

# EVALUACIÓN DE FUNCIONES WAVELET MADRE CON DESCRIPTORES DE TEXTURA ESTADÍSTICOS EN LA CLASIFICACIÓN DEL ACROSOMA DE ESPERMATOZOIDES DE VERRACO

Enrique Alegre (enrique.alegre@unileon.es)  
Maribel González (gonmaribel@yahoo.com)  
Víctor González Castro (victor.gonzalez@unileon.es)  
Tomás Alonso (tomasalonsorodriguez@gmail.com)

Dpto. Ing. Eléctrica y de Sistemas y Automática. Univ. de León

## Resumen

*En este trabajo se ha utilizado una red neuronal de tipo backpropagation para determinar el estado del acrosoma en espermatozoides de verraco. Se ha evaluado cómo afecta a la tasa de acierto de la clasificación el procesado previo de la imagen utilizando diferentes wavelet madre. Se evaluaron cinco familias – o funciones madre – de wavelets diferentes: Daubechies, Coiflets, Symlets, Meyer y Biortogonales y sobre las imágenes obtenidas se obtuvieron descriptores de textura estadísticos de primer y segundo orden. La clasificación se ha realizado con una red neuronal, evaluándose diferentes configuraciones de la red. Los resultados muestran que las tasas de acierto para las distintas familias utilizadas pueden variar hasta en un 7%. Los mejores resultados se obtienen utilizando las familias Biortogonal y Symlets, con tasas de acierto ligeramente superiores al 95%.*

**Palabras clave:** descripción de textura, transformada Wavelet, semen de verraco

## 1. INTRODUCCIÓN

La fuerte demanda de productos derivados del cerdo ha obligado a esta industria a desarrollar sistemas que permitan mejorar su producción. En este contexto resulta fundamental por un lado seleccionar verracos con buenas capacidades reproductivas y, por otro, mejorar las técnicas de fertilización.

De acuerdo con muchos expertos veterinarios, y apoyado por pruebas experimentales, el estado de la membrana que recubre la cabeza del espermatozoide – acrosoma – es muy relevante de cara al éxito o fracaso de la fertilización, porque está directamente relacionada con algunos procesos metabólicos e intercambios con el medio, la reacción

del acrosoma, y con su penetración en el óvulo [9]. Por lo tanto una muestra que presente una proporción alta de espermatozoides con el acrosoma en mal estado – dañado o muerto – hará que ese semen sea inútil para la fertilización. El espermatozoide se divide morfológicamente en cinco clases [13, 1, 14], pero en los estudios de integridad se pueden agrupar en dos: Acrosomas íntegros y acrosomas dañados (ver figura 1). Así pues, el objetivo ha sido clasificar los espermatozoides de una muestra en una de estas dos clases.



Figura 1: Ejemplo de acrosoma íntegro (izquierda) y dañado (derecha).

Los veterinarios suelen realizar esta tarea manualmente, utilizando tinciones que resaltan los acrosomas dañados y microscopios de fluorescencia para reconocerlos. Esto tiene varios problemas, como el alto coste económico y temporal, la necesidad de personal especializado, o el hecho de que depende en gran medida de la subjetividad del observador, lo cual no es deseable en actividades de control de calidad.

Sería de gran ayuda contar con sistemas que realizaran este trabajo automáticamente. Existen algunos trabajos en esta línea que utilizan visión artificial pero no hay, al menos hasta donde conocemos, aplicaciones comerciales que puedan estimar la calidad del semen en función del estado de la membrana.

En este tipo de trabajos, la segmentación es una etapa crucial. González-Castro et al. [6, 5] han propuesto un método para segmentar cabezas de esperma de verraco utilizando la transformada Watershed, técnicas de umbralización, y técnicas para detectar y descartar las imágenes mal segmentadas.

Petkov y sus colaboradores [12] así como Alegre et al. [2] propusieron métodos de clasificación mediante descriptores de textura, que utilizan *Learning Vector Quantization* para realizar la clasificación. Sanchez et al. propusieron métodos de clasificación basado en la distribución intracelular de las cabezas [16, 15].

La clasificación de la integridad del acrosoma en el dominio del espacio ha sido analizada por Suarez y sus colaboradores [17]. En su trabajo se utilizan descriptores basados en la matriz de co-ocurrencia de la textura, y se clasifican mediante Análisis Discriminante Lineal (LDA) para diferenciar acrosomas íntegros y dañados. Recientemente, siguiendo esta misma línea, Alegre y sus colaboradores compararon el rendimiento de clasificadores supervisados – kNN y redes neuronales – y no supervisados – LDA y QDA – utilizando varios descriptores de textura para caracterizar las imágenes [3]. En este trabajo se obtuvo una tasa de error global del 93.37% al describir la imagen con matrices de co-ocurrencia y clasificando estos patrones con LDA.

El análisis de la textura en el dominio de la frecuencia ha sido utilizado en diferentes campos [10, 11, 18]. La transformada Wavelet ha demostrado ser una herramienta poderosa para realizar dicho análisis. Gonzalez et al ya la han utilizado aplicada al análisis seminal [4], con resultados bastante satisfactorios. Sin embargo, no está claro cuál de los tipos de transformada wavelet permite reducir la tasa de error en el reconocimiento del estado del acrosoma. El objetivo de este trabajo es, por un lado, determinar qué familia de wavelets es más apropiada en el análisis de la textura del acrosoma del espermatozoide para discriminarlo en íntegro o dañado. Nuestra propuesta es combinar la transformada wavelet con descriptores estadísticos de primer y segundo orden, y clasificarlos utilizando redes neuronales. De esta manera se ha completado el segundo objetivo del trabajo: Determinar la configuración de la red que minimice la tasa de error de la clasificación.

## 2. MATERIALES Y MÉTODOS

### 2.1. PREROCESAMIENTO Y SEGMENTACIÓN

Las imágenes fueron tomadas usando una cámara AVT Oscar F-810C y un microscopio epifluorescente Nikon E-600. Tanto la adquisición como la segmentación se realizaron según proponen González-Castro et al. [6]. En primer lugar se realiza una umbralización de la imagen del espermatozoide, con diferentes valores si no se satisfacen unas determinadas condiciones de superficie y excentricidad de la región segmentada. Posteriormente, siguiendo el mismo criterio, se usa la transformada Watershed con las imágenes mal segmentadas. Finalmente, las imágenes que sigan sin satisfacer las condiciones anteriores son automáticamente descartadas, de modo que no se usan en el análisis final por estar mal segmentada la región de interés (la cabeza del espermatozoide). El resultado de la segmentación es una sola cabeza – con sus valores originales de nivel de gris – por imagen, con el fondo negro. Al final del proceso quedaron 207 cabezas íntegras (en adelante de clase 0 ó negativa) y 156 cabezas con acrosoma dañado (clase 1 ó positiva).

### 2.2. EXTRACCIÓN DE CARACTERÍSTICAS

La información contenida en las frecuencias espaciales se usa frecuentemente en el análisis de texturas. En este trabajo se ha utilizado la Transformada Wavelet Discreta (DWT en sus siglas en inglés). Cuando ésta se aplica a una imagen se obtiene una matriz de coeficientes. Existen cuatro clases de coeficientes: aproximaciones y detalles horizontales, verticales, y diagonales. Los primeros contienen la mayor parte de la energía de la imagen, mientras que los detalles tomarán valores cercanos a cero. La figura 2 muestra un ejemplo de los coeficientes extraídos de una imagen. Una vez calculados los coeficientes, se extraen descriptores estadísticos de primer y de segundo orden de ellos.

Sea  $x$  una variable aleatoria que representa los niveles de gris de una imagen  $f(x)$ ; el histograma de dicha imagen ( $P(x)$ ) se define como:

$$P(x) = \frac{\text{Número de pixels con nivel de gris } x}{\text{número total de pixels}}$$

Considerando los histogramas extraídos de las matrices de los coeficientes en las tres primeras escalas de la transformada (ver figura 3), se extraen de cada uno de ellos la media y la desviación típica, formando patrones de 24 características.




Figura 2: Ejemplo de coeficientes extraídos de la imagen de un espermatozoide.

LL3	HL3	HL2	HL1
LH3	HH3		
LH2		HH2	
LH1		HH1	

Figura 3: Nombres de las subbandas de una transformada wavelet de 3 niveles.

1. Media:

$$m = \sum_{i=0}^{N-1} iP(x_i)(i) \quad (1)$$

2. Desviación típica:

$$\sigma = \sqrt{\frac{1}{N^2} \sum_{i=0}^{N-1} (P(x_i) - m)^2} \quad (2)$$

En el caso de los estadísticos de segundo orden se toma la imagen original y las subbandas de la primera escala de la transformada (LL1, LH1, HL1 y HH1). Para cada una de ellas se calcula la matriz de coocurrencia y se extraen los descriptores propuestos por Haralick Energía (E), Homogeneidad (H), Contraste (Cont) y Correlación (Corr) [8, 7]. Cada descriptor del patrón es la media de los descriptores extraídos de las matrices en cuatro orientaciones ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  y  $135^\circ$ ), de modo que sean invariantes a la rotación. La distancia utilizada en el cálculo es 1, porque distancias mayores no han mejorado los resultados. Las características extraídas son las siguientes:

$$E = \sum_i \sum_j C(i, j)^2 \quad (3)$$

$$H = \sum_i \sum_j \frac{C(i, j)}{1 + (i - j)^2} \quad (4)$$

$$Cont = \sum_i \sum_j |i - j|^2 C(i, j) \quad (5)$$

$$Corr = \sum_i \sum_j \frac{(i - u_i)(j - u_j)C(i, j)}{\sigma_i \sigma_j} \quad (6)$$

Donde  $u_i$ ,  $u_j$  son los valores medios de  $C_x$  y  $C_y$  respectivamente, y  $\sigma_i$  y  $\sigma_j$  son sus desviaciones típicas.

Así, cada patrón está formado por 20 características.

### 2.3. CLASIFICACIÓN

El conjunto de imágenes se dividió en tres grupos: Uno se utilizó para entrenar la Red Neuronal que es de tipo backpropagation; el segundo se utilizó como conjunto de validación y el tercero se utilizó para el test. Los tamaños de estos conjuntos se escogieron aleatoriamente. El proceso de extracción de los conjuntos, el entrenamiento de la red y el test de los elementos se realiza varias veces, con el objetivo de evitar posibles efectos aleatorios en el entrenamiento de la red.

En las matrices de confusión se expresan los aciertos y errores cometidos por el clasificador al evaluar los elementos en el conjunto de test. En ella se representan los verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN) (ver tabla 1). El clasificador se considera mejor cuanto más altos sean los valores de TN y TP, y más bajos los de FP y FN. Utilizando las matrices de confusión se calculan las siguientes medidas para medir el rendimiento de cada método:

- **Precisión: AC.** Porcentaje de imágenes bien clasificadas.

$$AC = \frac{TP}{TP + FP} \quad (7)$$

- **Tasa de verdaderos positivos: TPR (Sensibilidad).** Se trata del porcentaje de imágenes clasificadas como pertenecientes a la clase 1 y que realmente pertenecen a dicha clase.

$$TPR = \frac{TP}{TP + FN} \quad (8)$$

- **Tasa de falsos positivos: FPR.** Porcentaje de imágenes clasificadas como pertenecientes a la clase 1, que en realidad pertenecen a la clase 0.

$$FPR = \frac{FP}{TN + FP} \quad (9)$$

- **Tasa de verdaderos negativos: TNR (Especificidad).** Es el porcentaje de imágenes bien clasificadas como pertenecientes a la clase 0.

$$TNR = \frac{TN}{TN + FP} \quad (10)$$

- **Tasa de falsos negativos (FNR):** Porcentaje de imágenes mal clasificadas como pertenecientes a la clase 0.

$$FNR = \frac{FN}{TP + FP} \quad (11)$$

		DETECTADO	
		Bien	Mal
REAL	Bien	TP	FN
	Mal	FP	TN

Cuadro 1: Matriz de confusión.

## 2.4. EXPERIMENTOS

En estos experimentos se ha utilizado el conjunto que resulta del proceso de segmentación (sección 2.1).

Se realizaron 15 tests con diferentes configuraciones de la red neuronal, para determinar cuál proporciona mejores resultados. Las funciones de transferencia de las neuronas de la capa oculta y de salida de la red que se han utilizado son tangente hiperbólica (*tansig*), lineal (*purelin*) y sigmoideal (*logsig*). El porcentaje de elementos utilizados para el entrenamiento y para test varía entre el 50 y el 70 %, mientras que para validación y test varía entre el 15 y el 25 %. Utilizar menos elementos para el entrenamiento puede ocasionar que la red no converja, por lo que la tasa de error aumentaría. Utilizar ms elementos ocasionara que el nmero de elementos para la validacin y test fuese demasiado escaso como para evaluar el rendimiento de la red. En la tabla 2 se muestra un resumen de los experimentos realizados en la que se indica el número de experimento (E), las neuronas de la capa oculta de la red (N) y los ciclos de entrenamiento (C), las funciones de transferencia de la capa oculta y de salida de la red, y el porcentaje de imágenes utilizadas para el entrenamiento (Tr), validación (V) y test (T).

Se han utilizado cinco familias de Wavelets (Daubechies, Coiflets, Symlets Meyer y Biortogonales) y los dos tipos de descriptores expuestos en la sección 2.2

## 3. RESULTADOS

### 3.1. CLASIFICADOR NEURONAL BASADO EN PROTOTIPOS

Los experimentos 1, 2, 3 y 4 (ver tabla 2) se llevaron a cabo para encontrar el número de neuronas más apropiado en la capa oculta de la red. Las tasas de falsos positivos y negativos son más bajas cuanto menor sea el número de neuronas en la capa oculta. Las mejores tasas de acierto – así como las métricas MSE y Regresión – se han obtenido con 1 ó 2 neuronas en la capa oculta. Con un número alto de neuronas se obtuvieron valores aceptables para el conjunto de entrenamiento, pero malos valores con los conjuntos de test y validación. Reducir el número de neuronas causó que estas métricas fuesen similares para los tres grupos, y se mantuvieran en unos límites aceptables.

Esto se puede observar en la tabla 3, donde la mejora es significativa especialmente en el caso de los descriptores de primer orden, donde la tasa de acierto mejora en casi un 6 %. Esta tabla muestra las métricas extraídas de la matriz de confusión para diferentes neuronas en la capa oculta de la red. Estos valores se obtuvieron promediando los resultados de las clasificaciones realizadas con los descriptores calculados usando cada una de las familias Wavelet que se han examinado.

Los mejores resultados se obtienen cuando se utilizan funciones de transferencia *purelin-purelin* y *tansig-purelin* en las capas intermedia y oculta, con tasas de acierto de 93.10 % y 91.31 % utilizando descriptores basados en la matriz de coocurrencia.

Los experimentos 4, 14 y 15 se realizaron para determinar cómo afecta la división de los elementos en conjuntos en el rendimiento del clasificador. Como se puede ver en la tabla 4 el aprendizaje y la generalización son más sencillos para el clasificador cuando se utilizan los descriptores extraídos de la matriz de coocurrencia. Observando los resultados correspondientes a los descriptores estadísticos de primer orden se puede apreciar claramente que la división óptima de de los elementos es de 60 % para el entrenamiento, 20 % para la validación y 20 % para el test. En cuanto a los descriptores extraídos de la matriz de coocurrencia, el mejor resultado se obtiene con una división del 70 %, 15 % y 15 % respectivamente. Sin embargo, la diferencia con la configuración 60 % - 20 % - 20 % es tan baja que

Exp.	N	C	Transferencia oculta	salida	Tr (%)	V (%)	T (%)
1	20	50	tansig	purelin	60	20	20
2	10	50	tansig	purelin	60	20	20
3	5	50	tansig	purelin	60	20	20
4	2	50	tansig	purelin	60	20	20
5	1	50	tansig	purelin	60	20	20
6	2	50	logsig	logsig	60	20	20
7	2	50	logsig	tansig	60	20	20
8	2	50	logsig	purelin	60	20	20
9	2	50	tansig	logsig	60	20	20
10	2	50	tansig	tansig	60	20	20
11	2	50	purelin	logsig	60	20	20
12	2	50	purelin	tansig	60	20	20
13	2	50	purelin	purelin	60	20	20
14	2	50	tansig	purelin	70	15	15
15	2	50	tansig	purelin	50	25	25

Cuadro 2: Resumen de los parámetros de cada experimento.

Neuronas	Mean-Std (%)					GLCM (%)				
	TPR	FPR	TNR	FNR	AC	TPR	FPR	TNR	FNR	AC
1	89.49	14.05	85.64	10.18	<b>88.89</b>	92.64	9.62	90.13	7.16	<b>91.46</b>
2	89.10	14.14	85.54	10.61	87.71	92.51	9.91	89.81	7.35	91.29
5	88.20	15.39	84.30	11.60	87.01	92.29	9.95	89.81	7.57	91.14
10	86.41	17.26	82.51	13.41	86.04	92.18	10.06	89.74	7.62	91.01
20	84.20	20.92	78.80	15.58	83.26	91.49	10.54	89.19	8.33	90.39

Cuadro 3: Precisión (en %) en función del número de neuronas en la capa oculta de la red.

	Experimento 4	Experimento 14	Experimento 15
Entrenamiento	50 %	60 %	70 %
Validación	25 %	20 %	15 %
Test	25 %	20 %	15 %
Precisión Media-Std	85.61 %	<b>87.71 %</b>	86.85 %
Precisión GLCM	90.93 %	91.29 %	<b>91.59 %</b>

Cuadro 4: Precisión (en %) según la división de los grupos.

esta configuración se considera la óptima.

### 3.2. COMPARACIÓN DE LAS FAMILIAS DE WAVELETS

El rendimiento medio de todas las familias Wavelet produjo los mejores resultados cuando se usaron entre 1 y 10 neuronas en la capa oculta. La tasa de acierto mínima fue 91.01 % utilizando la familia Symlets y descriptores GLCM, la división de grupos mencionada anteriormente, las funciones de transferencia tansig-purelim, y 50 ciclos de entrenamiento. Sin embargo, la familia Biortogonal ha proporcionado los mejores resultados.

El análisis de las distintas familias determinó que la mejor es Rbio5.5, que proporcionó una tasa de acierto del 94.72 % cuando se combinó con descriptores estadísticos de primer orden, utilizando

2 neuronas en la capa oculta de la red neuronal. La familia Rbio3.1 también ha demostrado ser más eficiente en la clasificación de imágenes con el primer descriptor (tasa de acierto de 87 %), con 5 y 10 neuronas en la capa oculta de la red neuronal.

Las familias Rbio2.8, Sym3 y Sym6 en combinación con los descriptores GLCM obtienen tasas de acierto de entre 93 % y 94.5 %. El mejor resultado se obtuvo aplicando la función madre Rbio2.8, con una tasa de acierto de 94.44 %, usando una neurona en la capa oculta (ver tabla 5).

En general, los resultados muestran que la familia Rbio5.5 proporciona un mejor rendimiento. Además al usar esta función madre, los descriptores estadísticos de primer orden presentan robustez a los cambios en el número de neuronas en la capa oculta.

Exp.	Neuronas	Funciones		Media-Std		GLCM	
		input	output	Familia	Precisión(%)	Familia	Precisión(%)
1	20	Tansig	purelin	Db29	87.50	Coif3	92.70
2	10	Tansig	purelin	Rbio3.1	90.34	Sym3	93.12
3	5	Tansig	purelin	Rbio3.1	92.84	Rbio2.8	<b>94.09</b>
4	2	Tansig	purelin	Rbio5.5	<b>94.72</b>	Sym6	<b>94.09</b>
5	1	Tansig	purelin	Bior2.8	93.88	Rbio2.8	94.44

Cuadro 5: Tasas de acierto de las redes neuronales utilizando diferentes familias Wavelet.




Figura 4: Análisis ROC de los clasificadores usando las diferentes familias Wavelet.

En cuanto a las familias Biortogonal y Symlets, los resultados han sido cercanos al 95 % con tan sólo dos neuronas en la capa oculta. Por otro lado, las Coiflets y Daubechies proporcionan mayores tasas de éxito cuanto mayor sea el número de neuronas en la capa oculta, aunque los resultados son relativamente bajos (aproximadamente 90 % de aciertos).

Las curvas ROC (*Receiver Operating Characteristic*) se utilizan para analizar el rendimiento del clasificador en muchos problemas de clasificación debido a que en ocasiones el clasificador que proporciona el menor error no es siempre el mejor. En este caso el análisis ROC se ha utilizado para comparar el rendimiento de las diferentes familias Wavelet utilizando clasificadores neuronales con 1, 2, 5, 10 y 20 neuronas en la capa oculta.

De acuerdo con los resultados obtenidos con los dos tipos de descriptores utilizados, todos los clasificadores se comportan bien, porque tienen una alta TPR y una baja FPR. Los descriptores obtenidos usando las wavelet Biortogonal y Symlets han sido ligeramente mejores, como se puede comprobar en la figura 4.

## 4. CONCLUSIONES

En este artículo se ha utilizado un sistema de visión artificial para evaluar la calidad del semen

de verraco a partir del análisis de la textura del acrosoma de los espermatozoides. Se han utilizado descriptores estadísticos de primer orden – media y desviación típica del histograma – y de segundo orden – extraídos de la matriz de coocurrencia de la textura –. Para la clasificación se han utilizado redes neuronales.

La familia de transformadas wavelet se ha ido variando, así como la configuración de las redes, con el objetivo de encontrar tanto el descriptor como la configuración de la red óptimas. Los resultados han mostrado que se comportan mejor las redes con menos neuronas en la capa oculta, y entrenadas con el 60 % de los elementos, usando el 20 % para validación y los elementos restantes para test.

Los mejores resultados se obtuvieron con las Wavelets Biortogonales y las Symlets en combinación con los descriptores extraídos de la matriz de coocurrencia, con tasas de acierto de aproximadamente el 95 %. La mejor familia ha sido Rbio5.5, obteniendo un 94.72 % de tasa de aciertos.

Los resultados muestran que el uso de ciertos tipos de familias de Wavelet y la selección apropiada de los parámetros de diseño del clasificador permiten utilizar un sistema automático de clasificación muy útil para este problema. Este sistema puede resultar de una gran ayuda en la evaluación de la calidad del semen de verraco en términos del reconocimiento de la integridad de los acrosomas.

## Agradecimientos

Este trabajo está parcialmente financiado por el proyecto de investigación DPI2009-08424 del Ministerio de Educación.

Damos las gracias a CENTROTEC por facilitarnos las muestras de semen y su colaboración en la toma de imágenes.

## Referencias

- [1] A. P. Aguas and P. Pinto da Silva. The acrosomal membrane of boar sperm: a golgi-derived membrane poor in glycoconjugates. *Journal of Cell Biology*, 100(2):528–534, February 1985.

- [2] E. Alegre, M. Biehl, N. Petkov, and L. Sánchez. Automatic classification of the acrosome status of boar spermatozoa using digital image processing and lvq. *Computers in Biology and Medicine*, 38(4):461–468, 2008.
- [3] Enrique Alegre, Victor Gonzalez-Castro, Sir Suarez, and Manuel Castejon. Comparison of supervised and unsupervised methods to classify boar acrosomes using texture descriptors. In *Proc. Int. Symp. ELMAR '09*, pages 65–70, 2009.
- [4] Maribel Gonzalez, Enrique Alegre, Rocio Alaiz, and Lidia Sanchez. Acrosome integrity classification of boar spermatozoon images using dwt and texture descriptors. In *Computational Vision and Medical Image Processing: VipIMAGE 2007*, October 2007.
- [5] Víctor González, Enrique Alegre, Patricia Morala-Argüello, and Sir Alexci Suárez Castriellón. Segmentación de cabezas de espermatozoides de verraco mediante combinación de umbralización y transformada watershed. In *XXIX Jornadas de automática 2008*, 2008.
- [6] V. González-Castro, Enrique Alegre, P. Morala-Argüello, and S. A. Suarez. A combined and intelligent new segmentation method for boar semen based on thresholding and watershed transform. *International Journal of Imaging*, 2(S09):70–80, 2009.
- [7] R.M. Haralick. Statistical and structural approaches to texture. In *Proceedings of the IEEE*, pages 45–69, 1978.
- [8] R.M. Haralick, K. Shanmugam, and I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610–621, November 1973.
- [9] R. A. Harrison. Sperm plasma membrane characteristics and boar semen fertility. *Journal of Reproduction and Fertility*, 52:195–211, 1997.
- [10] Xin Pan and Qiu-Qi Ruan. Palmprint recognition using gabor-based local invariant features. *Neurocomputing*, 72(7-9):2040 – 2045, 2009. Advances in Machine Learning and Computational Intelligence - 16th European Symposium on Artificial Neural Networks 2008, 16th European Symposium on Artificial Neural Networks 2008.
- [11] Pradeep M. Patil and Jayant V. Kulkarni. Rotation and intensity invariant shoeprint matching using gabor transform with application to forensic science. *Pattern Recognition*, 42(7):1308 – 1317, 2009.
- [12] N. Petkov, E. Alegre, M. Biehl, and L. Sanchez. LVQ acrosome integrity assessment of boar sperm cells. In *CompIMAGES, Computational modelling of objects represented in images*, 2006.
- [13] K. L. Polakoski and R. A. McRorie. Boar acrosin. ii. classification, inhibition, and specificity studies of a proteinase from sperm acrosomes. *The Journal of Biology and Chemistry*, 248(23):8183–8188, December 1973.
- [14] V. G. Pursel, L. A. Johnson, and G. B. Rampacek. Acrosome morphology of boar spermatozoa incubated before cold shock. *Journal of Animal Science*, 34(2):278–283, February 1972.
- [15] L. Sanchez, N. Petkov, and E. Alegre. Classification of boar spermatozoid head images using a model intracellular density distribution. In M. Lazo and A. Sanfeliu, editors, *Progress in Pattern Recognition, Image Analysis and Applications: Proc. 10th Iberoamerican Congress on Pattern Recognition, CIARP 2005, Lecture Notes in Computer Science*, volume 3773, pages 154–160. Springer-Verlag Berlin Heidelberg, 2005.
- [16] L. Sanchez, N. Petkov, and E. Alegre. Statistical approach to boar semen head classification based on intracellular intensity distribution. In A. Gagalowicz and W. Philips, editors, *Proc. Int. Conf. on Computer Analysis of Images and Patterns, CAIP 2005, Lecture Notes in Computer Science*, volume 3691, pages 88–95. Springer-Verlag Berlin Heidelberg, 2005.
- [17] S. Suárez, E. Alegre, M. Castejón, and L. Sánchez. Use of statistic texture descriptors to classify boar sperm images applying discriminant analysis. In *Computational Vision and Medical Image Processing: VipIMAGE 2007*, pages 197–201, 2007.
- [18] Defeng Wang, Lin Shi, and Pheng Ann Heng. Automatic detection of breast cancers in mammograms using structured support vector machines. *Neurocomputing*, 72(13-15):3296 – 3302, 2009. Hybrid Learning Machines (HAIS 2007) / Recent Developments in Natural Computation (ICNC 2007).