

Aplicaciones veterinarias del procesamiento de imágenes

Mariana del Fresno¹ y Alejandro Clause^{1,2}

¹Universidad Nacional del Centro, Tandil, Argentina

²CNEA-CONICET

{mdelfres, clause}@exa.unicen.edu.ar

Resumen

Se presenta el desarrollo de un algoritmo de procesamiento de imágenes para el soporte de detección de celo vacuno. El método de detección se basa en el análisis del deterioro de pintadas lumbares, mediante la segmentación de fotografías color tomadas a la salida de un tambo. Inicialmente, las regiones de interés son aisladas del resto de la imagen en función de valores de umbral definidos en los espacios de color YUV e YIQ, generando un conjunto de componentes conectadas. Luego, se calcula un conjunto de características para posibilitar una evaluación cuantitativa de los objetos segmentados. Finalmente, la imagen es clasificada mediante una regla de decisión basada en el análisis de las diferencias entre las medidas obtenidas a partir de la imagen y las provenientes de un conjunto de imágenes manualmente segmentadas, de acuerdo a la evaluación de expertos. Este enfoque constituye una valiosa alternativa para la mejora del control de celo, ya que la ardua tarea de observación visual de los animales en el tambo puede ser reemplazada por el análisis automático de imágenes capturadas en ambientes controlados. Los resultados experimentales a partir de las segmentaciones obtenidas con este método resultan altamente satisfactorios, permitiendo una clasificación precisa de las imágenes con un bajo costo computacional.

Palabras clave: Procesamiento de señales, segmentación de imágenes, clasificación.

Abstract

This paper presents the development of an algorithm of image processing which was applied to a decision support tool for estrus detection in cattle. The detection method is based on the analysis of rubbed off lumbar paintings, by means of the segmentation of color pictures taken to cows in a cattle ranch. Firstly, the regions of interest are isolated from the rest of the image based on threshold functions defined in the YUV and YIQ color spaces, producing a set of connected components. Then, a set of features is computed to enable a quantitative evaluation of the segmented objects. Finally, the image is classified by means of a decision rule based on the analysis of the differences between the computed measures and a set of ideally segmented images, according to experts' assessment. This approach constitutes a valuable alternative to improve this process, as it may replace the visual observation by the automatic analysis of pictures taken to cows in controlled environments. Experimental results show that the segmentations obtained with this method are highly satisfactory and they allow a precise classification of the images with low computational complexity.

Keywords: Signal processing, image segmentation, classification.

1. INTRODUCCIÓN

La segmentación es la operación de identificación y separación de objetos significativos contenidos en una imagen. Esta es una etapa sumamente importante en la automatización de procesos de reconocimiento y determina el eventual éxito o fracaso de tareas de más alto nivel como clasificación, análisis y visualización [2].

Se han propuesto diferentes técnicas de segmentación [6, 9]. El umbralado es uno de los métodos más simples y más comúnmente utilizados [10]. Se basa en una clasificación estadística de los niveles de gris de la imagen, suponiendo que todos los puntos con valores de intensidad dentro de un cierto rango corresponden al mismo objeto. Por otro lado, los enfoques basados en bordes buscan la detección de discontinuidades de los niveles de gris que idealmente se asocian a los límites entre diferentes componentes [2]. Otro tipo de enfoques se basa en la determinación de regiones homogéneas dentro de la imagen, por medio de la incorporación de aquellos píxeles que satisfacen cierto criterio de conectividad y similitud [1]. Finalmente, existen varios métodos que combinan dos o más de los enfoques anteriores y que resultan más complejos, como por ejemplo los basados en *snakes* [7] o redes neuronales [9]. Por lo general, la mayoría de estos algoritmos resultan computacionalmente intensivos y por lo tanto poco convenientes para aplicaciones en tiempo real.

Recientemente se ha manifestado un interés creciente por su aplicación a imágenes color, debido a que éstas generalmente aportan mayor contenido de información, facilitando la identificación de objetos [11]. Entre los algoritmos desarrollados, se encuentran algunas técnicas ad hoc que utilizan conocimiento específico sobre la naturaleza de la información de color. Por otro lado, también pueden explorarse extensiones convenientes de las técnicas usadas para imágenes en tonos de gris, aplicando por ejemplo el algoritmo a cada componente del espacio de color (*RGB*, *YIQ*, etc.) para luego combinar los resultados individuales.

El campo de aplicación de la segmentación de imágenes color es sumamente amplio y se han propuesto interesantes usos en diversas áreas. En particular, la detección de celo en bovinos en base a pintadas lumbares constituye un ejemplo práctico de estas aplicaciones. La técnica consiste en pintar una banda de 20 cm de largo por 5 cm de ancho a lo largo de la base de la cola del animal. Durante la monta, la pintura se desgasta y se pierde gradualmente. De esta manera, la ausencia o deterioro de la pintura en la zona lumbar puede ser usada para determinar un estado de celo [8]. La detección se realiza generalmente mediante la observación visual de operadores entrenados ya que no existen dispositivos automáticos para este propósito. Al disponer de una herramienta de segmentación de imágenes color provenientes de las pinturas lumbares en tiempo real, se podrían implementar sistemas automáticos de detección de celo que permitan reducir costos.

En este trabajo se presenta un algoritmo computacionalmente eficiente para segmentación y clasificación de imágenes color. El método ha sido aplicado a la segmentación de pinturas sobre el área lumbar de vacunos, seguida por la extracción y comparación de algunas características de las imágenes a fin de extraer resultados significativos. Esta herramienta provee un sistema automático novedoso para el soporte de decisiones capaz de determinar en tiempo real el estado de celo de los animales, lo que permite mejorar el diagnóstico y obtener mayores ganancias a los productores.

El artículo se organiza de la siguiente manera. En la Sección 2, se discute el algoritmo de segmentación basado en umbralado a partir de transformaciones no lineales de los espacios de color. Las etapas de extracción y clasificación se describen en la Sección 3. En la Sección 4, se analiza detenidamente la performance del método usando diferentes grupos de imágenes. Finalmente, en la Sección 5 se presentan las conclusiones generales del trabajo.

2. SEGMENTACIÓN DE IMÁGENES COLOR

A pesar de la disponibilidad de otras opciones de segmentación, el umbralado se encuentra entre las técnicas más populares para segmentar imágenes debido a su baja complejidad computacional y buena performance. El umbralado frecuentemente provee un enfoque simple y apropiado para la detección de objetos del fondo usando el histograma de la imagen. Si el rango de intensidades se encuentra bien diferenciado, esta tarea puede realizarse efectivamente eligiendo un valor de umbral adecuado en el valle entre las dos modas dominantes. El problema es más complicado cuando las distribuciones se superponen y por lo tanto no es simple determinar el valle [5].

En su forma más simple, cada píxel de una imagen $f(i,j)$ es comparado con un umbral T , y luego es clasificado para obtener una imagen binaria $I(i,j)$ definida como:

$$I(i, j) = \begin{cases} 1 & \text{if } f(i,j) > T \\ 0 & \text{if } f(i,j) \leq T \end{cases} \quad (1)$$

esto es, los píxeles rotulados con 1 corresponden a objetos, mientras que los rotulados con 0 corresponden al fondo.

Si bien el umbralado es una técnica fácil de aplicar a imágenes en tonos de gris, pueden aparecer algunas complicaciones en el caso de imágenes color. El color se representa comúnmente por una tripla de componentes escales rojo, verde y azul (R, G, B) en un espacio ortogonal, o alguna transformación de ellos. Detectar clusters de puntos en este espacio involucra el análisis de picos y valles de tres histogramas diferentes o determinar un umbral apropiado en un histograma tridimensional, el cual puede requerir un alto costo computacional [3]. Por otra parte, el espacio RGB es apropiado para visualizar color, pero no es conveniente para muchas tareas de procesamiento de imágenes a causa de la alta correlación entre sus componentes. Contrariamente, el espacio YIQ tiene en cuenta la mayor sensibilidad humana a los cambios en luminosidad (Y) que en la información sobre el color (I y Q). Estas componentes se encuentran desacopladas, de manera que pueden ser procesadas independientemente. El espacio YUV es una versión levemente diferente del YIQ pero con las mismas ventajas [4].

Aunque el algoritmo desarrollado puede ser aplicado a diferentes áreas con pocas modificaciones, el presente estudio se enfoca en imágenes con zonas artificialmente pintadas de color rojo, amarillo, verde o azul (de acuerdo a los colores utilizados por los veterinarios en los diferentes ciclos de celo) sobre fondos en tonos marrón, negro y blanco (correspondientes a los posibles cueros vacunos). El principal objetivo es separar automáticamente las regiones pintadas del fondo para permitir su evaluación posterior (Figura 1). Inicialmente, las variables de crominancia (u, v en el espacio YUV e i, q en el espacio YIQ) fueron analizadas para todos los colores posibles de pintura y cuero, tratando de encontrar valores de umbral apropiado. Sin embargo, ni YUV ni YIQ poseen un rango de valores que puedan ser usados para discriminar efectivamente entre objetos y fondo. Por esta razón, se estudiaron varias funciones de color de las variables de crominancia a fin de identificar un campo escalar adecuado que permita asegurar una correcta segmentación de la imagen.

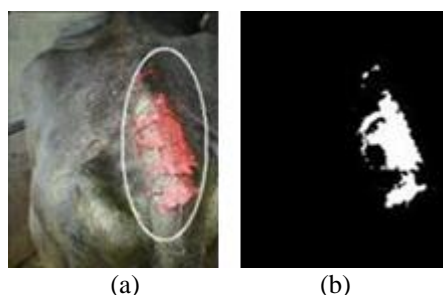


Figura 1. Segmentación de una imagen típica: banda de pintura sobre la base de la cola de un animal (a), objeto de interés segmentado del fondo (b)

A fin de evaluar los resultados de la segmentación de diferentes funciones de color, se generó un conjunto de 1000 imágenes sintéticas semejando escenas libres de error. Este análisis permitió analizar el comportamiento de las funciones que lograron distinguir correctamente los diferentes colores utilizados para las pinturas y los asociados con los distintos cueros de los animales. Como ejemplo, la Figura 2 muestra cuatro histogramas correspondientes a la función $\sqrt{u^2 + v^2}$, mostrando una clara distinción entre los dos grupos.

Luego de haber procesado las imágenes con las distintas funciones propuestas, se eligió un subconjunto de ellas según su performance. Las funciones seleccionadas fueron: $k \max(|u|, |v|)$ y $\sqrt{u^2 + v^2}$, en el espacio YUV , y $k_1 \max(|i|, |q|) + k_2 \min(|i|, |q|)$ y $\sqrt{i^2 + q^2}$ en el espacio YIQ , ya que con ellas se logró segmentar aproximadamente el 97% de las imágenes de prueba, para los cuatro colores de pintura y con un rango de valores bastante amplio. Los valores de k , k_1 y k_2 fueron obtenidos mediante ensayos numéricos, verificando que con $k=11$ para el primer caso, y $k_1=10$, $k_2=2$ para el segundo se logran segmentaciones exitosas con una alta tasa de eficiencia. Este conjunto de funciones fue utilizado en pruebas con imágenes experimentales, como será explicado en la Sección 4.

3. PROCESAMIENTO POST-SEGMENTACIÓN

La imagen binaria obtenida en la etapa de segmentación se procesa mediante una operación de erosión para eliminar los posibles puntos espurios que pueden surgir durante el umbralado [2]. Esta operación morfológica puede reducir levemente el tamaño de los objetos, pero a la vez contribuye a revelar su forma básica, lo cual se requiere en la etapa de clasificación. Luego de este proceso, las componentes conectadas que permanecen son rotuladas a fin de poder determinar las regiones de interés [5]. Entonces, estas regiones son evaluadas mediante sus características geométricas y se las compara contra medidas ideales (Figura 3), como se describe en las siguientes subsecciones.

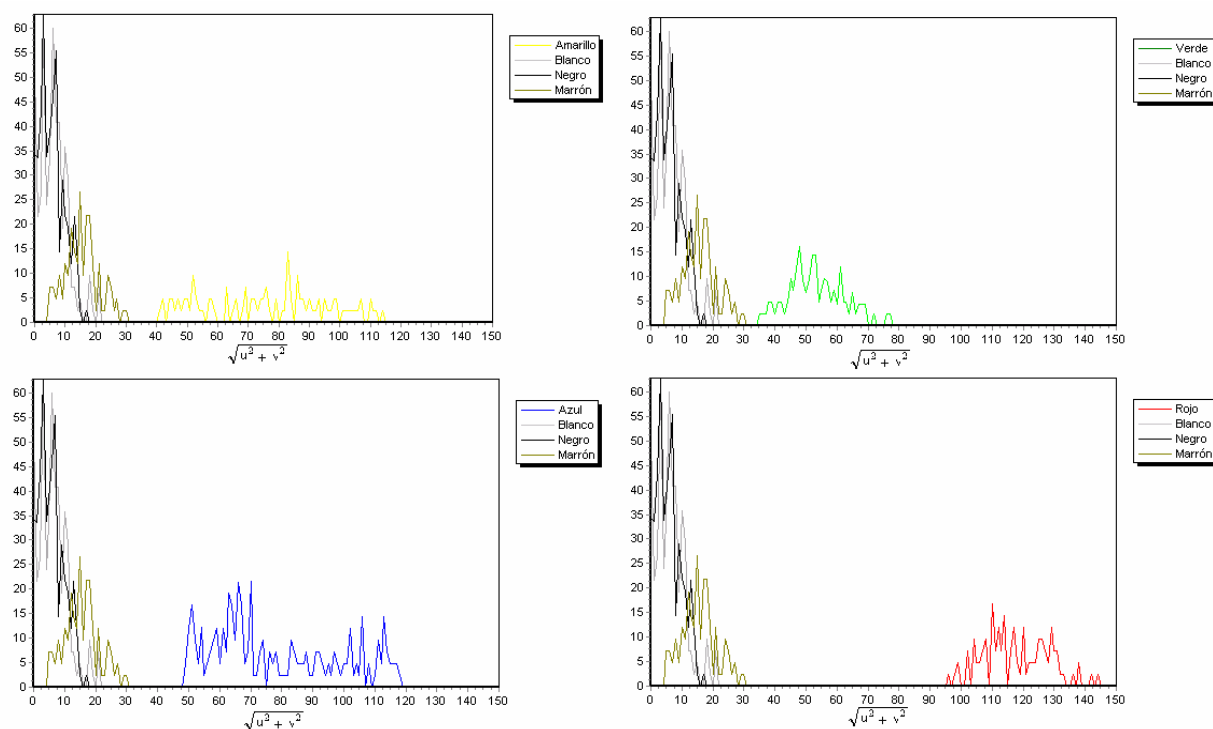


Figura 2. Distribuciones de los valores de $\sqrt{u^2 + v^2}$ para los colores del fondo (negro, blanco y marrón) y los diferentes colores de pinturas: amarillo (a), verde (b), azul (c) y rojo (d)

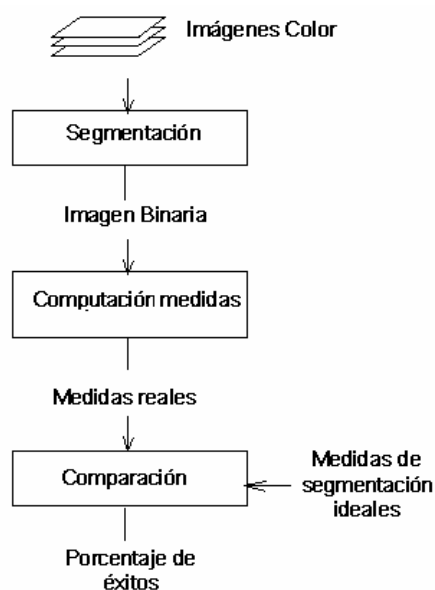


Figura 3. Etapas involucradas en la evaluación de las funciones

3.1 Extracción de características

Las regiones detectadas por el proceso de segmentación son evaluadas según sus características y descriptores de forma. Adquirir mediciones precisas de los objetos es un problema fundamental en análisis de imágenes, ya que tales medidas generalmente brindan información útil a tener en cuenta en la posterior etapa de clasificación [2]. En este caso, los objetos segmentados fueron caracterizados a través de las siguientes métricas:

Área. El área es el momento de orden cero y se calcula como el número de pixels dentro del objeto incluyendo su borde, esto es:

$$A = \sum_x \sum_y I(x, y) \quad (2)$$

Dispersión. Esta métrica indica cuán diseminados se encuentran los pixels del objeto con respecto al centroide. Entonces, para aquellos pixels con $I(x, y) = 1$:

$$D = \sqrt{\sum_x \sum_y (x - \bar{x})^2 + (y - \bar{y})^2} \quad (3)$$

donde el centroide está dado por los momentos de primer orden \bar{x} y \bar{y} :

$$\bar{x} = \frac{\sum_x \sum_y x I(x, y)}{\sum_x \sum_y I(x, y)} \quad \bar{y} = \frac{\sum_x \sum_y y I(x, y)}{\sum_x \sum_y I(x, y)} \quad (4)$$

Longitud del eje mayor. El eje mayor de un objeto se define como la línea más larga que puede dibujarse dentro del objeto. Para calcular esta medida, se calculan las distancias entre cada combinación de pixels (x_i, y_i) y (x_j, y_j) sobre el borde del objeto y se determina el par (x_{M1}, y_{M1}) y (x_{M2}, y_{M2}) con la mayor longitud. De esta manera, la longitud del eje mayor es la distancia en pixels entre estos puntos y representa la longitud del objeto. Se calcula como:

$$L_M = \sqrt{(x_{M2} - x_{M1})^2 + (y_{M2} - y_{M1})^2} \quad (5)$$

Longitud del eje menor. El eje menor se define como la línea más larga que atraviesa al objeto y que puede dibujarse en forma perpendicular al eje mayor. Los puntos extremos del eje menor (x_{m1}, y_{m1}) y (x_{m2}, y_{m2}) se determinan calculando la distancia en píxels entre cada par de puntos del borde (x_i, y_i) y (x_j, y_j) que definen segmentos perpendiculares al eje mayor y determinando el par con la mayor longitud. Así, la longitud del eje menor se obtiene como:

$$L_m = \sqrt{(x_{m2} - x_{m1})^2 + (y_{m2} - y_{m1})^2} \quad (6)$$

3.2 Clasificación por comparación de medidas

En este punto del proceso de evaluación, se ha logrado segmentar uno o más objetos dentro de la imagen de entrada y se han obtenido varias medidas a partir de ellos, de acuerdo a las Ec. (2) a (6). Estas métricas son utilizadas durante la tercera etapa correspondiente a la clasificación como entrada para una regla de decisión que permite determinar si un animal se encuentra en celo.

Con el fin de asistir al proceso de decisión, se pueden usar distintos algoritmos de inteligencia artificial. Sin embargo, en este enfoque se ha implementado una regla sencilla basada en lógica difusa que analiza las diferencias entre las medidas calculadas a partir del conjunto de imágenes de prueba, clasificadas de acuerdo a la evaluación de expertos veterinarios y aquellas obtenidas por el algoritmo para imagen particular (Figura 4). Las medidas obtenidas a partir del primer conjunto fueron usadas como valores de referencia para definir intervalos de confianza para las propiedades geométricas derivadas de la región segmentada (A , D , L_M y L_m). Para determinar un celo positivo se requiere que todas las métricas calculadas a partir de la imagen correspondiente caigan dentro de los respectivos intervalos de confianza. Basado en pruebas experimentales, se ha determinado que pérdidas por debajo del 30% representan casos de no-celo o dudosos, mientras que pérdidas superiores a este porcentaje dan indicio de que el animal está en celo. Por lo tanto, el valor usado para discriminar entre casos de celo positivo y negativo fue definido como $0.3x$, donde x representa cada uno de los descriptores anteriores. El criterio puede ser modificado en el futuro, luego de una retro-información de aplicaciones reales.

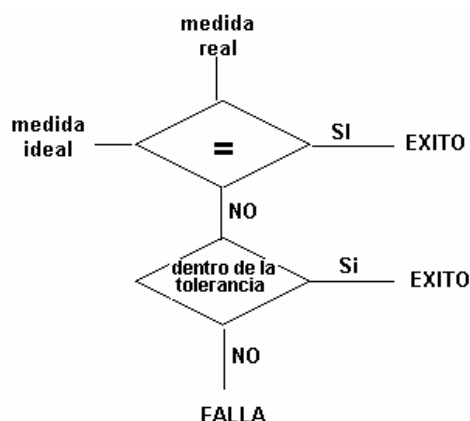


Figura 4. Criterio de éxito

4. VALIDACIÓN EXPERIMENTAL DE FUNCIONES DE UMBRAL

A partir de dos conjuntos de fotografías correspondientes a pinturas sobre cueros vacunos, se llevó a cabo una evaluación integral del método. La primera muestra fue tomada en un ambiente con luz controlada, usando cueros naturales con bandas de pintura de aproximadamente 100 cm^2 .

El segundo conjunto de imágenes fue obtenido a partir de fotografías de animales reales en un tambo (El Choique, zona de Napaleofú), a fin de reproducir lo más posible las condiciones de iluminación que se pueden encontrar en aplicaciones reales (Figura 5). La Tabla 1 muestra los resultados obtenidos, indicando el porcentaje de casos que el algoritmo descripto determinó positivos y que fueron confirmados mediante diagnóstico clínico. La segunda columna muestra el porcentaje de éxito de las funciones de umbral seleccionadas para la primera muestra y la tercera columna corresponde al conjunto obtenido a partir de animales reales.

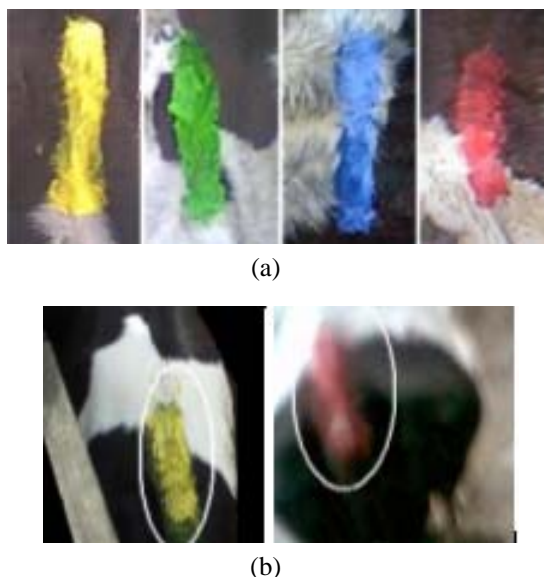


Figura 5. Pintadas de color sobre cueros: en muestra artificial (a), ejemplo de muestras con casos reales (b)

Tabla 1. Resultados de las funciones de umbral de color

función de color	% de éxito con fotografías en ambiente controlado	% de éxito con fotografías in situ
$\sqrt{u^2 + v^2}$	96.28	94.59
$11 \max(u , v)$	96.85	97.29
$\sqrt{i^2 + q^2}$	97.71	97.29
$10 \max(i , q) + 2 \min(i , q)$	97.14	94.59

La Figura 6(a) muestra la performance de las funciones $11 \max(|u|, |v|)$ y $\sqrt{i^2 + q^2}$, que lograron los mayores porcentajes de éxito en la clasificación al ser aplicadas a las imágenes del primer conjunto. Como se puede ver, hay un amplio rango de valores de umbral para cada función que permiten obtener buenos resultados de clasificación. Para valores de umbral más pequeños, el algoritmo no alcanza a identificar partes de las pintadas, mientras que en el caso de valores mayores el fondo no se distingue plenamente de las bandas de pintura. La altura de la curva, que corresponde al mayor porcentaje de éxito, indica el poder de segmentación de la función de umbral utilizada, y su ancho determina su robustez (es decir, cuanto más amplio es el rango, menos sensible serán los resultados a las fluctuaciones de color). La Figura 6(b) presenta el comportamiento de las mismas funciones para la segunda muestra de imágenes. En este caso, los resultados parecen menos robustos que en el caso anterior. Sin embargo, hay que notar que esto se debe a que el conjunto obtenido a partir de animales reales es menor que en la muestra controlada.

Aunque la observación visual es el método comúnmente usado para determinar el estado de celo, su eficiencia se estima en sólo 50% en la mayoría de los tambos y se estima que entre el 5 y el 30% de las inseminaciones se realizan en vacas que no se encuentran en celo. El uso de asistentes en el proceso de detección puede mejorar esta situación. Por ejemplo, los sistemas comerciales basados en dispositivos sensibles a la presión reportan una precisión de aproximadamente el 95%. El sistema automático basado en el análisis de pinturas presentado en este trabajo puede brindar una alternativa eficiente para la detección de celo, con una precisión cercana al 97%, siendo mucho más económico y accesible a la mayoría de los productores.

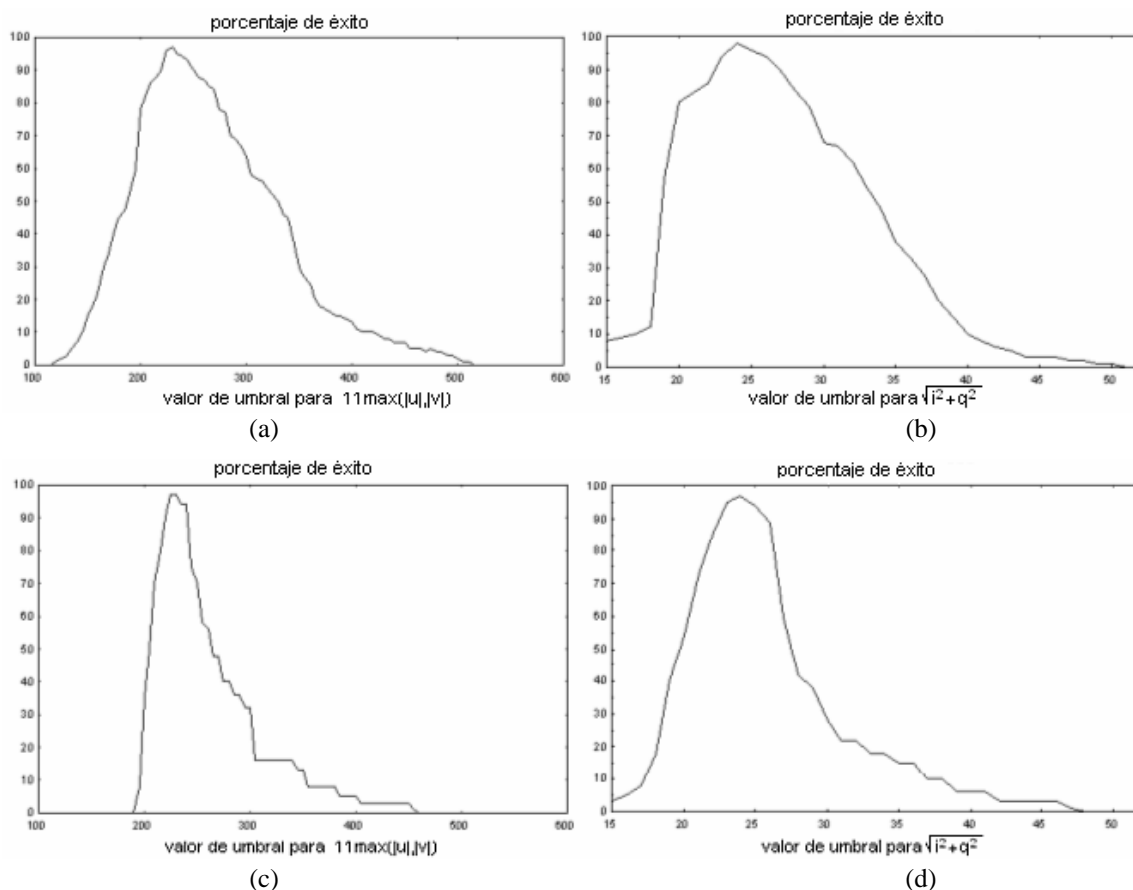


Figura 6. Porcentaje de éxito alcanzado por las funciones $11 \cdot \max(|u|, |v|)$ y $\sqrt{i^2 + q^2}$ para el primer conjunto de imágenes – laboratorio controlado- (a) y para el conjunto de imágenes tomadas in-situ – tambos-

5. CONCLUSIÓN

Se presentó un método de umbralado para la segmentación automática de imágenes color, basado en transformaciones no-lineales de las componentes de los espacios de color YUV y YIQ . El método es simple, robusto y ha mostrado una excelente performance con baja complejidad computacional. Además, los valores de umbral y los valores de referencia para la clasificación se deben calcular sólo al comienzo de la operación del sistema. La técnica de segmentación no requiere parámetros de entrada para cada imagen, prescindiendo de la interacción con el usuario.

El algoritmo fue utilizado en una herramienta de soporte de decisiones para detección de celo. Esta herramienta constituye una contribución de alto valor tecnológico para mejorar la eficiencia de este procedimiento, ya que aún no se han desarrollado dispositivos automáticos en este dominio de

aplicación. Los resultados de la segmentación fueron caracterizados mediante medidas geométricas, las cuales brindan un conjunto de parámetros válidos para determinar el estado de celo. La técnica fue probada exitosamente contra conjuntos de fotografías tomadas en ambientes de luz controlada y también en tambos ubicados en el campo. Se ha advertido que ciertos efectos como sombras, cambios de iluminación y ruido pueden afectar la efectividad del proceso de segmentación, y serán investigados en el futuro.

REFERENCIAS

- [1] Adams R. and Bischof L., Seeded region growing, *IEEE Trans. Pattern Anal. Machine Intelligence*, 16-6, 641-647, 1994.
- [2] Baxes G., *Digital Image Processing: Principles and Applications*, John Wiley & Sons, 1994.
- [3] Cheng H., Jiang X., Sun Y. and Wang J., Color Image Segmentation: Advances and Prospects. *Pattern Recogn.*, 34, 2259-2281, 2001.
- [4] Gonzalez R. and Woods R., *Digital Image Processing*, Addison-Wesley, 1992.
- [5] Haralick R. and Shapiro L., *Computer and Robot Vision*, Addison-Wesley Publishing Company, 1992.
- [6] Lucchese L. and Mitra S., Color Image Segmentation: A State-of-the-Art Survey, *Image Processing, Vision, and Pattern Recognition*, The Indian National Science Academy (INSA-A), New Delhi, India, 67-2, 207-221, 2001.
- [7] McInerney T. and Terzopoulos D., T-snakes: Topology adaptive snakes, *Medical Image Analysis*, 4, 73-91, 2000.
- [8] Perry G., *Detection of standing estrus in cattle*, <http://agbiopubs.sdstate.edu/articles/FS921B.pdf>, South Dakota State Univ., 2004.
- [9] Pham D., Xu C. and Prince J., A Survey of Current Methods in Medical Image Segmentation, *Annual Review Biomedical Engineering*, 2, 315-337, 2000.
- [10] Sezgin M. and Sankur B., Survey over image thresholding techniques and quantitative performance evaluation, *Journal of Electronic Imaging*, 13-1, 146-165, 2004.
- [11] Skarbek W. and Koschan A., *Color Image Segmentation: A Survey*, Technischer Bericht, Tech Univ. of Berlin, 94-32, 1994.