

Utilización de técnicas de Inteligencia Artificial en la clasificación de canales bovinas¹

J. Díez†, F. Goyache†, J. Alonso*, J.J. del Coz* J. R. Quevedo*,
S. López*, J. Ranilla*, O. Luaces* A., Bahamonde*

*Centro de Inteligencia Artificial
Universidad de Oviedo en Gijón
Parque Científico Tecnológico de Gijón
Cabueñes S/N. 33203 – Gijón
<http://www.aic.uniovi.es>

†CENSYRA-SERIDA
C/ Camino de los Claveles 604
33208 – Gijón
felixgg@princast.es

Resumen: *En esta comunicación se presenta una aplicación de técnicas de Inteligencia Artificial en la industria alimentaria. Se ha desarrollado una metodología de representación de la conformación de canales bovinas, sintetizándose el conocimiento de los expertos mediante herramientas de Aprendizaje Automático. Los resultados obtenidos demuestran la viabilidad de utilizar clasificadores automáticos, que son capaces de realizar su tarea de manera eficaz con una reducción importante del número de atributos inicial. Este trabajo abre un amplio abanico de posibilidades de aplicación del Aprendizaje Automático en la industria de la alimentación.*

Palabras clave: Aprendizaje Automático, representación de conocimiento, filtrado de atributos, conformación, canales bovinas

1 Introducción

La clasificación de canales bovinas por su conformación es una actividad de gran importancia económica. La conformación de las canales se considera un buen predictor de la cantidad de carne [Vallejo et al., 1991] y, en buena medida, condiciona el precio que

¹ Este trabajo ha sido financiado parcialmente mediante los proyectos 1FD97-1633 (CICYT-FEDER) y PB98-1556 (Programa Sectorial de Promoción General del Conocimiento de la Dirección de la Dirección General de Enseñanza Superior e Investigación Científica).

recibe el productor. Por otra parte, la nota de conformación obtenida por una canal condiciona su inclusión o no en un Programa de Carne de Calidad. En cualquier caso, los Reglamentos CEE 390/81, CEE 1208/81, CEE 2930/81 y CEE 1026/91 hacen obligatoria la clasificación de la conformación de las canales bovina en todo el territorio de la Unión Europea mediante la aplicación del llamado sistema SEUROP.

A pesar de las estrictas normas que rigen su aplicación, el sistema SEUROP está diseñado para ser aplicado a un amplísimo espectro de canales bovinas, desde las producidas por animales de 300 Kg. de peso vivo, sin importar el sexo, edad o condiciones de producción del animal. Este hecho provoca que las reglas que definen el sistema oficial de clasificación de canales sean muy generales y que estén descritas de una forma vaga. Cada una de las clases de conformación correspondientes a cada una de las letras SEUROP depende de los perfiles apreciables en la canal y del desarrollo muscular de cada una de las regiones de la misma. De hecho la descripción de los desarrollos musculares va desde *excepcionales* a *pobres* y los perfiles desde *extremadamente* convexos a *muy* cóncavos. En estas condiciones, no sorprende que los intentos de obtener un sistema objetivo de clasificación automática para canales bovinas usando como datos de entrada los pesos y medidas lineales de la canal no hayan tenido repercusión más allá del ámbito académico [De Boer et al, 1974]. En consecuencia, el uso de sistemas no inteligentes para estos fines no ha experimentado gran desarrollo [Cross et al, 1983][Colomer-Rocher, 1992].

Por estas razones, la clasificación de canales se realiza casi exclusivamente por expertos humanos cuyos conocimientos adquieren un gran valor. Sin embargo, la utilización de un sistema automático que realice una clasificación de canales de forma objetiva parece clara: la necesidad de contar con la presencia de un experto en cada matadero (o en un grupo de ellos) supone un considerable aumento de los costes, el entrenamiento de los expertos es difícil y caro, y la repetibilidad de los resultados no es alta, lo que reduce la confianza de los operadores del mercado de la carne.

En cualquier caso, la clasificación de canales es un problema que puede ser aprendido, y el diseño de un sistema automático de clasificación de la conformación de las canales bovinas puede ser una herramienta útil para clasificadores y operadores comerciales, reduciendo costes de formación y perfeccionamiento de expertos, permitiendo una clasificación diferida y resultando un instrumento de apoyo a las decisiones. El objetivo de la presente comunicación es probar las posibilidades de aplicación de las técnicas de Aprendizaje Automático en la clasificación de la conformación de las canales bovinas y testar las posibilidades de desarrollo de una herramienta informática que utilice el mínimo número de atributos para obtener clasificaciones de canales de forma que, sin provocar un aumento significativo del error de clasificación respecto de los expertos humanos, pueda ser utilizada en un entorno industrial.

2 Representación de las canales bovinas

Abordar el problema propuesto supuso la realización de un gran esfuerzo para la representación computacional de la conformación de las canales bovinas. Para conseguir nuestros objetivos contamos con la colaboración de tres expertos clasificadores de EASA, empresa encargada del control del producto amparado por el Programa de Carne de Calidad “Carne de Asturias Calidad Controlada”. Los expertos de EASA expresaron su convencimiento de que las medidas tradicionales de la canal [De Boer et al, 1974] no podían representar adecuadamente su conformación. Consideraban de especial importancia en sus decisiones atributos como el grado de convexidad de algunos perfiles o el desarrollo muscular de algunas regiones de la canal, como el lomo, o la relación existente entre diferentes medidas de la canal. Se concluyó que 28 atributos, incluyendo el peso de la canal y el índice de compacidad (calculado como la relación entre el peso y la longitud de la canal) [Yeates, 1967] podían tener importancia en las decisiones de clasificación.

En la medida en que esta cantidad de atributos no puede ser obtenida en las salas de sacrificio, se desarrolló una aplicación informática (basada en la experiencia obtenida para la clasificación de la conformación de animales vivos [Goyache et al, 2000] para calcularlos a partir de tres imágenes digitales, obtenidas por los expertos de EASA de cada canal clasificada. Cada imagen corresponde a una posición (externa, interna y lateral -ver *Figura 1*-) y está tomada en presencia de una referencia métrica de 25 cm de longitud. Las imágenes se procesaron para marcar sobre ellas 21 puntos y 5 perfiles (*Figura 1*) para calcular los valores de los 28 atributos. La distancia en píxeles entre los puntos marcados, respecto de la referencia métrica, permite el cálculo directo de longitudes y volúmenes. La obtención de la curvatura de un perfil [Díez et al, 2001] es, en cambio, un proceso más complejo. En la *Figura 2* puede verse que el arco de la curva que define el perfil (b) se representa como una variable real de la función f referida a los ejes de coordenadas que tienen como origen la parte inferior del perfil (c). Realizando esta traslación, se puede entonces calcular la curvatura [Álvarez de León, 2000] del perfil por medio de la ecuación (1).

$$curvatura(x) = \frac{f''(x)}{(1 + (f'(x))^2)^{3/2}} \quad (1)$$

Dado que no se tiene disponible la fórmula explícita de la curva, se deben calcular las derivadas aproximadas utilizando los valores de la función en cada punto utilizado para definir el perfil. Finalmente, para calcular la convexidad de toda la curva en el intervalo $[0, a]$ (véase *Figura 2* (c)), se calcula la media de la curvatura puntual de una

secuencia de puntos del intervalo $[0, a]$ que divide dicho intervalo en un número de sub-intervalos de igual longitud (el mismo número de subintervalos en todos los casos).

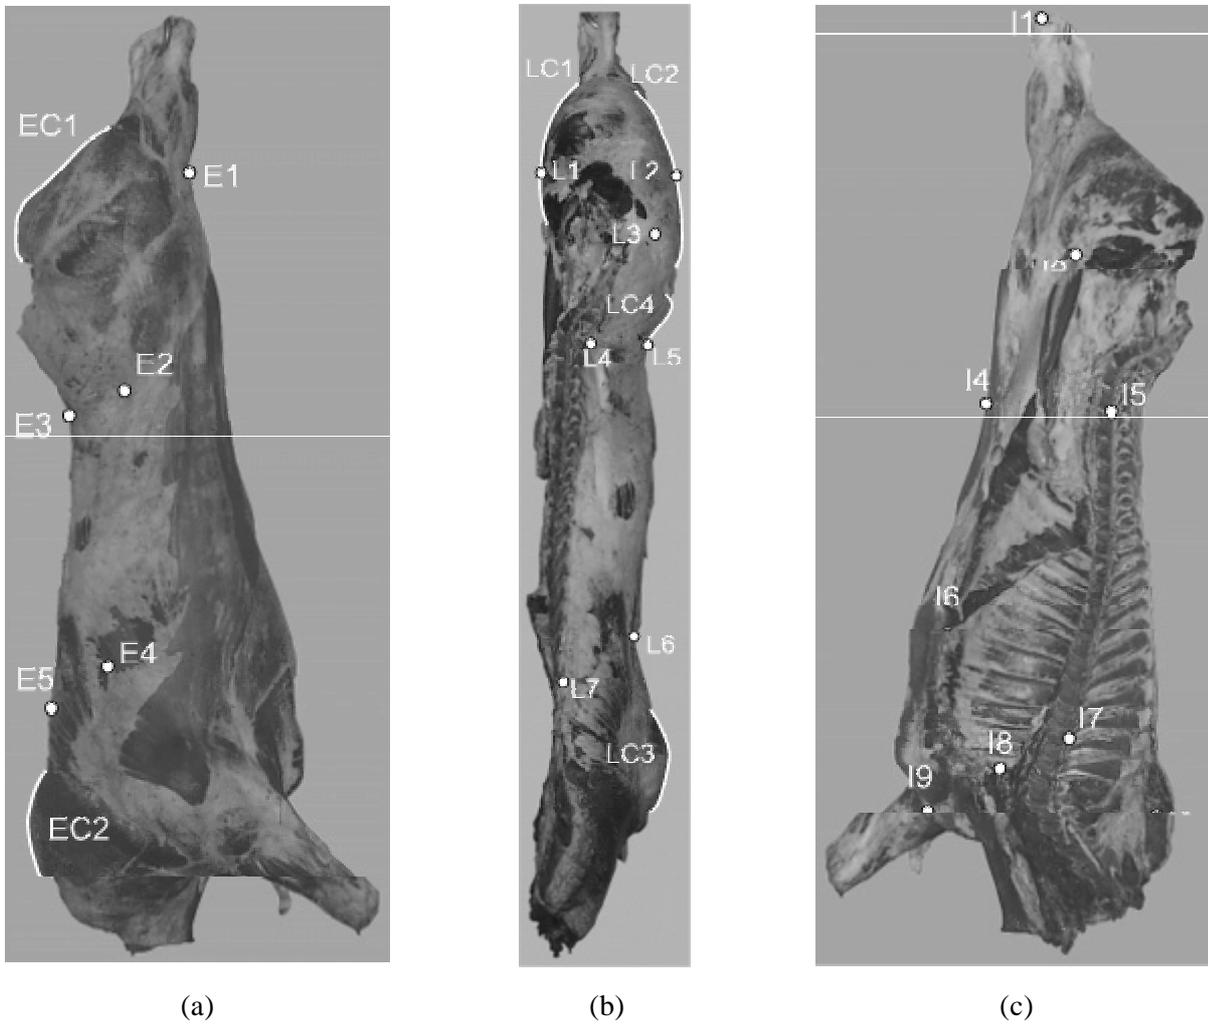


Figura 1. Cada canal ha sido fotografiada en tres posiciones: externa (a), lateral (b) e interna (c).

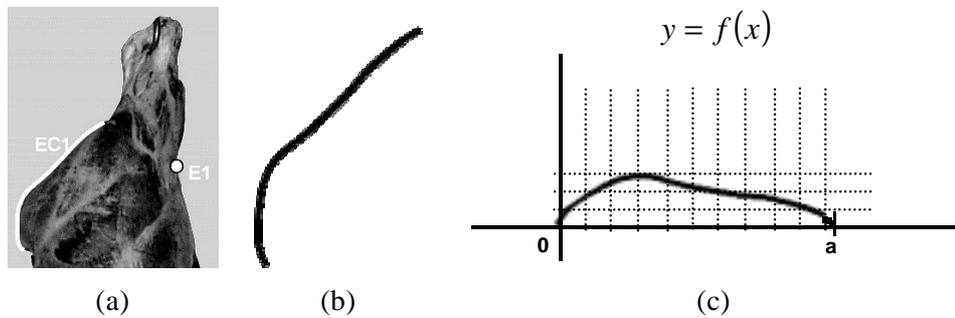


Figura 2. Un perfil de la canal (a), el arco de la curva que lo define (b) y la función que representa la convexidad del perfil (c).

3 El proceso de aprendizaje

3.1 Conjunto de entrenamiento inicial

Tras conseguir una forma precisa de representar el conocimiento adquirido de las canales bovinas se obtuvo un conjunto de entrenamiento que sería analizado, posteriormente, mediante algoritmos de aprendizaje automático. Se clasificaron individualmente y se fotografiaron 104 canales bovinas. Concretamente, el primer experto clasificó 84 canales, el segundo 79 y el tercero 80. La clasificación se realizó aplicando las normas del sistema SEUROP. Para mejorar la precisión de la clasificación se admitió añadir a la letra de clasificación los signos + o - [Kempster, 1986]. Cada clase de conformación se puntuó numéricamente de 1 (P) a 6 (S). Los signos + y - se consideraron como +0.25 o -0.25 puntos de conformación respectivamente, sobre la puntuación de la clase correspondiente. Se considera que este sistema de puntuación representa adecuadamente el comportamiento de los clasificadores en la medida en que no suelen existir dudas en cuanto a la clase de la canal, aunque sí en cuanto a su grado ($\pm 0,25$).

En total se dispuso de 243 clasificaciones diferentes que se consideraron ejemplos independientes en el conjunto de entrenamiento, que constituye una muestra representativa de la distribución real de sexos, pesos y clases de conformación existentes en el mercado asturiano de la carne.

Finalmente se crearon dos conjuntos de entrenamiento: uno con todos los atributos (28) y otro eliminando el índice de compacidad (27 atributos). Se decidió eliminar este índice puesto que, aunque es un buen indicador de la conformación de la canal [Vallejo et al., 1991], en el cálculo del mismo interviene el peso de la canal (los clasificadores humanos deberían tomar sus decisiones sin tener en cuenta el peso).

Debido a la naturaleza del problema, se han utilizado algoritmos de aprendizaje capaces de concluir categorías continuas: CUBIST [Cubist, 2000] , M5' [Quinlan, 1993] [Wang y Witten, 1997] , SAFE (System to Acquire Functions from Examples) [Quevedo, 2000] [Quevedo y Bahamonde, 1999] , BETS (Best Examples in Training Sets) [Del Coz, 2000] [Del Coz et al, 1999] [Luaces et al, 1999] [Bahamonde et al, 1997] y LC3 (Learning to Calculate Continuous Clases) [Gonzalez, 2001] . Todos estos sistemas generan reglas de regresión que permiten obtener un valor numérico de las categorías.

Para realizar las pruebas se han llevado a cabo *validaciones cruzadas* (dividiendo el conjunto de entrenamiento en 10 particiones y efectuando 5 repeticiones). Para garantizar las mismas condiciones de ejecución para todos los sistemas, se ha utilizado la librería MLC++ [Kohavi et al, 1994] usando siempre la misma semilla (2032, teléfono del

laboratorio donde se encuentra el servidor en el que se llevaron a cabo los experimentos) para la generación de números aleatorios. Además, todos los experimentos se han realizado en la misma máquina. Para medir la calidad del aprendizaje en la clasificación de las canales se calcula el error absoluto medio de cada sistema en la validación cruzada.

Los resultados obtenidos aplicando los algoritmos de aprendizaje a los conjuntos de entrenamiento de partida pueden verse en la *Tabla I*. La última columna representa el error absoluto medio obtenido utilizando regresión lineal. Es importante destacar que la diferencia media absoluta de los tres expertos de EASA respecto a la media de la SEURO es 0,41 para el primero de los expertos, 0,39 para el segundo y 0,41 para el tercero. El error que se comete prediciendo siempre la media de las calificaciones es 0,74 (valor calculado en las mismas condiciones que los sistemas).

Tabla I. Error absoluto medio generado por los distintos sistemas sobre los conjuntos de partida.

ATRIBUTOS	SAFE	BETS	LC3	CUBIST	M5'	LINEAL
28	0,4300	0,4728	0,4326	0,4360	0,4331	0,4548
27	0,4341	0,4605	0,4328	0,4371	0,4334	0,4503

De estos resultados se desprende que la clasificación de las canales de bovino puede realizarse mediante técnicas de Aprendizaje Automático manteniendo una precisión similar a la de los expertos. Sin embargo, el número de atributos que intervienen en el aprendizaje es demasiado elevado para proceder a la aplicación del proceso en entorno industriales, puesto que se precisa mucho tiempo para procesar las imágenes de las canales. Por esta razón, se hace necesario realizar un estudio de la relevancia de los atributos para determinar si es posible la reducción en número de los mismos sin que el error se vea sustancialmente incrementado.

3.2 Reducción del número de atributos

Inicialmente se tiene un conjunto con 28 atributos y otro con 27. Para buscar una reducción efectiva del número de atributos hay que tener en cuenta que la exploración exhaustiva del espacio de búsqueda con el fin de encontrar la combinación de atributos con mejor relación entre el error cometido y el número de atributos se hace impracticable. Por tanto, se hace necesaria la utilización de técnicas que acoten de una manera coherente el espacio de búsqueda.

Para realizar esta tarea se ha utilizado una combinación de varias herramientas. La primera de ellas es BETS [Del Coz, 2000]. Este sistema de aprendizaje efectúa un estudio de la relevancia de los atributos que puede usarse para establecer una ordenación de

los mismos. BETS genera todas las reglas posibles del tipo: $Clase \leftarrow (atributo = valor)$ y mide la calidad de las mismas utilizando el nivel de impureza [Ranilla et al, 1998]. La calidad de estas reglas indicará cuánto influye este atributo en la predicción de la clase. Combinando estos resultados se obtiene una ordenación de los atributos en función de su relevancia.

Con la ordenación de los atributos según su relevancia, se ha logrado distanciar los atributos más relevantes de los atributos irrelevantes. Es el momento de eliminar los peores atributos, para lo que se utiliza una segunda herramienta denominada FA [Quevedo et al, 2001]. Esta herramienta comienza eliminando el atributo menos relevante y comprobando la bondad del conjunto resultante. Para ello se realiza una validación cruzada aplicando el método del vecino más próximo (el número de vecinos a utilizar se calcula en función del número de ejemplos). El proceso se repite eliminando, uno a uno, todos los atributos excepto el más relevante. El corte de atributos adoptado como solución será aquel que menor error genere. Si los errores obtenidos son siempre mayores que el error obtenido con el conjunto de partida, no se elimina ningún atributo.

Una variante de esta técnica es la de admitir un cierto incremento en el error cuando se reduce el número de atributos (en [Quevedo et al, 2001], esta variante se denomina *filtrado agresivo*). El incremento de error admitido es un porcentaje del error obtenido con el conjunto de partida. Dicho porcentaje puede ser modificado, lo que permite variar la agresividad del filtrado.

La combinación de ambos métodos, en primer lugar la obtención de una ordenación basada en la relevancia de los atributos y posteriormente la eliminación de los atributos menos relevantes, hizo posible la obtención de los conjuntos de entrenamiento que se utilizaron como entrada de los algoritmos de aprendizaje.

Tabla II. Error de los distintos sistemas para los problemas generados tras la reducción de atributos partiendo de 28 y de 27 atributos (sin índice de compacidad).

ATRIBUTOS	SAFE	BETS	Lc3	CUBIST	M5'	LINEAL
28	0,4300	0,4728	0,4326	0,4360	0,4331	0,4548
15	0,4413	0,4255	0,4551	0,4328	0,4009	0,4370
4	0,5137	0,4524	0,4360	0,4541	0,4907	0,6179
27	0,4341	0,4605	0,4328	0,4371	0,4334	0,4503
14	0,4362	0,4567	0,4420	0,4345	0,4212	0,4396
5	0,4486	0,4115	0,4251	0,4487	0,4507	0,5615

La Tabla II muestra el error obtenido por los sistemas en sus diversas ejecuciones con distinto número de atributos.

Las pruebas utilizando los 28 atributos (o 27, si se elimina el índice de compacidad) indicaron que, efectivamente, estamos ante un problema del cual puede extraerse información suficiente para realizar una tarea de aprendizaje buena. En la *Tabla II* puede verse cómo evoluciona el error de los diferentes sistemas ante la reducción de atributos. La tendencia general es el mantenimiento de las cotas de error en valores similares, lo que demuestra que aun reduciendo drásticamente el número de atributos, sigue siendo posible realizar la clasificación automática de canales. En la última fila de la tabla aparece la combinación con la mejor relación entre error cometido y número de atributos necesario. En este caso, el conjunto de entrenamiento sólo tiene 5 atributos que se pueden obtener marcando, únicamente, 4 puntos y 3 perfiles sobre dos fotografías (una de las fotografías se hace innecesaria). Esta importante reducción en el número de atributos manteniendo el error cometido en valores comparables con los de los expertos, haría posible el desarrollo de un sistema de clasificación automática de canales bovinas para uso industrial.

4 Conclusiones y trabajo futuro

La clasificación de las canales se considera generalmente una actividad basada en la experiencia humana. La no linealidad de la clasificación hace difícil reproducir el comportamiento de los expertos humanos usando herramientas tradicionales. No obstante, el aprendizaje automático muestra un funcionamiento aceptable incluso con la reducción del número de atributos disponibles para obtener una clasificación precisa (la precisión alcanzada en las clasificaciones es comparable a la ofrecida por los expertos). El número de atributos necesarios para la clasificación de las canales hace posible fomentar el desarrollo de metodologías útiles en entornos industriales con el fin de obtener resultados precisos. Observando los resultados mostrados en la sección anterior, únicamente 4 puntos, 3 perfiles y 2 fotografías por canal son necesarias para garantizar una desviación en la clasificación similar a la de los expertos. Estos resultados permitirían plantear el desarrollo de procedimientos que evitaran la necesidad de procesado de las imágenes por operadores humanos. En cualquier caso, aunque fuera necesaria la presencia de un operador humano para procesar las imágenes digitales de las canales, el tiempo empleado en todo el proceso no supera los 10 segundos. Para alcanzar un comportamiento similar usando regresión lineal simple sería necesario un costoso esfuerzo adicional.

En la actualidad, la calidad de los productos alimenticios se evalúa frecuentemente mediante metodologías subjetivas aplicadas por expertos humanos. La presente comunicación abre un campo de posibilidades de aplicación de las técnicas de Aprendizaje Automático a la categorización de la calidad alimenticia en cuanto a su percepción sensorial [Goyache et al, 2001].

Referencias

- [Álvarez de León, 2000] Álvarez de León, L.: Comunicación personal. Universidad de Las Palmas de Gran Canaria, 2000.
- [Bahamonde et al, 1997] Bahamonde, A., de la Cal, E., Ranilla, J., Alonso, J.: Self-organizing symbolic learned rules. Lecture Notes in Computer Science, LNCS N° 1240, 536-545. Springer-Verlag. Berlin, 1997.
- [Colomer-Rocher, 1992] Colomer-Rocher, F: El carácter conformación en los bovinos y sus determinantes biológicos. Actas de Jornadas sobre tecnología de valoración de canales y carnes y defensa de la calidad de los productos ganaderos. Feria Internacional Ganadera Quinto Centenario. Zafra, Badajoz, España, Mayo, 1992.
- [Cross et al, 1983] Cross, H.R., Gilliland, D.A., Durland, P.R. and Seildman, S. (1983). Beef carcass evaluation by use of a video image analysis system. *J Anim Sci*, 57: 908-917.
- [Cubist, 2000] Release 1.09, <http://www.rulequest.com/cubist-info.html>
- [De Boer et al, 1974] De Boer H., Dumont B.L., Pomeroy R.W., Weniger J.H. 1974. Manual on E.A.A.P. reference methods for the assessment of carcass characteristics in cattle. *Livest. Prod. Sci.*, 1, 151-164.
- [Del Coz et al, 1999] Del Coz, J. J., Luaces, O., Quevedo, J.R., Alonso, J., Ranilla, J., Bahamonde, A.: Self-Organizing Cases to Find Paradigms. Lecture Notes in Computer Sciences, Springer-Verlag, Vol. 1606, 527-536, 1999.
- [Del Coz, 2000] Del Coz, J.J.: BETS. Sistema de aprendizaje basado en la selección de ejemplos paradigmáticos. Tesis Doctoral dirigida por A. Bahamonde. Universidad de Oviedo. 2000.
- [Díez et al, 2001] Díez, J., Alonso, J., López, S., Bahamonde, A., Goyache, F.: Una aplicación informática para la representación informática de la conformación de canales Bovinas. Información Técnica Económica Agraria (ITEA), Vol. Extra, nº 22, Tomo II, pp. 550-552, 2001.
- [Domingos, 1996] Domingos, P.: Unifying instance-based and rule-based induction. *Machine Learning*, 24, 141-168, 1996.
- [Gonzalez, 2001] Gonzalez, F.: LC3: Learning to Calculate Continuous Classes. Technical Report, Centro de Inteligencia Artificial, Universidad de Oviedo en Gijón, 2001.
- [Goyache et al, 2000] Goyache, F., del Coz, J.J., Quevedo, J.R., López, S., Alonso, J., Ranilla, J., Luaces, O., Alvarez, I., Bahamonde, A. (2000): Using artificial intelligence to design and implement a morphological assessment system in beef cattle. Enviado para publicación en *Animal Science*.

- [Goyache et al, 2001] Goyache, F., Bahamonde, A., Alonso, J., López, S, del Coz, J.J., Quevedo, J.R., Ranilla, J., Luaces, O., Alvarez, I., Royo, L.J., Díez, J.: Usefulness of Artificial Intelligence techniques to assess subjective quality of products in food industry. Enviado para publicación en Trends in Food Science and Technology (2001).
- [Kempster, 1986] Kempster, A.J. 1986. Estimation of the carcass composition of different cattle breeds and crosses from conformation assessments adjusted for fatness. J Agric sci Camb, 106: 239-254.
- [Kohavi et al, 1994] Kohavi, R. and John, G. and Long, R. y Manley, D.: MLC++: A machine learning library in C++. Proceedings of the Sixth International Conference on Tools with Artificial Intelligence. IEEE Computer Society Press, 740-743, 1994.
- [Luaces et al, 1999] Luaces, O., del Coz, J. J., Quevedo, J.R., Alonso, J., Ranilla, J. Bahamonde, A: Autonomous Clustering for Machine Learning. Lecture Notes in Computer Sciences, LNCS No. 1606, pp. 497-506, Springer-Verlag, Berlín 1999.
- [Quevedo y Bahamonde, 1999] Quevedo, J. R., & Bahamonde, A.: Aprendizaje de Funciones Usando Inducción sobre Clasificaciones Discretas. Proceedings CAEPIA'99 VIII Conferencia de la Asociación Española para la Inteligencia Artificial, Vol. I, 64-71. Murcia, Spain, 16-19 November 1999.
- [Quevedo, 2000] Quevedo, J.R.: SAFE. Tesis Doctoral dirigida por A. Bahamonde. Universidad de Oviedo. 2000
- [Quevedo et al, 2001] Quevedo, J. R., Del Coz, J. J. y Díez, J.: Filtrando atributos para mejorar el aprendizaje automático. Informe Técnico, Centro de Inteligencia Artificial, Universidad de Oviedo Gijón, 2001.
- [Quinlan, 1993] Quinlan, J. R.: *C4.5: Programs for Machine Learning*. San Mateo. Morgan Kaufmann 1993.
- [Ranilla et al, 1998] Ranilla, J., Mones, R., y Bahamonde, A.: El Nivel de Impureza de una regla de clasificación aprendida a partir de ejemplos. *Revista Iberoamericana de Inteligencia Artificial*, 4, 4-11, 1998.
- [Vallejo et al., 1991] Vallejo, M., Alonso, L., Revuelta, J.R., Cima, M., & Cañón, J. Características de las canales de razas bovinas asturianas. I. Bases cuantitativas de la valoración subjetiva. *Archivos de Zootecnia*, 40: 335-357, (1991).
- [Wang y Witten, 1997] Wang Y., y Witten I.H.: Inducing of Model Trees for Predicting Continuous Classes. *Proceedings of European Conference on Machine Learning*. Prague, Czech Republic, 128-137 1997.
- [Yeates, 1967] Yeates, N.T.M. 1967. Avances en Zootecnia. ACRIBIA, Zaragoza, pp. 202