Congr. Int. en Ing. Electrónica. Mem. ELECTRO, Vol. 39, pp. 67-71, Oct 2017, Chihuahua, Chih. , México
http://electro.itchihuahua.edu.mx/memorias_electro/MemoriaElectro2017.zip
ISSN 1405-2172

RECONOCIMIENTO DE LA HUELLA DACTILAR DE UN RATÓN MEDIANTE LOS K-VECINOS MÁS CERCANOS (KNN) Y MÉTRICAS DE ANÁLISIS DE TEXTURA

Mateo Juárez Jorge
Facultad de Ciencias de la Electrónica
jorge.mateo@alumno.buap.mx

Barreto Flores Aldrin
Facultad de Ciencias de la Electrónica
aldrin.barreto@correo.buap.mx

Bautista López Verónica Edith
Facultad de Ciencias de la Computación
vbautista@cs.buap.mx

Ayala Raggi Salvador Eugenio
Facultad de Ciencias de la Electrónica
saraggi@ece.buap.mx

Ramos Collazo Francisco
Bioterio Claude Bernard
bio_paco@yahoo.com.mx

Benemérita Universidad Autónoma de Puebla,
Prolongación 24 Sur S/N Ciudad Universitaria, San Manuel, 72570 Puebla, Pué.

RESUMEN.

Este trabajo presenta un método para la clasificación y reconocimiento de la imagen de la huella de un ratón en función de cinco puntos de referencia sobre la imagen, mediante la técnica de los k-vecinos más cercanos (kNN) y en función del análisis de su textura, esto es importante para reconocer roedores en un bioterio sin dañarlos cuando se tiene un conjunto de tres o más animales en el mismo contenedor y del mismo color, siendo una manera no invasiva para el reconocimiento de estos. Se evaluaron un conjunto de 208 imágenes, las cuales fueron pre-procesadas para acondicionarlos en cuanto a la alineación y normalización de los pixeles y de esta forma tener imágenes similares. Finalmente se utiliza un clasificador basado en los k vecinos más cercanos, donde se obtiene un 70% de reconocimiento de estas huellas.
Palabras Clave: Filtro Gaussiano, Knn, Matriz de co-ocurrencia, Warping

ABSTRACT.

This work presents a method for the classification and recognition of the image of the footprint of a mouse in function of five reference points on the image by the technique of the k-nearest neighbors (kNN) and based on the analysis of its texture, this is important to recognize rodents in a bioterio without damaging them when you have a set of three or more animals in the same container and the same color, being a non-invasive way to recognize them. A set of 208 images were evaluated, which were pre-processed to condition them in alignment and normalization of the pixels and thus have similar images. Finally a classifier is used based on the k nearest neighbors, where a 70% recognition of these footprint is obtained.
Keywords: Gaussian Filter, Knn, Co-occurrence Matrix, Warping

1. INTRODUCCIÓN.

En los bioterios pueden utilizarse una amplia variedad de sistemas de marcaje para la identificación de los animales de laboratorio como, por ejemplo: el pelaje, rasurado en alguna parte específica del cuerpo. También se usan tintes no tóxicos a prueba de agua. Marcadores de colores pueden ser usados en pelajes claros, o en áreas sin pelo. Estos sistemas presentan la desventaja de que se desvanecen muy fácilmente y no son eficientes en animales de pelajes obscuros. Otros métodos de identificación a corto plazo incluyen: marcas naturales, sexo, textura del pelaje, longitud y cepa.

En diversos trabajos se han empleado algunos métodos de reconocimiento y en función del cálculo de métricas como de textura o forma y clasificadores, como son mencionados en los artículos [8] y [7]. En este trabajo se emplea el procesamiento de imágenes de las huellas dactilares del ratón para su identificación, el cual está conformado por algoritmos que

permiten la reducción del ruido, el alineamiento, la normalización y clasificación de las huellas, por lo cual es un método no invasivo. A continuación se presenta los conceptos y la metodología empleada.

2. PRE-PROCESAMIENTO DE LA IMAGEN.

2.1. Filtrado.

La atenuación del ruido en una imagen mediante el filtro Gaussiano es menos agresiva que el de bordes debido a la forma de esta función, la parte central aislará el ruido con mayor fuerza que en la periferia, la respuesta impulsiva de la función Gaussiana es dada por la siguiente relación [6]:

$$g(m,n) = \frac{1}{2\pi\sigma^2} e^{\frac{-m^2+n^2}{2\sigma^2}} \qquad (1)$$

Donde σ es la varianza de la exponencial bidimensional sobre los ejes m y n, que definen el tamaño de la máscara.

3. SEGMENTACIÓN DE LA IMAGEN.

3.1. Análisis de Procrustes.

El análisis de procustes minimiza las diferencias entre las configuraciones de puntos de referencia (landmarks) basado en mínimos cuadrados y transformaciones [2]. El método general consiste en tres pasos:

a) La variación en el tamaño, se limita a ajustar cada configuración de landmarks de modo que tenga un tamaño de centroide igual a 1 (El tamaño del centroide, es una medida de tamaño que cuantifica la extensión de los landmarks entorno a su centro de gravedad).
b) La variación en la posición, es removida mediante el desplazamiento de las configuraciones de manera que compartan la misma posición de su centro de gravedad.
c) Las configuraciones se rotan hasta encontrar una orientación óptima para cada una de las configuraciones.

El procedimiento para el análisis de procrustes se muestra de manera gráfica en la figura 1, donde en la figura 1 a) se tienen un conjunto de cinco pentágonos, el cual cada uno de ellos tiene cinco puntos de referencia colocados en sus vértices, el análisis implica realizar variaciones en tamaño, desplazamiento y rotación en función a los puntos de referencia, figuras 1 b) y 1 c), hasta lograr que todos los puntos estén alineados como se observa en la figura 1 d).

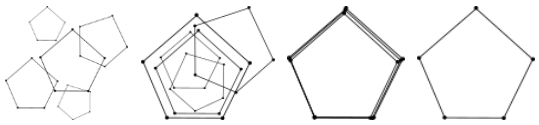

a) b) c) d)

Figura 1. Representacion generalizada del análisis de procrustes.

En este trabajo, se colocan cinco puntos de referencia sobre las imágenes de las huellas del ratón. Estos puntos no están alineados debido a la captura de la huella que no es la misma y están localizados los puntos de referencia en diferentes ubicaciones sobre la imagen. El empleo de este método da como resultado cuanto se debe variar en tamaño, desplazamiento y rotación, para cada forma o modelo que en este caso es un pentágono delimitado por cinco puntos de referencia, estas variaciones pueden deformar el modelo por lo cual se calculó la media del tamaño, desplazamiento y rotación, de tal forma se obtuvo una forma media del modelo del pentágono.

3.2. Deformación de la imagen.

La deformación de la imagen (image warping) es el proceso de manipulación digital, mediante técnicas matemáticas basadas en modelos activos de apariencia (AAM), de tal manera que cualquier forma representada en la imagen se distorsione significativamente. AAM son un método estadístico de ajuste entre los modelos de forma, apariencia, movimiento y una imagen dada. La colocación de una AAM en una imagen implica estimar los parámetros del modelo para que el modelo ejemplo y la imagen dada sean lo suficientemente cercanas. Una formulación propuesta por [4] para los modelos activos de apariencia soluciona de manera eficiente la optimización para el ajuste rápido y exacto de AAM .

El empleo de este método es para alinear todas las imágenes a base de la forma media que está conformado por cinco puntos de referencia sobre la imagen de la huella del ratón.

3.3. Normalización de la imagen.

La normalización de las imágenes se realizó mediante la siguiente expresión:

$$I_{norm} = \frac{\sum_i (I_i - \bar{I})}{\|I\|} \qquad (2)$$

Donde I_i es un vector columna de la i-ésima imagen, $\bar{I}$ es la media del vector I_i y $\|I\|$ es la norma del vector I_i.

4. EXTRACCIÓN DE CARACTERÍSTICAS.

La textura en imágenes digitales describe la estructura de una superficie, esta descripción se puede obtener con propiedades como la granulosidad, el contraste y la dirección de las fibras. El análisis de texturas se fundamente en el análisis de información redundante, y es por eso que puede presentar errores considerables cuando se aplica a zonas fronterizas donde existen cambios de textura. El análisis de textura es dependiente de que la distribución del vecindario sea uniforme con respecto a una medida y un periodo determinado [1].

Los elementos de la matriz de coocurrencia $M_d(i,j)$, representan las frecuencias relativas de los niveles de gris i y j, tomando los píxeles dos a dos y separados una distancia d según una dirección dada. Así, cuanto mayores sean los valores de su diagonal principal más homogénea será la textura que representa, mientras que cuanto más distribuidos estén los valores fuera de la diagonal más heterogénea será. La matriz de coocurrencia normalizada es la siguiente:

$$N_d(i,j) = \frac{M_d(i,j)}{\sum_{i=1}\sum_{j=1} M_d(i,j)} \qquad (3)$$

Las características derivadas de una matriz de coocurrencia normalizada son métricas como energía, entropía, homogeneidad, contraste y correlación que son los más comunes en [8].

La propiedad de energía da una idea de la suavidad de la textura, y esto se refleja en la ubicación de sus probabilidades en la matriz de co-ocurrencia. De modo que, si una mayor cantidad de píxeles de colores iguales cumplen con la condición de ocurrencia, será posible observar un pico de intensidad en la diagonal principal de la matriz. La forma de calcularla es:

$$Energía(i,j) = \sum_i \sum_j N_d^2(i,j) \qquad (4)$$

La entropía de una imagen es una medida de su información. Si la entropía es alta, la información tiende a ser altamente imprevisible porque algo imprevisible o infrecuente aporta más información que algo previsible. Una imagen con información de alta entropía, contiene mucha aleatoriedad y baja redundancia.

$$Entropía(i,j) = -\sum_i \sum_j N_d(i,j)\, log_2 N_d(i,j) \qquad (5)$$

El contraste de una textura proporciona información acerca de las variaciones bruscas de color en la imagen. La extracción de este descriptor está dada por la expresión:

$$Contraste(i,j) = \sum_i \sum_j (i-j)^2 N_d(i,j) \qquad (6)$$

El descriptor de homogeneidad local proporciona información sobre la regularidad local de la textura. Indica que mientras los elementos de la matriz de coocurrencia estén más próximos a la diagonal principal mayor será el valor de la homogeneidad local.

$$Homogeneidad(i,j) = \sum_{\mathrm{i}} \sum_{\mathrm{j}} \frac{N_d(i,j)}{1+|i-j|} \qquad (7)$$

La correlación de la textura es una medida de la probabilidad que mide la relación entre las diferentes intensidades presentes en el entorno definido en la matriz de co-ocurrencia. Matemáticamente la correlación se describe como:

$$Correlación(i,j) = \frac{\sum_i \sum_j (i-\mu_i)(j-\mu_j) N_d(i,j)}{\sigma_i \sigma_j} \qquad (8)$$

Donde σ_i y μ_i son respectivamente la desviación estándar y la media de las filas de $N_d(i,j)$ y para las columnas son σ_j y μ_j.

Las métricas mencionadas anteriormente para la textura fueron utilizadas para construir un vector característico para clasificación por medio de la huella dactilar del ratón.

5. CLASIFICACIÓN.

5.1. Técnica de los k vecinos más cercanos (kNN).

El método del vecino más cercano en [3] representa una de las técnicas más simples e intuitivas en el campo de la discriminación estadística. Es un método no paramétrico, donde un nuevo ejemplo se coloca en la clase de la observación del conjunto de aprendizaje más cercano al nuevo ejemplo, con respecto a las covariables utilizadas. La determinación de esta similitud se basa en medidas de distancia [5].

5.2. Cálculo de la distancia ponderada de los k vecinos más cercanos.

Sea x_q un vector de características para prueba x_i con $i = 1,2,\ldots,k$ los k vectores más cercanos a x_q, $f(x_i)$ una función de etiquetado que otorga huella dactilar (clase) a cada ejemplo x_i de tal manera que:

$$\hat{f}(x_q) \leftarrow \frac{\sum_{i=1}^{k} w_i f(x_i)}{\sum_{i=1}^{k} w_i} \qquad (9)$$

Donde $\hat{f}(x_q)$ es la etiqueta estimada y w_i son pesos de distancia lineal que es calculado en función de una base radial como:

$$w_i = e^{-Cd^2(x_q,x_i)} \qquad (10)$$

Donde

$$C = \frac{1}{\frac{1}{3} d_{min}^2(x_q,x_i)} \qquad (11)$$

$$d(x_q,x_i) = \sqrt{\sum_{i=1}^{k} \left(x_q(i) - x_i(i)\right)^2} \qquad (12)$$

6. METODOLOGÍA.

Primero se colocaron manualmente cinco puntos sobre 208 imágenes plantares de la extremidad posterior izquierda de 6 ratas (ratus norvegicus) de la cepa Spragüe/Dawley, donde se formaron dos grupos G1 (105 imágenes) y G2 (103 imágenes). El grupo G1esta conformado por 3 ratones hembras (H1, H2 y H3) con 35 imágenes para cada animal y el grupo G2 tiene 3 ratones machos (M1, M2, M3) con subgrupos de 35, 35 y 33 imágenes correspondientemente, estos dos grupos fueron empleados como vector de prueba. También se utilizaron 25 imágenes de entrenamiento por cada ratón, formando una base de datos de 150 imágenes con los cinco puntos de referencia. En la figura 2, se muestra un ejemplo de la región de interés (ROI) delimitado por los cinco puntos de referencia sobre la huella dactilar del ratón.

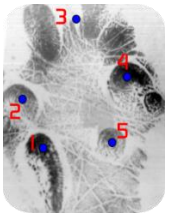

Figura 2 Muestra la ROI formado por los 5 puntos de referencia sobre la imagen de la huella dactilar del ratón.

La propuesta para el reconocimiento de la huella dactilar del ratón es conforme al diagrama de flujo de la figura 3, donde se realiza: el pre-procesamiento, la segmentación, la extracción de características y la clasificación, de acuerdo a la ROI.

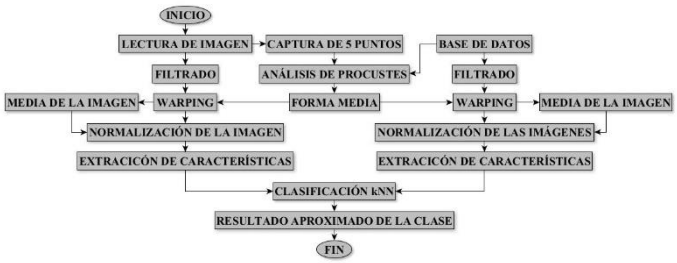

Figura 3. Diagrama de flujo para obtener el reconocimiento de la huella dactilar del ratón.

El código que se empleó para el Warping fue tomado de [4]. Para la clasificación de la huella se empleó el kNN mencionado en las secciones anteriores definido por las ecuaciones 9 a 12, la implementación de esta técnica fue mediante el siguiente diagrama de flujo, figura 4.

Figura 4. Diagrama de flujo para el clasificador kNN.

7. RESULTADOS.

Se realizaron las implementaciones de los diagramas de flujo de las figuras 3 y 4, donde fueron programadas en Matlab. El resultado de la imagen segmentada para su clasificación se visualiza en la figura 5 b), para la imagen original de la huella del ratón del grupo dos y hembra tres (G2 H3), figura 5 a).

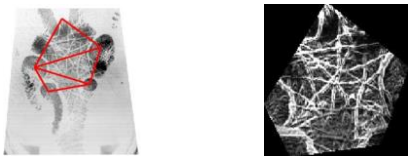

a) Imagen G2 H3. b) Imagen segmentada.

Figura 5. Imagen original y segementada de la huella del ratón.

En las siguientes figuras, se presentan las gráficas de los resultados de las métricas de la matriz de co-ocurrencia para el análisis de textura de la ROI a 0° y la distancia de un pixel. Estos valores fueron utilizados como vectores de características para la clasificación de cada animal, donde se observan variaciones considerables entre cada animal para su identificación.

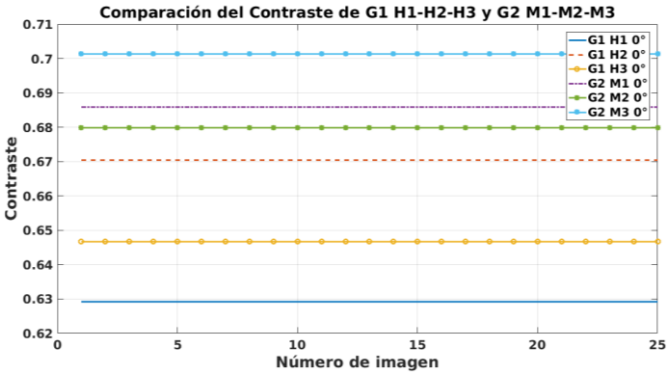

Figura 6. Gráficas de la métrica de Contraste.

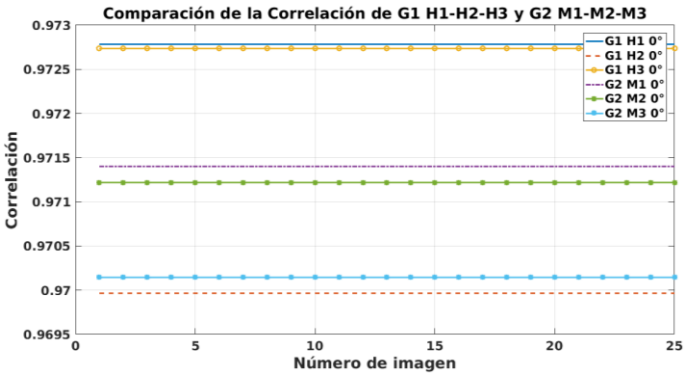

Figura 7. Gráficas de la métrica de Correlación.

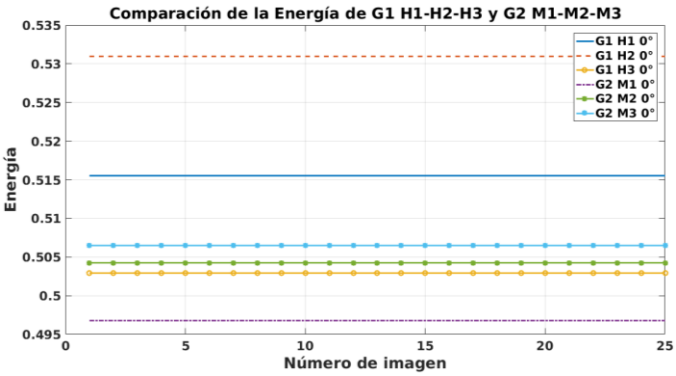

Figura 8. Gráficas de la métrica de Energía.

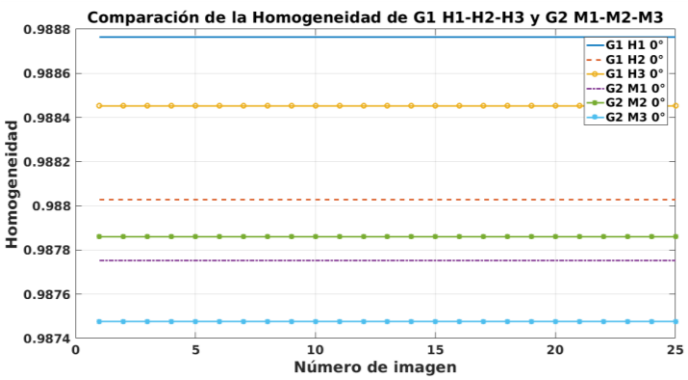

Figura 9. Gráficas de la métrica de Homogeneidad.

A continuación se presentan los resultados obtenidos de la metodología planteada anteriormente, donde se observan las ventanas de los resultados que muestra la interfaz de Matlab en la figura 10, donde se presentan las dos puntuaciones más cercanas para la clase reconocida en este caso para la hembra 1 (H1) es de 893 y la hembra 2 (H2) es de 513 y como resultado decide que es H1 coincidiendo con la imagen de prueba etiquetada como 02-06-08 (1) G1H1, donde el valor de k es de 11 para el clasificador kNN. En la tabla 1 se muestra la matriz de confusión del conjunto de imágenes de prueba para los 6 ratones, obteniendo un porcentaje de 70% de imágenes efectivamente reconocidas.

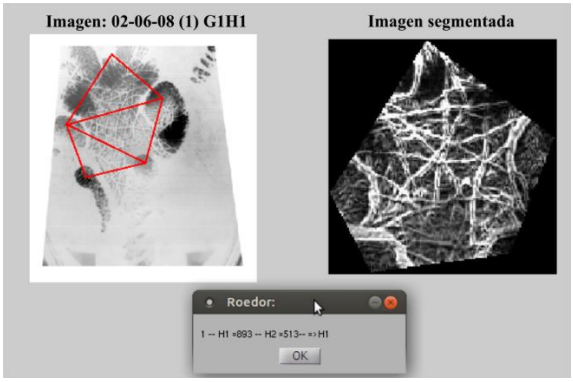

Figura 10. Muestra el resultado de programa en Matlab para el reconocimiento de la huella dactilar.

Tabla 1 Matriz de confusión.

	PREDICCIÓN						
REAL	**H1**	**H2**	**H3**	**M1**	**M2**	**M3**	**EFECTIVIDAD**
H1	23	5	3	2	1	1	65.71%
H2	1	26	1	3	2	2	74.29%
H3	1	1	24	4	2	3	68.57%
M1	2	4	1	23	3	2	65.71%
M2	3	2	1	2	26	1	74.29%
M3	1	3	1	1	2	25	75.76%
PROMEDIO							70.72%

8. CONCLUSIONES

Los resultados obtenidos hasta el momento aún no son los adecuados, pero en este proyecto se presenta una forma de resolver el problema logrando el 70% de efectividad en el reconocimiento de estas huellas. Los factores que contribuyen estos resultados son: el pre-procesamiento de las imágenes de las huellas dactilares donde se tiene que realizar una ecualización robusta y un enriquecimiento de la imagen, ya que no es suficiente con solo suavizar la imagen. Se está trabajando en un algoritmo más robusto basado en redes neuronales para la clasificación del ratón, además del empleo de filtros Gabor para obtener un patrón de reconocimiento. Finalmente, una más mejora es incrementar el vector de características, el cual se está realizando un concentrado de imágenes para la obtención de un conjunto más amplio de características del roedor.

9. REFERENCIAS.

[1] Adniery B., “Utilización de la textura como rasgo en la clasificación de células en imágenes de microscopía”. Universidad Central Marta Abreu de Las Villas, Facultad de Ingeniería Eléctrica, Centro de Estudios de Electrónica y Tecnologías de la Información, 2013.

[2] Celia C. Cintas, C. Delrieux, G. S. Bianchi, and N. Defossé, “Procesamiento inteligente de imágenes: Posicionamiento de vértebras mediante landmarks y redes neuronales,” in XIV Workshop de Investigadores en Ciencias de la Computación, 2012.

[3] Fix, E., Hodges Jr, J. L. Discriminatory analysis-nonparametric discrimination: consistency properties. California Univ Berkeley, 1951.

[4] G. Tzimiropoulos, M. Pantic, “Optimization problems for fast AAM fitting in-the-wild”, ICCV 2013.

[5] Hechenbichler, K., Schliep, K. “Weighted k-nearest-neighbor techniques and ordinal classification”, 2004.

[6] Juan S., Roberto R. “Procesamiento y análisis digital de imágenes”. Alfaomega, 2012, 105-107

[7] Kenneth Nilsson and Thorsteinn Rögnvaldsson, Jens Cameron, Christina Jacobson, “Biometric Identification of Mice”, The 18th International Conference on Pattern Recognition (ICPR06), IEEE, 2006.

[8] Mohammed Nazir Alli, Serestina Viriri, “Animal Identification Based on Footprint Recognition”, International Conference on Adaptive Science and Technology, IEEE, 25-27 Nov, 2013.