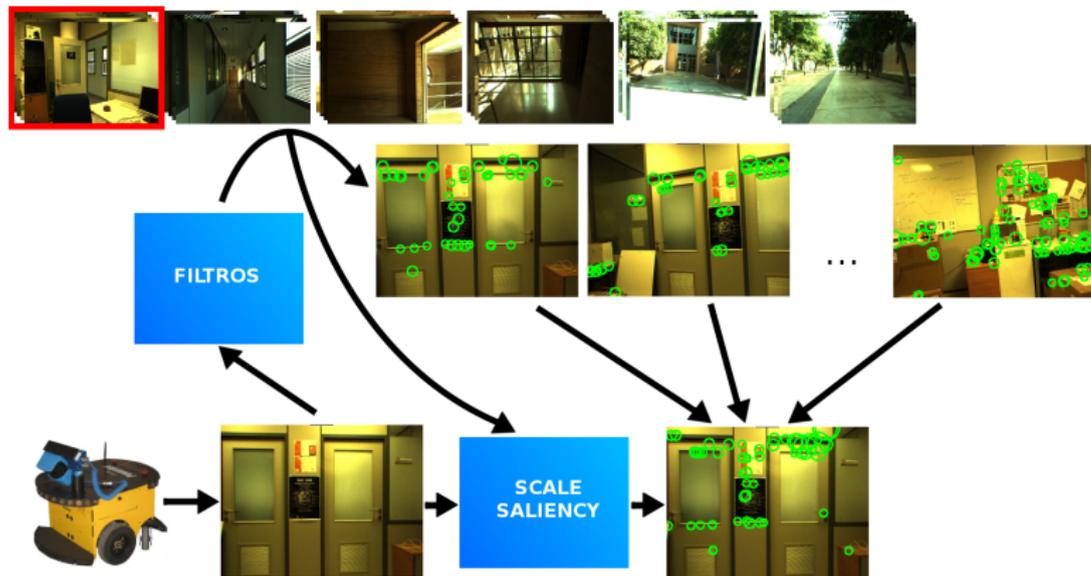
Aplicación: localización robótica



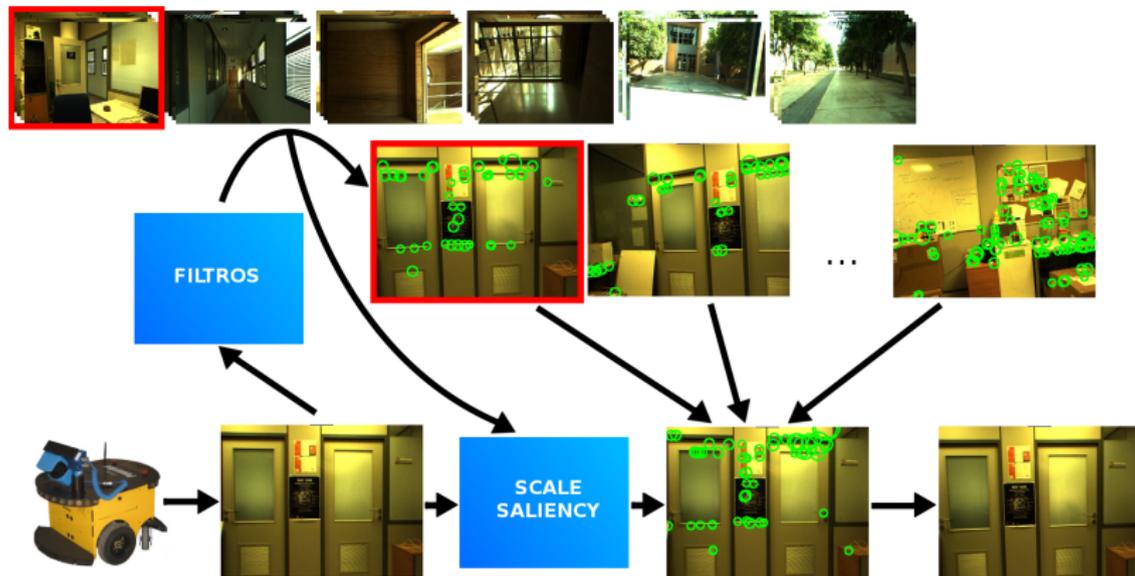
Aplicación: localización robótica



Aplicación: localización robótica

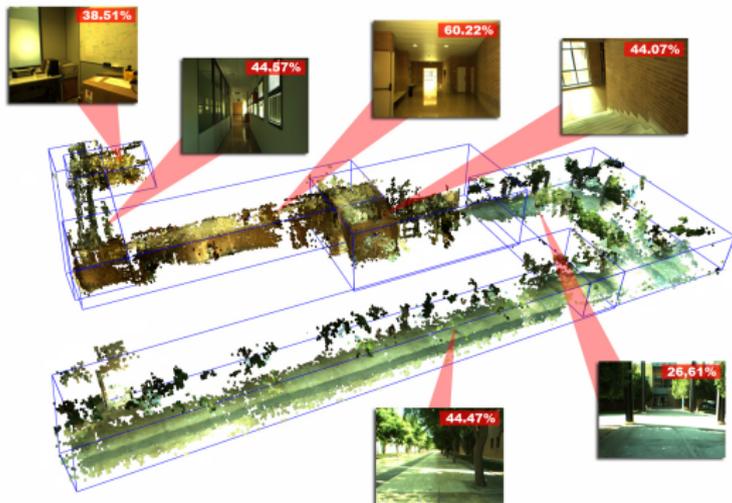


Aplicación: localización robótica



Aplicación: localización robótica

■ Resultados



Contenido

- 1 Introducción y objetivos
- 2 Extracción de características visuales
- 3 El algoritmo Scale Saliency
- 4 Filtrado Bayesiano previo al Scale Saliency
- 5 Scale Saliency multidimensional**
- 6 Conclusiones



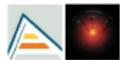
Introducción

- Scale Saliency fácilmente aplicable a dominios multidimensionales
- Basado en histogramas: **maldición de la dimensionalidad**
 - Complejidad exponencial
 - Histogramas dispersos

Hipótesis

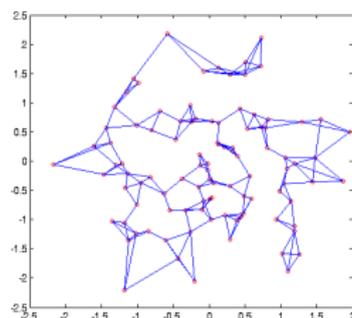
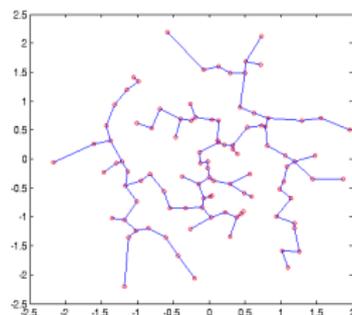
Estimadores alternativos permitirán superar las limitaciones de los histogramas

- Estudio de diferentes estimadores
 - Basados en grafos
 - K-d partition



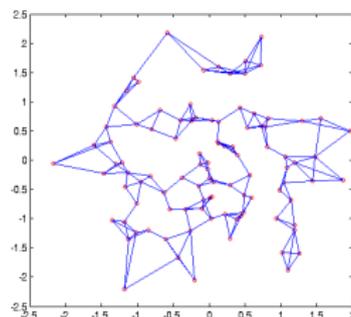
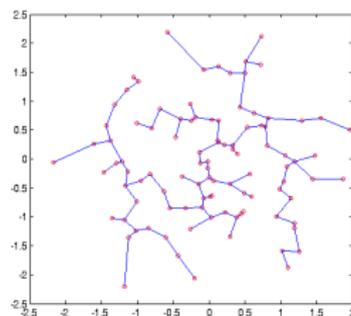
Estimación a partir de grafos entrópicos

- Grafos entrópicos
 - Minimal Spanning Trees
 - K-Nearest Neighbour Graphs



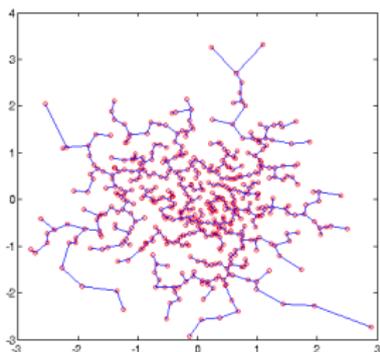
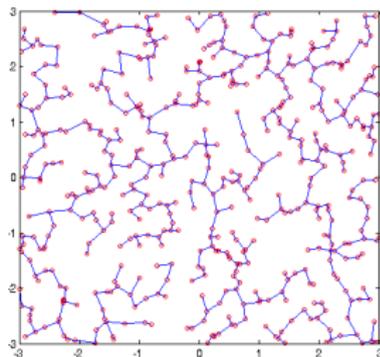
Estimación a partir de grafos entrópicos

- Grafos entrópicos
 - Minimal Spanning Trees
 - K-Nearest Neighbour Graphs
- Nuestra propuesta
 - $x \in X \rightarrow$ vector d -dimensional
 - $R_x \rightarrow$ grafo $G = (V, E)$ no dirigido y totalmente conexo



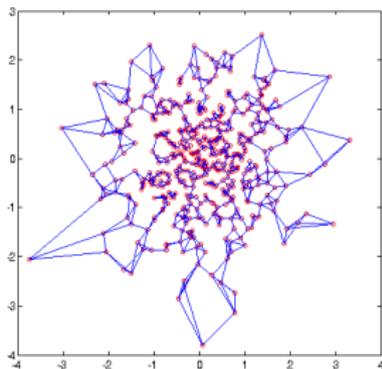
Estimación a partir de grafos entrópicos

- Estimación de entropía
 - Entropía de Shannon a partir de entropía de Rényi [[Hero and Michel, 1999](#)][[Peñalver et al., 2009](#)]

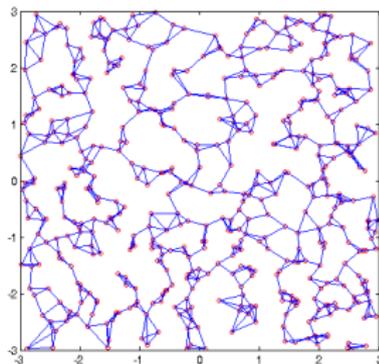
 $H = 1.1838$  $H = 1.9762$

Estimación a partir de grafos entrópicos

- Estimación de entropía
 - Entropía de Shannon a partir de entropía de Rényi [[Hero and Michel, 1999](#)][[Peñalver et al., 2009](#)]
 - Método de Kozachenko y Leonenko [[Leonenko et al., 2008](#)]



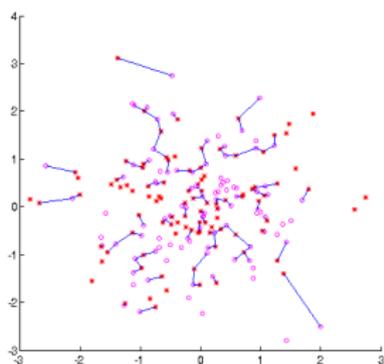
$$H = 2.7553$$



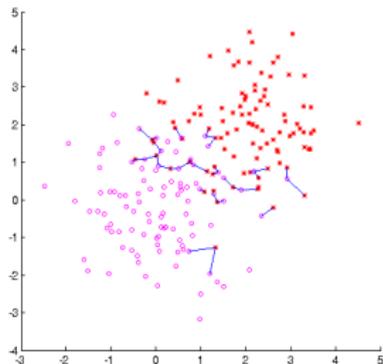
$$H = 3.6351$$

Estimación a partir de grafos entrópicos

- Estimación de entropía
 - Entropía de Shannon a partir de entropía de Rényi [[Hero and Michel, 1999](#)][[Peñalver et al., 2009](#)]
 - Método de Kozachenko y Leonenko [[Leonenko et al., 2008](#)]
- Estimación de divergencia
 - Test de Friedman-Rafsky (divergencia de Henze-Penrose) [[Friedman and Rafsky, 1979](#)]



$$D_{HP}(O||X) = 0.5427$$



$$D_{HP}(O||X) = 0.8191$$



Estimación basada en el algoritmo k-d partition

- El algoritmo k-d partition [Stowell and Plumbley, 2009]

- Particionado recursivo
- Criterio de parada: uniformidad

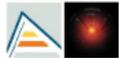
$$Z_j = \sqrt{n_j} \frac{2\text{med}_d(A_j) - \min_d(A_j) - \max_d(A_j)}{\max_d(A_j) - \min_d(A_j)}, |Z_j| > 1.96$$

- El criterio de parada se empieza a aplicar a partir del nivel L_n

$$L_n = \lceil \frac{1}{2} \log_2(n) \rceil$$

- Estimación de entropía a partir de la partición $A = \{A_j | j = 1, \dots, m\}$

$$\hat{H} = \sum_{j=1}^m \frac{n_j}{n} \log \left(\frac{n}{n_j} \mu(A_j) \right)$$



Estimación basada en el algoritmo k-d partition

■ Nueva divergencia basada en k-d partition

- Basada en la distancia de variación total (alfabeto finito)
- Aplicar k-d partition al conjunto total de muestras $X \cup O$
- $A = \{A_j | j = 1, \dots, m\}$ es un alfabeto finito compartido por X e O
- Probabilidad de una celda

$$p_x(A_j) = \frac{n_{x,j}}{n_x} = p_j, \quad p_o(A_j) = \frac{n_{o,j}}{n_o} = q_j$$

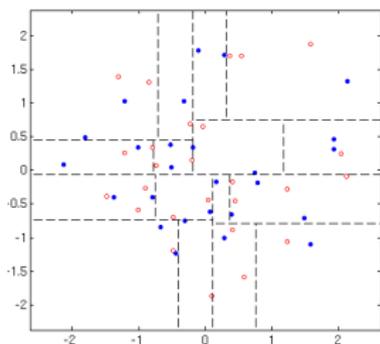
- Divergencia

$$D(O||X) = \frac{1}{2} \sum_{j=1}^p |p_j - q_j|$$

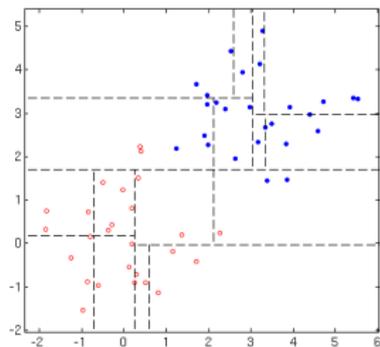


Estimación basada en el algoritmo k-d partition

■ Divergencia basada en k-d partition (ejemplo)



$$D(O||X) = 0.24$$



$$D(O||X) = 0.92$$

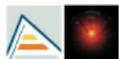
Scale Saliency multidimensional: el algoritmo

Scale Saliency multidimensional

Entrada: un array I de m dimensiones (m características por píxel)

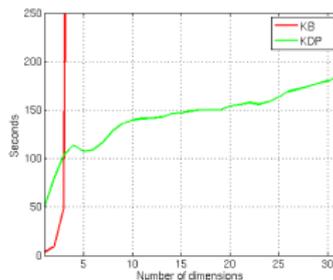
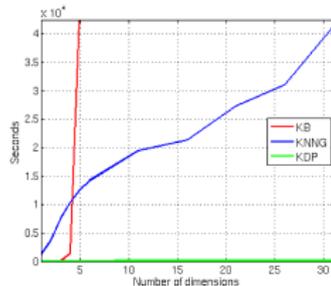
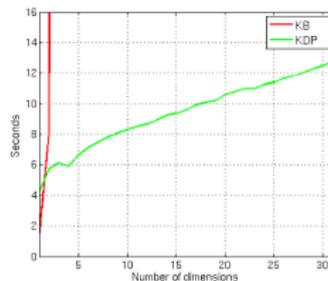
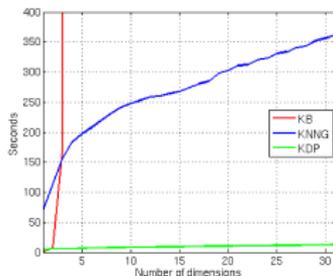
Salida: un array HW de entropía ponderada

- Para cada píxel x de la imagen
- Para cada escala s_j entre s_{min} y s_{max}
 - Crear un conjunto de muestras m dimensionales $X_j = \{x_j\}$ a partir de la vecindad de x en la escala s_j
 - Aplicar el algoritmo k-d partition a X para estimar la entropía $H(s_j)$
 - Si $s_j > s_{min} + 1$ y $H(s_{j-2}) < H(s_{j-1}) > H(s_j)$
 - Divergencia basada en k-d partition $W = D(X_{j-1} || X_{j-2})$
 - $HW(s_{j-1}, x) = H(s_{j-1}) \cdot W$
 - Sino
 - $HW(s_{j-1}, x) = 0$



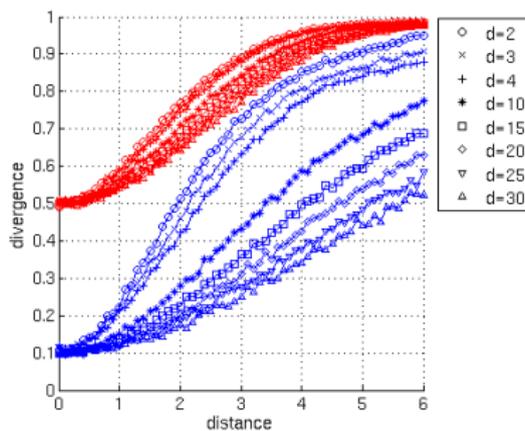
Resultados experimentales

■ Tiempo de ejecución



Resultados experimentales

■ Estimación divergencia



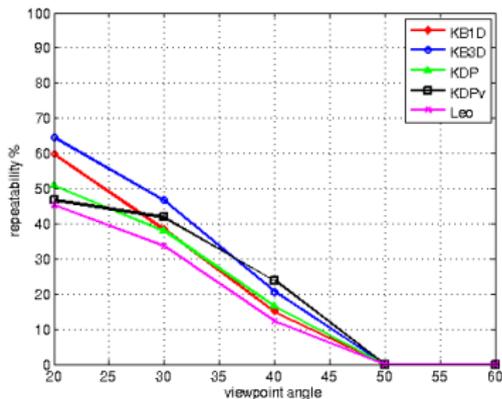
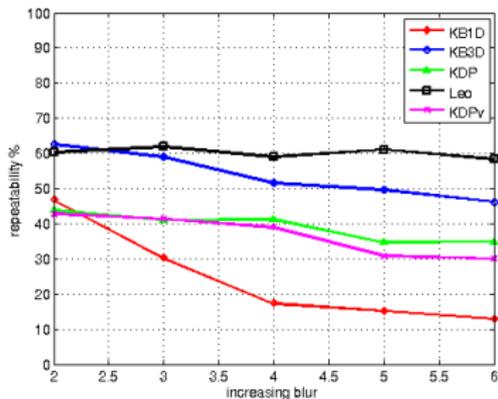
Resultados experimentales

- Repetibilidad [Mikolajczyk et al., 2005]



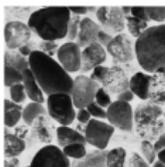
Resultados experimentales

■ Repetibilidad [Mikolajczyk et al., 2005]



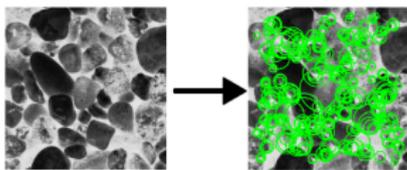
Aplicación: categorización de texturas

- Representación dispersa de texturas [Lazebnik et al., 2005]



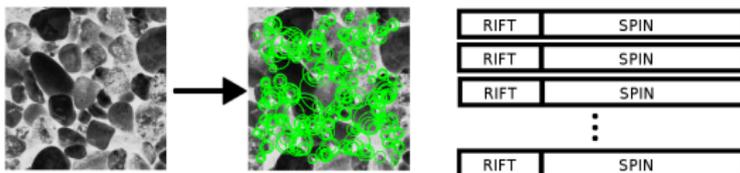
Aplicación: categorización de texturas

- Representación dispersa de texturas [Lazebnik et al., 2005]



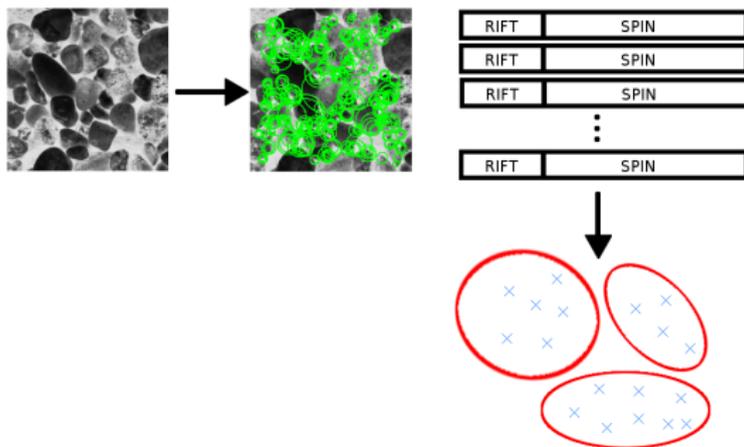
Aplicación: categorización de texturas

- Representación dispersa de texturas [Lazebnik et al., 2005]



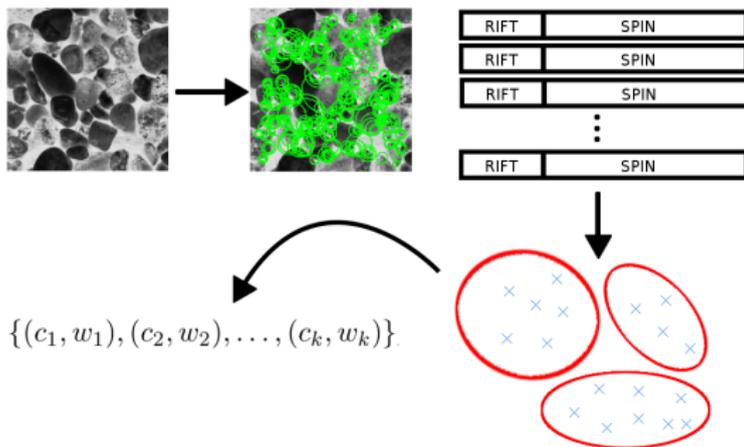
Aplicación: categorización de texturas

- Representación dispersa de texturas [Lazebnik et al., 2005]



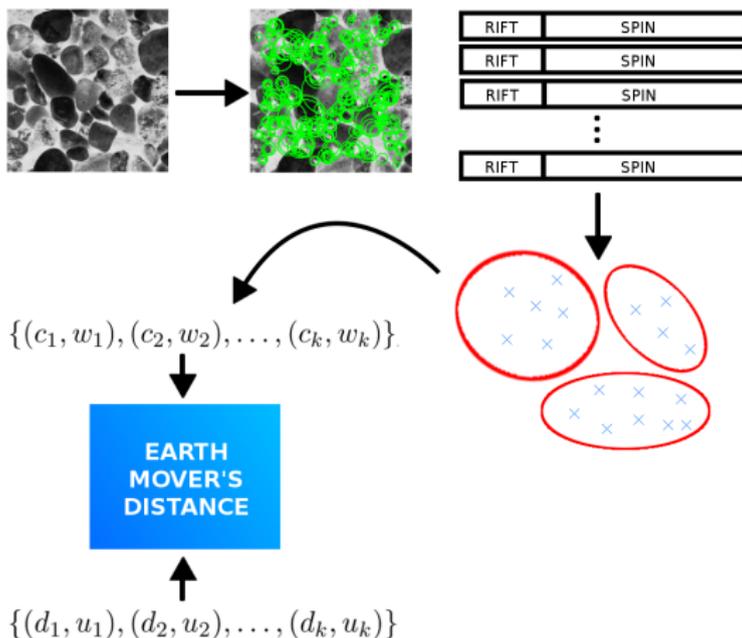
Aplicación: categorización de texturas

- Representación dispersa de texturas [Lazebnik et al., 2005]



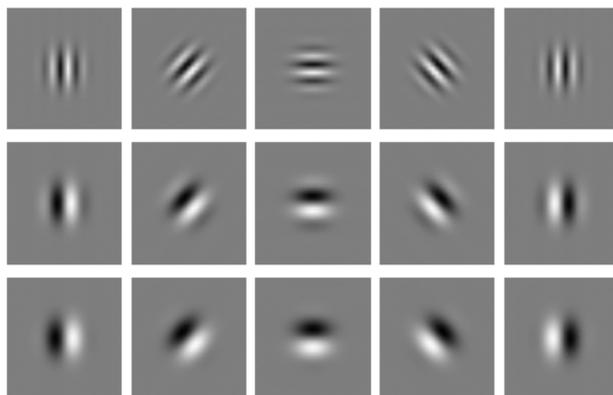
Aplicación: categorización de texturas

- Representación dispersa de texturas [Lazebnik et al., 2005]

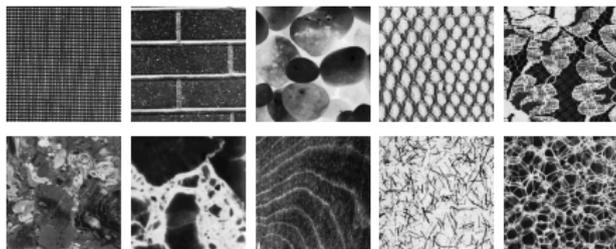


Aplicación: categorización de texturas

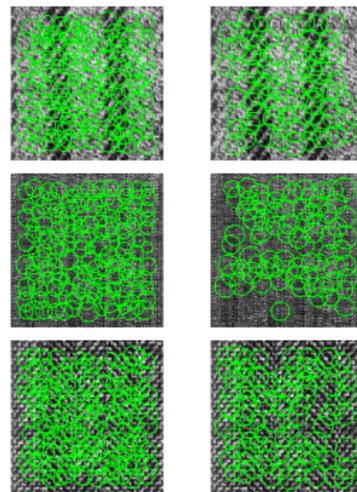
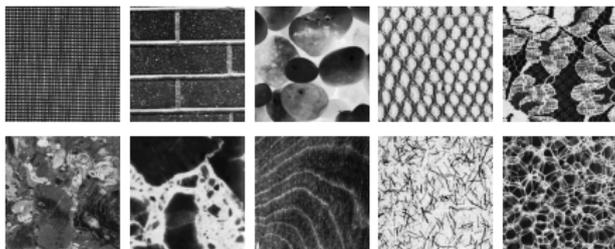
- Representación de texturas a partir de información multidimensional
 - Cada píxel de la imagen procesado con un banco de 15 filtros de Gabor
 - Extracción de características a partir de datos 15D mediante Scale Saliency multidimensional



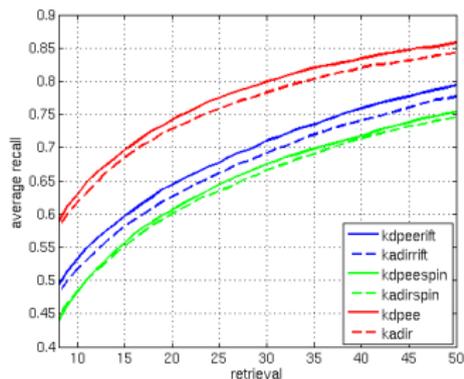
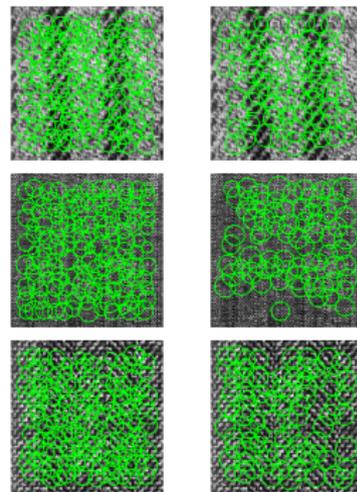
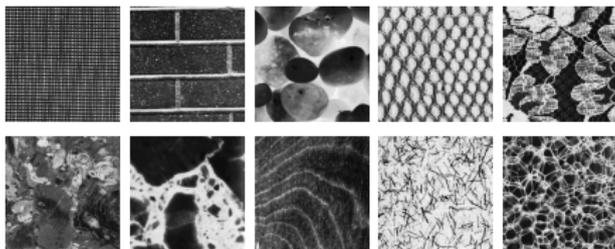
Aplicación: categorización de texturas



Aplicación: categorización de texturas



Aplicación: categorización de texturas



Contenido

- 1 Introducción y objetivos
- 2 Extracción de características visuales
- 3 El algoritmo Scale Saliency
- 4 Filtrado Bayesiano previo al Scale Saliency
- 5 Scale Saliency multidimensional
- 6 Conclusiones**



Conclusiones

- Resumen de las aportaciones
 - Filtrado Bayesiano previo al Scale Saliency



Conclusiones

- Resumen de las aportaciones
 - **Filtrado Bayesiano previo al Scale Saliency**
 - Análisis de la evolución de la entropía en el espacio de escalas



Conclusiones

- Resumen de las aportaciones
 - **Filtrado Bayesiano previo al Scale Saliency**
 - Análisis de la evolución de la entropía en el espacio de escalas
 - Primera solución básica de filtrado



Conclusiones

- Resumen de las aportaciones
 - **Filtrado Bayesiano previo al Scale Saliency**
 - Análisis de la evolución de la entropía en el espacio de escalas
 - Primera solución básica de filtrado
 - Uso de la teoría de la información para aprender un umbral válido para un conjunto de imágenes



Conclusiones

- Resumen de las aportaciones
 - **Filtrado Bayesiano previo al Scale Saliency**
 - Análisis de la evolución de la entropía en el espacio de escalas
 - Primera solución básica de filtrado
 - Uso de la teoría de la información para aprender un umbral válido para un conjunto de imágenes
 - Uso de la teoría de la información para evaluar la aplicabilidad de nuestra solución



Conclusiones

- Resumen de las aportaciones
 - **Filtrado Bayesiano previo al Scale Saliency**
 - Análisis de la evolución de la entropía en el espacio de escalas
 - Primera solución básica de filtrado
 - Uso de la teoría de la información para aprender un umbral válido para un conjunto de imágenes
 - Uso de la teoría de la información para evaluar la aplicabilidad de nuestra solución
 - Descenso notable del tiempo de ejecución



Conclusiones

- Resumen de las aportaciones
 - **Filtrado Bayesiano previo al Scale Saliency**
 - Análisis de la evolución de la entropía en el espacio de escalas
 - Primera solución básica de filtrado
 - Uso de la teoría de la información para aprender un umbral válido para un conjunto de imágenes
 - Uso de la teoría de la información para evaluar la aplicabilidad de nuestra solución
 - Descenso notable del tiempo de ejecución
 - Aplicación práctica: localización robótica



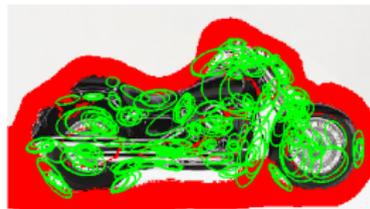
Conclusiones

- Líneas futuras (filtrado Bayesiano)
 - Selección no supervisada de categorías mediante información de Chernoff



Conclusiones

- Líneas futuras (filtrado Bayesiano)
 - Selección no supervisada de categorías mediante información de Chernoff
 - Aplicación del filtrado Bayesiano a
 - Scale Saliency con invarianza afín
 - Otros extractores de características: Harris, Hessian, etc.



Conclusiones

- Líneas futuras (filtrado Bayesiano)
 - Selección no supervisada de categorías mediante información de Chernoff
 - Aplicación del filtrado Bayesiano a
 - Scale Saliency con invarianza afín
 - Otros extractores de características: Harris, Hessian, etc.
 - Cascada de filtros a partir de filtros adicionales



Conclusiones

- Resumen de las aportaciones
 - Filtrado Bayesiano previo al Scale Saliency
 - **Scale Saliency multidimensional**



Conclusiones

- Resumen de las aportaciones
 - Filtrado Bayesiano previo al Scale Saliency
 - **Scale Saliency multidimensional**
 - Estudio de la aplicación de diferentes métodos de estimación basados en grafos y en el algoritmo k-d partition



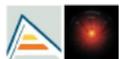
Conclusiones

- Resumen de las aportaciones
 - Filtrado Bayesiano previo al Scale Saliency
 - **Scale Saliency multidimensional**
 - Estudio de la aplicación de diferentes métodos de estimación basados en grafos y en el algoritmo k-d partition
 - Diseño de una nueva divergencia basada en el algoritmo k-d partition



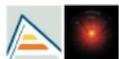
Conclusiones

- Resumen de las aportaciones
 - Filtrado Bayesiano previo al Scale Saliency
 - **Scale Saliency multidimensional**
 - Estudio de la aplicación de diferentes métodos de estimación basados en grafos y en el algoritmo k-d partition
 - Diseño de una nueva divergencia basada en el algoritmo k-d partition
 - Reducción del orden de complejidad



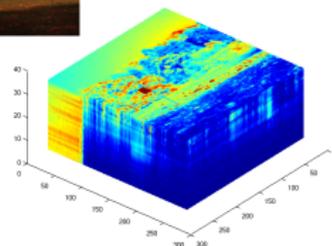
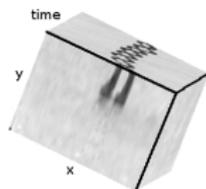
Conclusiones

- Resumen de las aportaciones
 - Filtrado Bayesiano previo al Scale Saliency
 - **Scale Saliency multidimensional**
 - Estudio de la aplicación de diferentes métodos de estimación basados en grafos y en el algoritmo k-d partition
 - Diseño de una nueva divergencia basada en el algoritmo k-d partition
 - Reducción del orden de complejidad
 - Aplicación práctica: categorización de texturas



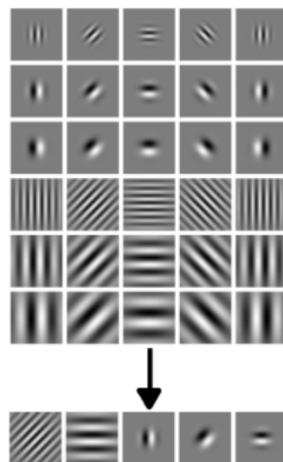
Conclusiones

- Líneas futuras (Scale Saliency multidimensional)
 - Nuevas aplicaciones (video, imágenes hiperespectrales, etc.)



Conclusiones

- Líneas futuras (Scale Saliency multidimensional)
 - Nuevas aplicaciones (video, imágenes hiperspectrales, etc.)
 - Mejora de la categorización de texturas mediante selección de características



Producción científica

■ Publicaciones más relevantes

- Pablo Suau, Francisco Escolano, **Exploiting Information Theory for Filtering the Kadir Scale-Saliency Detector, IBPRIA2007**
- Pablo Suau, Francisco Escolano, **Bayesian Optimization of the Scale Saliency Filter, Image and Vision Computing**, 26(9), pp. 1207–1218, 2008
- Miguel Ángel Lozano, Francisco Escolano, Boyán Bonev, Pablo Suau, Wendy Aguilar, Juan Manuel Sáez, Miguel Ángel Cazorla, **Region and Constellations Based Categorization of Images With Unsupervised Graph Learning, Image and Vision Computing**, 27(7), pp. 960–978, 2009
- Pablo Suau, Francisco Escolano, **Entropy Estimation and Multi-Dimensional Scale Saliency, ICPR2010**
- Francisco Escolano, Pablo Suau, Boyán Bonev, **Libro: Information Theory in Computer Vision and Pattern Recognition**, Springer, 2009



Detección de regiones de interés visuales basada en la teoría de la información

Presentada por *Pablo Suau*
Dirigida por *Dr. Francisco Escolano*

Programa *Ingeniería Informática y Computación*
Dpto. de Ciencia de la Computación e Inteligencia Artificial
Escuela Politécnica Superior
Universidad de Alicante

