

ANÁLISIS DE LA INFLUENCIA DE LOS PERFILES EN LA CALIFICACIÓN SEUROP DE LAS CANALES BOVINAS MEDIANTE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

F. Goyache^{a*}, P. Alberti^b, I. Fernández^a, G. Ripoll^b, F. Lahoz^b, J.L. Olleta^c, B. Panea^c, C. Sañudo^c, A. Bahamonde^d y J. Díez^d

^aSERIDA-Somío, C/ Camino de los Claveles 604, 33203 Gijón; ^bCITA de Aragón, Apdo. 727. 50080 Zaragoza; ^cDepartamento de Producción Animal. Universidad de Zaragoza, 50013 Zaragoza; ^dCentro de Inteligencia Artificial. Universidad de Oviedo en Gijón, Campus de Viesques, 33271 Gijón *e-mail: fgoyache@serida.org

INTRODUCCIÓN

Las reglas de calificación SEUROP de la conformación de las canales bovinas son de utilización obligatoria en todo el territorio de la Unión Europea. Análisis previos (DÍEZ et al., 2003) han demostrado que los criterios para su aplicación práctica no son los mismos para todo el rango de pesos en el que está prevista su utilización y que el comportamiento para la clasificación de canales bovina es altamente no lineal. Por otra parte, la necesidad de evaluar los perfiles de la canal provoca que la clasificación no pueda realizarse de forma totalmente objetiva, lo que puede afectar a la confianza de los mercados e impide la normalización de los productos. Las técnicas de Aprendizaje Automático (AA) permiten analizar el comportamiento de los calificadores ante la canal (GOYACHE et al., 2001). Por otra parte, DÍEZ et al. (2004) consideran que la no linealidad de la calificación de productos alimentarios se debe tanto a la heterogeneidad de los productos a evaluar como a las diferencias entre evaluadores, por lo que la congruencia de los criterios de calificación debe realizarse en conjuntos homogéneos diseñados para reducir las diferencias entre evaluaciones. El presente trabajo pretende obtener información sobre la influencia de los perfiles de las canales bovinas en la calificación de la conformación de canales bovinas SEUROP. Este trabajo ha sido financiado mediante los proyectos INIA-RTA01-106 y MEC-FEDER-TIC2001-3579.

MATERIAL Y MÉTODOS

Se han utilizado 101 canales de añajos de 7 razas bovinas españolas: Asturiana de la Montaña (15), Asturiana de los Valles (16), Avileña-Negra Ibérica (19), Morucha (3), Parda Alpina (3), Pirenaica (38), Retinta (3) y Rubia Gallega (3). El cebo de los animales fue *ad libitum* con paja de cereales y concentrado. La calificación de la conformación SEUROP (\pm) se obtuvo por consenso de dos calificadores expertos. 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 realizaron tres fotografías digitales de cada canal en vistas dorsal, medial y lateral. Esas fotografías se procesaron mediante la aplicación informática descrita en DÍEZ et al. (2003) marcándose en cada canal 21 puntos y 5 perfiles para obtener las siguientes dimensiones y perfiles de cada canal: anchura del muslo, longitud del muslo, longitud de la pierna, longitud de la espalda, anchura de la espalda, altura lateral de la espalda, longitud del lomo, anchura anterior del lomo, anchura posterior del lomo, anchura lateral del lomo en la cadera, anchura lateral del lomo en la cruz,

profundidad del pecho, profundidad del flanco, longitud de la canal, perfil de la pierna, perfil de la espalda, perfil de la tapa, perfil de la cadera, perfil del muslo y perfil del morrillo. Estos 20 atributos, con la adición o no del peso de la canal, se utilizaron para el aprendizaje la nota de conformación.

La linealidad de la nota de conformación en la base de datos se probó mediante la comparación de la regresión lineal con los algoritmos de AA Cubist (2000) y M5' (Quinlan, 1993). El rendimiento de los métodos de aprendizaje se estimó por validación cruzada y los resultados se interpretaron como desviación absoluta media (*mad*) de la función *f* aprendida mediante regresión calculada

como
$$mad = \frac{1}{|TS|} \sum |f(x) - x_{class}| \quad \forall x \in TS$$
, donde *TS* es el conjunto de prueba. La relevancia de los atributos se probó para encontrar el conjunto de aprendizaje con la mejor ratio entre error de predicción y número de atributos utilizados. Para ello se redujo gradualmente el número de atributos mediante la eliminación del menos relevante en cada iteración. Los nuevos conjuntos de aprendizaje se probaron mediante validación cruzada interpretada como *mad*.

RESULTADOS Y DISCUSIÓN

Los análisis preliminares (Tabla 1) mostraron la linealidad de la respuesta al aprendizaje de la nota de conformación, por lo que posteriormente los conjuntos de entrenamiento se probaron exclusivamente mediante regresión lineal. La Figura 1 muestra la variación de la *mad* obtenida con los conjuntos de entrenamiento que incluían o no el peso de la canal cuando el atributo menos relevante era eliminado. Los errores fueron mayores cuando no se consideraba el peso de la canal. Las menores *mad* se obtuvieron con conjuntos de entrenamiento de 5 atributos incluyendo el peso canal (*mad* = 0.289) y con 6 y 5 atributos en los conjuntos que no lo incluían (respectivamente, 0.374 y 0.375). La Tabla 2 describe los 5 atributos utilizados en los 'mejores' conjuntos de entrenamiento. Cuando se incluía el peso de la canal en el conjunto de entrenamiento, éste resultó ser el más relevante mientras que cuando no se consideró el atributo más relevante fue la anchura del muslo. En todo caso no se utilizaron perfiles para el aprendizaje de la nota de conformación, por lo que se apunta la posibilidad de diseñar sistemas objetivos de clasificación para las canales de añojo. Será necesario profundizar en los umbrales que permiten separar canales de diferentes categorías.

Tabla 1: Errores absolutos medios y número de funciones seleccionadas para la realización de predicciones de casos desconocidos de calificación SEUROP de canales bovinas mediante regresión lineal y dos algoritmos de Aprendizaje Automático. Los resultados, computados como desviación absoluta media (*mad*) se han obtenido mediante validación cruzada.

Método	<i>mad</i>	Número medio de funciones utilizadas
Regresión lineal	0,316	1,0
Cubist	0,336	2,6
M5'	0,315	1,0

Figura 1: Desviación absoluta media (*mad*) obtenida mediante el análisis de los conjuntos de entrenamiento que incluían el peso de la canal (círculos) o no (cuadrados) cuando el atributo menos relevante era eliminado del conjunto de entrenamiento.




Tabla 2: Descripción de los atributos utilizados en el aprendizaje de la nota de conformación cuando solo se consideraron 5 atributos en los conjuntos de aprendizaje.

Conjunto de entrenamiento	Lista de atributos	mad
Con peso de la canal	Anchura del muslo, Longitud del muslo, Profundidad del pecho, Longitud de la canal, Peso de la canal	0,289
Sin peso de la canal	Anchura del muslo, Anchura lateral del lomo en la cadera, Anchura lateral del lomo en la cruz, Anchura de la espalda, Profundidad del pecho	0,375

REFERENCIAS BIBLIOGRÁFICAS

- CUBIST (2000): Release 1.09, <http://www.rulequest.com/cubist-info.html>
- DÍEZ, J., BAHAMONDE, A., ALONSO, J., LÓPEZ, S., DEL COZ, J.J., QUEVEDO, J.R., RANILLA, J., LUACES, O., ALVAREZ, I., ROYO, L.J., GOYACHE, F. 2003 Artificial Intelligence techniques point out differences in classification performance between light and standard bovine carcasses. *Meat Science*, 64:249-258.
- DÍEZ, J., BAYÓN, G.F., QUEVEDO, J.R., DEL COZ, J.J., LUACES, O., ALONSO, J., BAHAMONDE, A. 2004 Discovering relevancies in very difficult regression problems: applications to sensory data analysis. *Proceedings of the European Conference on Artificial Intelligence (ECAI '04)*, Valencia, Spain, 22-27 August.
- GOYACHE, F., BAHAMONDE, A. ALONSO, J., LÓPEZ, S., ALONSO, J., DEL COZ J.J., QUEVEDO, J.R., RANILLA, J., LUACES, O., ALVAREZ, I., ROYO, L.J., DÍEZ J. 2001. The usefulness of Artificial Intelligence techniques to assess subjective quality of products in the food industry. *Trend in Food Science & Technology*, 12: 370-381.
- QUINLAN, J. R. (1993): Combining instance-based and model-based learning. En *Proceedings Tenth International Machine Learning Conference*. Amherst, MA: Morgan Kaufmann.