



Inteligencia Artificial. Revista Iberoamericana  
de Inteligencia Artificial

ISSN: 1137-3601

revista@aepia.org

Asociación Española para la Inteligencia  
Artificial  
España

López, Secundino; Goyache, Félix; Quevedo, José Ramón; Alonso, Jaime; Ranilla, José; Luaces,  
Oscar; Bahamonde, Antonio; del Coz, Juan José

Un sistema inteligente para calificar morfológicamente a bovinos de la raza Asturiana de los Valles  
Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial, vol. 4, núm. 10, verano, 2000,  
pp. 5-17

Asociación Española para la Inteligencia Artificial  
Valencia, España

Disponible en: <http://www.redalyc.org/articulo.oa?id=92541001>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal

Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

# Un sistema inteligente para calificar morfológicamente a bovinos de la raza Asturiana de los Valles

Secundino López, Félix Goyache(\*), José Ramón Quevedo, Jaime Alonso, José Ranilla, Oscar Luaces, Antonio Bahamonde y Juan José del Coz

Centro de Inteligencia Artificial. Universidad de Oviedo en Gijón (www.aic.uniovi.es)  
Campus de Viesques. E-33271 Gijón, España

(\*)SERIDA-CENSYRA-Somió, C/ Camino de los Claveles s/n, E-33208 Gijón, España  
e-mail: {secun, quevedo, jalonso, ranilla, oluaces, antonio, juanjo}@aic.uniovi.es;  
(\*felixgg@princast.es

**RESUMEN.** *En el presente artículo se describen técnicas de representación y aprendizaje que permiten realizar de forma automática la calificación morfológica de bóvidos de la raza Asturiana de los Valles. La calificación morfológica es una metodología habitualmente aplicada en los programas de mejora de los animales domésticos. Hasta el momento, esa calificación es realizada por calificadoros humanos expertos sometidos a un entrenamiento específico. Los aspectos subjetivos de la condición humana impiden que se pueda lograr un sistema de calificación absolutamente objetivo. El desarrollo de las técnicas que aquí se exponen, además de ayudar a profundizar en un mejor conocimiento de los problemas de la calificación morfológica, constituye una herramienta muy útil para poder conseguir un sistema de calificación más justo y preciso. Para lograrlo, se ha optado por adaptar sistemas de aprendizaje, alguno de ellos bien conocido, a las peculiaridades que tiene el entorno de la calificación morfológica en el que nos movemos, tratando de aprovechar esas particularidades a nuestro favor.*

**Palabras clave:** Aprendizaje automático, representación del conocimiento, aplicaciones a la ganadería.

## 1. Introducción

En este artículo se van a describir los principios en los que está basado un sistema inteligente diseñado para poder realizar la calificación morfológica del ganado vacuno de aptitud cárnica y que resulta lo suficientemente versátil como para que pueda ser adaptado a cualquier raza bovina productora de carne. Este trabajo ha sido financiado parcialmente por el **Principado de Asturias** mediante el proyecto PRI-AE-AGR-03 y la **CICYT** mediante el proyecto CICYT-FEDER 1FD97-1633. Los autores quieren expresar su agradecimiento a las Asociaciones de Criadores **ASEAVA** (ASociación Española de criadores de la raza Asturiana de los **VALles**) y **ASEAMO** (Asturiana de la **MOntaña**), sin cuya colaboración este trabajo no hubiera podido realizarse.

La calificación morfológica es hoy en día una metodología indispensable para garantizar la mejora ganadera de una forma continuada y sistemática. En el caso de los bóvidos de Asturiana de los Valles, esta calificación morfológica la realizan un conjunto de calificadoros conocedores de la raza. A pesar del entrenamiento exhaustivo de los calificadoros, éstos no se pueden abstraer de aspectos subjetivos, inherentes a nuestra propia condición humana, que unidos al factor tiempo (distintos momentos en que se realizan la calificación de los animales) impiden que las calificaciones obtenidas sean totalmente consistentes.

Existen distintas maneras de realizar una calificación morfológica. En la siguiente sección se describen los fundamentos y objetivos concretos de la metodología

con que ASEAVA está calificando a los aproximadamente 40.000 animales reproductores inscritos en el Libro Genealógico de la raza Asturiana de los Valles. Este sistema constituye una novedad respecto a los métodos tradicionales hasta ahora aplicados en España. Por todo ello, los objetivos que nos planteamos con el sistema informático de calificación fueron, por una parte servir de prototipo para el nuevo método de calificación, y por otro el servir de ayuda para los calificadores expertos en su adaptación al nuevo sistema.

El prototipo informático debía mostrar que es factible la descripción objetiva de un conjunto de características que justifiquen minuciosamente la calidad de los bóvidos como productores de carne o como reproductores. Este aspecto no es trivial ya que las valoraciones tradicionales de los animales suelen adolecer de justificaciones objetivas.

El aspecto de ayuda a los calificadores es también fundamental. El sistema que aquí se describe, facilita el almacenamiento de la información y la recuperación inteligente de la misma. Esto último permite que el sistema sea capaz de sugerir una calificación inducida de las que previamente se han almacenado como muestras paradigmáticas. En otras palabras, parte de la recuperación de información será llevada a cabo por un sistema de aprendizaje automático que sintetizará conocimiento de los datos suministrados. Con esta herramienta será posible entrenar a los expertos y realizar sesiones periódicas de unificación de criterios, sin las cuales el sistema de calificación en su conjunto perdería coherencia.

Dejando aparte el aspecto ganadero que se sale fuera del ámbito de esta revista, las aportaciones de este sistema inteligente de calificación se pueden enmarcar en la representación del conocimiento y en la adquisición utilizando técnicas de Aprendizaje Automático.

En la siguiente sección se presentan a grandes rasgos las características del método de calificación morfológica en la que se basa nuestra aplicación. Distinguiremos dos fases en la calificación, una primera de apreciación o *puntuación* de las características de los animales sin tener en cuenta su condición o estado, y una segunda fase en la que se calcula una *calificación* teniendo en cuenta el tipo de animal de que se trate. A continuación discutimos las dificultades que tiene la representación del conocimiento en este caso y presentamos nuestras soluciones. La parte final describe los resultados de los minuciosos experimentos realizados con nuestro sistema.

## 2. La calificación morfológica continua en la raza Asturiana de los Valles

La raza bovina Asturiana de los Valles pertenece al tronco castaño del que hay varios representantes en el tercio norte de la península ibérica. Una descripción morfológica de la raza y de los principales aspectos de su programa de mejora puede encontrarse en [Dunner *et al.*, 1993]. Esta raza ha evolucionado desde una original utilización mantenera hasta una marcada aptitud cárnica en la actualidad, pudiendo observarse gran variabilidad en la conformación de los reproductores, no siempre compatible con la orientación de los productos de la raza al abastecimiento de los mercados de carne de calidad. Con la calificación morfológica se trata de conseguir animales más perfectos dentro de los cánones de belleza de la propia raza, así como permitir aumentar la rentabilidad de los animales potenciando aquellas características morfológicas que resulten más interesantes desde un punto de vista productivo y económico.

El sistema de calificación morfológica en el vacuno de carne debe permitir seleccionar aquellos reproductores con mayor capacidad genética para:

- transmitir una mayor calidad racial
- mantener o aumentar el tamaño de la raza
- mejorar el formato o conformación carnicera de la raza a cualquier edad y
- permitir los apareamientos dirigidos para corregir defectos

Para lograr estos objetivos, ASEAVA ha empezado a aplicar a la raza Asturiana de los Valles el **Sistema Descriptivo de Calificación Morfológica Continua**, muy similar a los programas de mejora de Francia e Italia [Goyache *et al.*, 1999]. Este nuevo sistema de calificación ha venido a sustituir al método de **Calificación por Regiones** [Cima 1986]. Con la aplicación del sistema de calificación morfológica continua, el objetivo de la evaluación del tipo de los reproductores bovinos ha experimentado un cambio radical: el concepto de *belleza exterior* ha sido reemplazado por el de *belleza funcional* dirigido a identificar los animales con mejores características morfológicas y funcionales lo que les convertirá en excelentes reproductores. El nuevo sistema resulta, ante todo, más informativo ya que proporciona las causas por las que una región no es perfecta, lo que permitirá al ganadero adoptar las medidas adecuadas para mejorar su rebaño. Los anteriores métodos otorgaban excesiva importancia a las particularidades estéticas, presuponiendo inexistentes correlaciones entre apariencia y función e imposibilitando el conocimiento del valor real morfológico y funcional de los animales. La clasificación de los caracteres de tipo en una escala deseable desde “muy malo” a

“excelente” en vez de en una escala objetiva de semántica numérica provocaba una pérdida de información sobre las relaciones biológicas existentes entre los diferentes caracteres y aumentaba la influencia de la subjetividad del calificador sobre las calificaciones obtenidas. El Sistema de Calificación Continua pretende resolver esos inconvenientes; la nueva metodología es, básicamente, un sistema de medida de las dimensiones del cuerpo de los animales y que por tanto es un sustitutivo de la zoometría capaz de ser aplicado de forma masiva en los planes de mejora de los animales bovinos.

## 2.1 Calificación final, caracteres esenciales y variables

El objetivo último del Sistema Descriptivo de Calificación Morfológica Continua es obtener para cada animal una **calificación final**, es decir, un número que nos resuma su *belleza funcional* y nos permita determinar los mejores ejemplares de la raza. Ese número debe sintetizar la información de muchas características y aspectos que se puntúan durante el proceso de calificación morfológica del animal. Para obtener esta calificación final debe conocerse el valor obtenido en los llamados **caracteres esenciales**, que, a su vez, se obtienen a partir de la puntuación de cierto número de **variables**. Estos caracteres esenciales resumen las cuatro cualidades más importantes que deben tenerse en cuenta en los programas avanzados de mejora de ganado bovino de carne:

- el **formato carnicero (FC)** o desarrollo muscular,
- el **tamaño (T)** o desarrollo esquelético,
- las **patas y aplomos (P)** o capacidad funcional, y
- el **aspecto general (AG)** o calidad racial.

La **calificación final** se calculará a partir de estos cuatro caracteres esenciales, mediante una combinación ponderada de las *calificaciones* (no

puntuaciones, más adelante diferenciaremos ambos conceptos) de los mismos. Obtendremos así una variable cuantitativa de un máximo de 100 puntos que resumirá la *belleza funcional* del animal.

$$CF = a(FC) + b(T) + c(P) + d(AG)$$

Los caracteres esenciales siguen resultando demasiado genéricos para que puedan ser puntuados directamente por los expertos. Por ello, cada uno de los caracteres se descompone a su vez en **variables** que sí pueden ser puntuadas por los calificadores ya que tienen una definición conceptual diáfana. En general, esas variables representan dimensiones del animal, ya sean distancias, ángulos o convexidades. Al igual que pasa con la calificación final, la *calificación* de los caracteres esenciales se obtendrá mediante una combinación ponderada de las *puntuaciones* de las variables en las que se descompone el carácter. Las calificaciones del Formato Carnicero, el Tamaño, las Patas y el Aspecto General, se expresarán también sobre un máximo de 100 puntos.

El proceso global, desde la puntuación de las variables hasta la obtención de la calificación final, queda resumido en la Figura 1. En un primer paso, se combinan las puntuaciones de las variables para calcular las calificaciones de los caracteres esenciales, y ponderando adecuadamente éstos se obtiene la calificación final.

La tarea de los calificadores profesionales, entrenados para la implantación del sistema de calificación, es simplemente otorgar, por apreciación visual, una *puntuación* entre 1 y 9 de cada una de las variables consideradas en que se descomponen cada uno de los cuatro caracteres esenciales. El resto de calificaciones se calculan de forma directa.

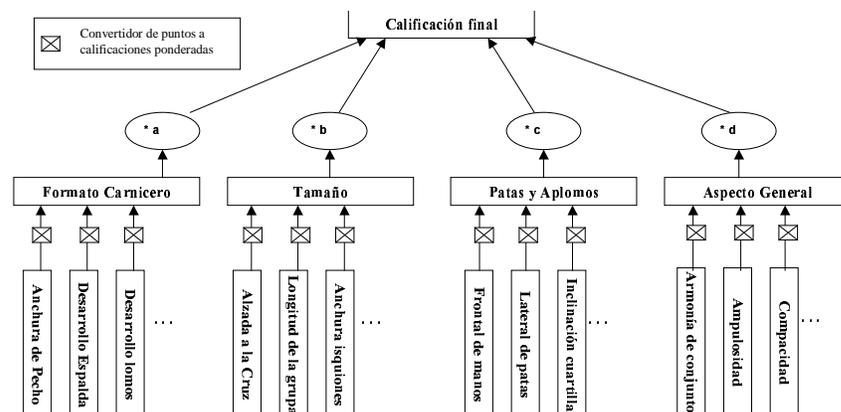


Figura 1 Proceso de cálculo de las calificaciones

## 2.2 Puntuación y Calificación

En el punto anterior se ha hablado de *puntuaciones* y *calificaciones*, términos que con frecuencia se suelen emplear indistintamente pero que en el Sistema de Calificación Continua aplicado en la raza Asturiana de los Valles son distintos. Es necesario diferenciar claramente entre la "*puntuación*" que obtienen los animales para cada variable en la observación realizada por los expertos calificadores y que es independiente de la edad o sexo del animal, y otra la "*calificación*" de esa misma variable que consiste en valorar la "*puntuación*" de acuerdo a la edad y el sexo del animal.

Así, un animal con una alzada de 120 cm para la variable "Alzada a la Cruz" debe obtener una puntuación de 4, independientemente de que el animal considerado sea una vaca de cuatro años o un ternero de catorce meses. Aunque su puntuación sea idéntica, esos dos animales no tendrán la misma calificación, ya que el óptimo para la variable "Alzada a la Cruz" no será el mismo en una hembra adulta que un macho de catorce meses. Mientras el 4 puede ser óptimo para el ternero, ese mismo 4 puede ser pésimo para la vaca. Es tarea de los expertos en la raza Asturiana de los Valles, o en la de cualquier otra raza a la que se aplique este método de calificación, determinar los óptimos de los cuatro grupos básicos de animales: machos de catorce meses, machos adultos, novillas de primer parto y hembras adultas. A partir de esos óptimos, se definirán las fórmulas para combinar las puntuaciones de las variables y poder obtener la calificación de los caracteres. De la misma forma, y teniendo en cuenta los objetivos de la raza de que se trate, se determinará la expresión que nos permita calcular la calificación final partiendo de las calificaciones de los caracteres.

Como consecuencia de lo anterior, hay que indicar en este momento que desde el punto de la construcción del sistema inteligente y tal y como se explicarán con posterioridad, sólo nos interesa averiguar la puntuación, ya que las posteriores calificaciones se obtendrán directamente a partir de aquéllas, sin más que aplicar las fórmulas de transformación de puntos en calificaciones a las que hayan llegado por consenso los expertos de la raza. Luego en principio nuestro objetivo es aprender a puntuar a los animales correctamente en cada una de las variables que analiza el Sistema de Calificación Continua.

## 3. Las variables puntuadas y su representación

Son muchas las variables que el Sistema Descriptivo de Calificación Morfológica Continua indica que deben ser puntuadas, exactamente 31. Es evidente que se sale del ámbito de este artículo exponer todas y cada una de ellas, por ello nos centraremos en los aspectos de más interés desde el punto de vista de su representación computacional y su posterior adquisición. Simplemente citaremos algunas de las variables más ilustrativas sobre las dificultades que entraña la representación y, para hacer más gráfica la explicación, mencionaremos cómo se miden esas características sobre las fotos de los animales que aparecen a la Figura 2.

Cada variable tendrá asociado un conjunto de atributos que influyen, o se cree que influyen, en los calificadores humanos cuando puntúan la variable. Estos atributos constituyen su representación.

Un primer bloque de variables a considerar en los animales está formado por aquellas que tienen una representación inmediata dada por una sola medida. Este es el caso de la Alzada a la Cruz. Su definición zoométrica es la siguiente:

- **Alzada a la Cruz.** Estimación de la estatura del animal desde el suelo hasta la cruz, formada por las apófisis espinosas de las vértebras dorsales. Su representación resulta sencillamente calculando una distancia.

**Alzada\_cruz := longitud\_segmento(L2, L3)**

Muy similares son los casos de la anchura entre isquiones o la inclinación lateral de la grupa.

- **Anchura entre isquiones.** Estimación, en vista posterior, de la distancia entre isquiones, punta de la nalga, en busca de una amplia base para el sustento de las masas musculares.

**Anchura\_entre\_isquiones :=  
longitud\_segmento(P1,P2)**

- **Inclinación lateral de la grupa.** Estimación, en vista lateral, del ángulo de la cadera formado entre la línea que une los iliones y los isquiones y la línea del suelo.

**Inclinacion\_grupo\_lateral :=  
pendiente\_vector (L12, L19, 'horizontal')**

El trabajo más complejo viene en aquellas características que dependen de más de una medida, en esos casos deberemos utilizar un espacio de varias dimensiones para poder captar el sentido, a veces muy difícil, de algunos conceptos. Una variable emblemática en este sentido es la que debe medir la armonía del conjunto de un animal. Su definición es la siguiente:

- **Armonía de conjunto.** Apreciación de la primera impresión que produce el animal como individuo de la raza Asturiana de los Valles, buscándose una apariencia que denote vigor, femineidad o masculinidad, estilo y correlación de sus formas con la aptitud para la producción cárnica, constituyendo un todo armónico entre la longitud, profundidad, ampulosidad y anchura corporales, sin bastedad ósea.

Teniendo en cuenta esta definición, la Armonía de Conjunto es puntuada por los jueces basándose en la apreciación visual que les produce la apariencia, el estilo y la correlación de las formas del animal. Como se puede ver, es una definición muy general y que no indica claramente qué medidas influyen en esa puntuación y qué relación debe existir entre ellas a la hora de puntuar un animal. Por ello, se ha considerado que para la puntuación de esa característica deben tenerse en cuenta, a priori, 13 atributos, que son todos aquellos que tienen que ver con la forma del animal, entre otras la anchura del pecho, la profundidad torácica, la profundidad del vientre, la longitud escapulo-isquiática, o la convexidad de la nalga. Por ello, para su representación usamos los siguientes atributos:

**{pecho}**  
**Anchura\_pecho := longitud\_segmento(F1,F2)**  
**Profundidad\_toracica :=**  
**longitud\_segmento(L2, L6)**  
**Relación\_torax :=**  
**Anchura\_pecho/Profundidad\_toracica**

**{vientre}**  
**Profundidad\_vientre :=**  
**longitud\_segmento(L9, L18)**  
**grado\_agalgamiento :=**  
**profundidad\_toracica / profundidad\_vientre**

**{longitud del cuerpo del animal}**  
**Longitud\_escapulo\_isquiática :=**  
**longitud\_segmento(L4,L19)**  
**Altura\_cruz := longitud\_segmento(L2, L3)**

**{ampulosidad}**  
**relación\_lateral\_nalga :=**  
**radio\_circunferencia (L10, L13,L25)/**  
**longitud\_segmento(L9, L18)**  
**convexidad\_nalga\_posterior :=**  
**redondez\_lista\_ptos(P2,P4,P9,P3,P1,P10)**  
**Redondez\_frontal :=**  
**redondez\_lista\_ptos (F13,F12,F1,F2,F9)**

**{muslo}**  
**Anchura\_muslo :=**  
**longitud\_segmento(P3, P4) /2**  
**Profundidad\_muslo :=**  
**longitud\_segmento(L19, L25)**  
**Relación\_muslo :=**  
**Anchura\_muslo/Profundidad\_muslo**

#### 4. Adquisición de datos

Los datos que se emplearán para realizar el aprendizaje de las variables que componen el Sistema Descriptivo de Calificación Morfológica Continua proceden fundamentalmente de dos vías. Por una parte, se realizan tres fotos a cada uno de los animales calificados: una frontal, otra lateral y otra posterior. Sobre estas fotos un operario debe marcar los puntos clave del animal (véase Figura 2). Con esos puntos, el sistema informático, mediante sencillas técnicas de visión artificial, podrá calcular las medidas de cada uno de los parámetros que son necesarios para realizar la medición de las características que componen el sistema de calificación.

Además de la información que el sistema extrae automáticamente de las fotos de los animales, contamos con las puntuaciones que para cada variable han otorgado los calificadores expertos de ASEAVA. A partir de esas dos fuentes de datos, teniendo en cuenta la representación computacional descrita parcialmente en la sección anterior, se genera un conjunto de entrenamiento por cada una de

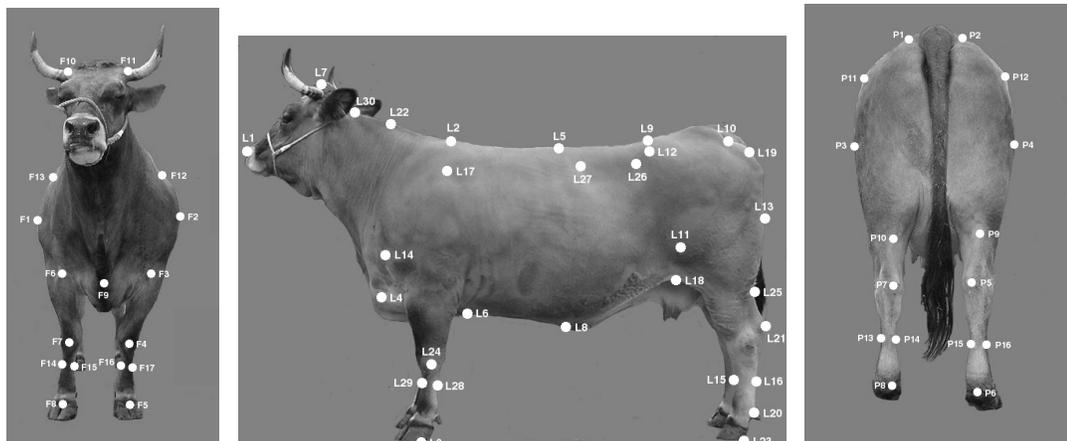


Figura 2 Fotos frontal, posterior y lateral con los puntos relevantes marcados

las variables o características que componen el Sistema de Calificación, es decir, el sistema se descompone en múltiples problemas de aprendizaje, tantos como variables. En esos conjuntos de entrenamiento tendremos, por cada animal, un conjunto de valores para cada atributo que representa la variable considerada; valores que se obtienen de las medidas calculadas a partir de las fotos.

Hay que señalar en este punto, que tanto la toma de las propias fotos como el proceso de calificación en sí, son una tarea con un coste temporal elevado, lo que ha impedido que el conjunto de animales empleados en las pruebas experimentales sea todo lo amplio en número que se hubiera deseado. Sin embargo, los conjuntos de entrenamiento se han compuesto de animales representativos de toda la variabilidad morfológica observable en la raza, desde los animales considerados excelentes, hasta los peor conformados que resulta posible encontrar en las ganaderías comerciales. Se ha tratado, en lo posible de evitar conjuntos con animales de una similar calidad racial, generalmente media-alta ya que son los más habitualmente calificados por su aparición en concursos ganaderos. Conjuntos de este tipo impedirían que los sistemas de aprendizaje pudieran realizar su labor eficientemente.

#### 4.1 Singularidades del aprendizaje de la puntuación

Como se ha podido deducir de la descripción del proceso de puntuación y posterior calificación, nos encontramos ante un problema no muy frecuente dentro de los abordados por el Aprendizaje Automático. Repasaremos a continuación las peculiaridades que presenta y que lo hacen de algún modo singular.

Por una parte estamos ante un problema de clasificación numérica, campo en el que los algoritmos de aprendizaje están menos desarrollados hasta la fecha que en los problemas de clasificación simbólica, los más habitualmente resueltos. Bien es cierto que podría entenderse el problema como discreto, interpretando que las puntuaciones de 1 a 9 que otorgan los calificadores expertos son clases simbólicas y no es necesario que el sistema devuelva valores reales.

Pero si el sistema aprendido concluyese categorías discretas que no tienen asociada ninguna semántica que permita establecer diferencias entre ellas, se limitaría sensiblemente la calidad de la solución resultante. Los algoritmos de aprendizaje que se deben utilizar no pueden, por tanto, emplear criterios de calidad internos basados en discriminaciones

binarias de igualdad o no-igualdad entre clases, sin tener en cuenta que la no-igualdad pueda ser matizable, como ocurre en este caso. No es lo mismo que dos clases sean distintas pero ocupen los lugares extremos de una escala o que sean contiguas. Esta peculiaridad debe ser tenida muy en cuenta.

Otro factor a tener en cuenta es la presencia de **ruido** en los ejemplos de entrenamiento. Al tratarse de puntuaciones otorgadas visualmente por expertos calificadores, es imposible que estén libres de los factores subjetivos consustanciales a la condición humana. Las calificaciones de animales con muy diversas calidades raciales, unido a la realización de las mismas en distintos instantes de tiempo dificultan a los calificadores expertos el mantenimiento de un criterio homogéneo en sus puntuaciones.

Además, existe la posibilidad de disponer de **distintas puntuaciones** sobre el mismo animal dadas por distintos expertos. Las puntuaciones de distintos expertos no tienen que coincidir, ni tan siquiera mantener una correlación elevada. Este es pues otro elemento de ruido, pero de distinta naturaleza que el descrito en el párrafo anterior.

Es conocido que cada sistema de aprendizaje se adapta mejor a unos problemas que a otros y que es absolutamente imposible que un sistema resulte el mejor en los distintos tipos de problemas existentes. Sobre la base de esa realidad bien conocida por todos, y teniendo en cuenta las peculiaridades antes indicadas del proceso de puntuación y calificación, junto a la propia naturaleza del problema, hemos decidido adaptar los algoritmos de aprendizaje empleados de forma que traten de aprovechar al máximo cada una de las particularidades de los problemas a tratar. Por ello adecuamos una versión del vecino más próximo [Aha, 90] [Del Coz *et al.*, 1999] [Del Coz, Bahamonde, 1999] para que se adapte mejor a la resolución de problemas donde la clase tiene una semántica de escala, ya que es una característica que ningún sistema contempla y es imprescindible tenerla en cuenta para poder resolver el problema.

## 5. Algoritmos de aprendizaje empleados

A partir de los ejemplares calificados, los algoritmos de aprendizaje extraerán el conocimiento y lo codificarán de acuerdo a su metodología de trabajo. En este apartado vamos a describir, brevemente, el funcionamiento de los dos algoritmos empleados, cada uno con una metodología distinta de trabajo: uno basado en ejemplos paradigmáticos, 2-NN

Medida 1	Medida 2	Medida 3	....	Puntuación
40.67	64.97	0.63		5
46.59	71.31	0.65		7
42.99	69.99	0.61		6
53.18	82.35	0.65		5
57.9	78.32	0.74		8
70.84	83.1	0.85		9
.....				

Tabla 1. Fragmento del conjunto de paradigmas para la variable Armonía de Conjunto

adaptado para escalas, y otro que extrae funciones, SAFE (Sistema de Aprendizaje de Funciones a partir de Ejemplos) [Quevedo, Bahamonde, 1999]. Comencemos con la adaptación del vecino más próximo para escalas.

### 5.1 Vecino más próximo para casos puntuables en una escala: 2NNE

Dada una característica o variable que queremos puntuar, consideremos un conjunto de casos, patrones o individuos paradigmáticos para las calificaciones que deseamos reproducir en los animales que en el futuro vayan a ser puntuados. Es decir, tenemos un conjunto de animales, de los que sabemos su puntuación en la citada característica, y de los que conocemos además los valores de los atributos con los que se representa la característica. En la Tabla 1 presentamos un ejemplo de conjunto de paradigmas para la Armonía de Conjunto: el conjunto de entrenamiento.

La idea que sigue el algoritmo del vecino más próximo para escalas es la siguiente. En primer lugar, dado un animal del que queremos puntuar una característica, 2NNE (2-NN para Escalas) conoce, gracias al preproceso de sus fotografías, los valores de los atributos que la representan internamente. Entonces, buscamos los dos patrones más parecidos en los valores de estas variables a nuestro animal a puntuar (ver Figura 3). ¿Por qué justamente dos patrones? Muy sencillo, se supone que disponemos de animales paradigmáticos en todo el rango de la escala, luego la puntuación que deberíamos dar al animal será un valor intermedio de las puntuaciones de esos dos paradigmas más próximos.

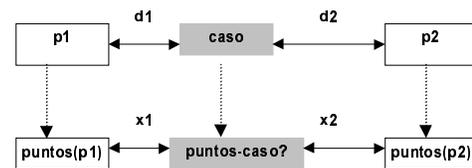


Figura 3. Algoritmo del vecino más próximo para escalas

El parecido entre dos vectores se establece mediante el concepto de vecindad, y se define como más parecidos los vectores que están más próximos según la métrica euclídea. Podría emplearse otro tipo de métricas más sofisticadas, y de hecho puede ser una labor a desarrollar en un futuro, pero de momento la métrica euclídea se adapta a nuestras necesidades.

Si el animal que se quiere puntuar no está situado entre dos paradigmas, sino que está en un extremo del conjunto de paradigmas, entonces la puntuación que le asignaremos será, simplemente, la del más cercano, sin que influya para nada la puntuación del segundo patrón más próximo. Es decir, el animal se encontrará en uno de los extremos de la escala. En el ejemplo de la Figura 4, la puntuación del nuevo *caso*, debe ser la misma que la del paradigma **p1**, ya que en ningún caso **p2** debe influir para nada en la puntuación a otorgar.

Por todo ello es imprescindible disponer de patrones de puntuación situados en los valores extremos; mientras que los patrones de puntuaciones intermedias no son tan necesarios, ya que mediante la interpolación de valores pueden aproximarse esas puntuaciones.

Para especificar las fórmulas concretas que se emplean supongamos, como en la Figura 3, que tenemos un *caso* del que queremos conocer los puntos que merece sabiendo que tiene como patrones más próximos a **p1** y **p2**, donde **p1** es el más próximo de los dos. Supongamos, además que

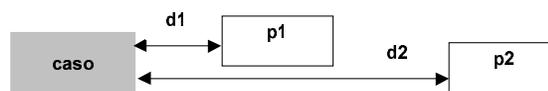


Figura 4. Puntuación para un caso situado en un extremo de los 2 paradigmas más próximos

**distancia(caso,p1) = d1**  
**distancia(caso,p2) = d2**  
**distancia(p1,p2) = d**  
**|puntos(p1) – puntos(p2)| =**  
**diferencia\_puntos**

Si queremos mantener una relación lineal entre las distancias entre los patrones, el caso a evaluar y sus puntos, deberíamos hacer que

**x1 = |puntos-caso? – puntos(p1)|**  
**x2 = |puntos-caso? – puntos(p2)|**

$$\frac{x1}{d1} = \frac{x2}{d2} = \frac{x1 + x2}{d1 + d2} = \frac{\text{Diferencia\_puntos}}{d1 + d2}$$

Nótese que

**x1 + x2 = diferencia\_puntos**

precisamente porque se trata de una escala lineal; si el conjunto de puntos fuese un espacio de más dimensiones esta igualdad no podría garantizarse.

En este contexto, para determinar si el *caso* a puntuar está en un extremo del conjunto de patrones o paradigmas, podemos usar la relación entre las distancias **d1**, **d2** y **d**. Si **d2 = d1 + d**, entonces el patrón **p1** estaría situado justo entre el caso que queremos puntuar y el patrón **p2**. En este caso, **p2**, como indicamos anteriormente, no debería influir en la puntuación del nuevo caso y deberíamos admitir que éste se encuentra en los extremos del conjunto de situaciones que describen los patrones y le adjudicaríamos la puntuación del patrón más cercano, en este caso, **p1**.

Pero cuando el espacio de atributos que definen los patrones tiene más de una dimensión, no siempre sucede que dados tres puntos (**p1**, **p2**, *caso*) uno de ellos está entre los otros dos. Así, en general, tendremos que

**d2 <= d1 + d.**

Entonces asumiremos como situación en la que debemos descartar la influencia de **p2** cuando

**d2 + 0.1 \* d2 >= d1 + d.**

Es decir, cuando **d1 + d** es muy próximo a **d2**; tanto que se diferencia en, a lo sumo, un 10% de la longitud de **d2**. La distorsión que produce el criterio del 10% sólo se manifiesta para puntos que estén verdaderamente muy alejados de los patrones y no es un parámetro que afecte demasiado al funcionamiento del algoritmo.

Hasta ahora hemos abordado la resolución del problema de las escalas pero falta por resolver las distorsiones que puede ocasionar el ruido. La observación de los datos obtenidos nos muestra que con bastante frecuencia existen animales con idénticos valores de los atributos y no siempre el mismo valor en puntos; y al revés, animales con la misma puntuación y muy distintos valores en los atributos. Esta situación se produce sobre todo en los valores más habituales de las escalas lineales, valores que son empleados con más frecuencia por los calificadores y en los que se acaban englobando animales muy distintos. Para resolverlo no consideraremos los dos paradigmas más próximos, sino los dos **grupos** de patrones más cercanos, garantizando que todos los elementos de cada uno de los grupos se encuentran a la misma distancia del caso a puntuar. A la hora de otorgar las puntuaciones se tendrán en cuenta las medias de las puntuaciones de ambos grupos, así como el número de patrones de los que constan. El algoritmo definitivo está descrito en la Figura 5.

Como se aprecia, se consideran tanto las longitudes

```

función vecino_mas_proximo_escalas (caso: un_caso; lista:una_lista_patrones):real;
comienzo
  lista_1 := lista_más_cercanos(caso, lista); {puede haber varios a la misma distancia}
  lista_2 := lista_más_cercanos(caso, lista – (lista_1));
  d1 := distancia(caso,first(lista_1));
  d2 := distancia(caso,first(lista_2));
  {son iguales para cada elección que hagamos de puntos de estas listas}
  (p1, p2) := par_puntos_minima_distancia (lista_1,lista_2);
  d := distancia(p1,p2);
  si (d2 * 1.1) >= d + d1
    entonces {el patrón más lejano está fuera del ámbito de influencia}
      devuelve media(puntos(lista_1))
    en_otro_caso
      devuelve media-larga (puntos(lista_1), d1, puntos(lista_2), d2)
  fin_si
fin

media-larga (p1, d1, p2, d2)= ( media(p1)*d2 + media(p2)*d1 ) / ( longitud(p1)*d2+ longitud(p2) * d1)

```

Figura 5. Algoritmo del vecino más próximo para escalas

de las listas como sus medias. Nótese que si un caso a puntuar tiene valores de los atributos a distancia cero de otros patrones, el resultado será la media de los puntos de éstos.

## 5.2 SAFE

Desde el punto de vista de las soluciones que produce lo aprendido, cabe distinguir en el Aprendizaje Automático dos corrientes fundamentales: los sistemas que sintetizan reglas (u otros mecanismos equivalentes, como los paradigmas de 2NNE) capaces de clasificar casos no vistos en un conjunto finito de categorías discretas, y los que inducen funciones y, por tanto, concluyen, en último extremo, números reales [Quinlan, 1993]. SAFE (Sistema de Aprendizaje de Funciones a partir de ejemplos) [Quevedo, Bahamonde, 1999] trabaja en este último sentido: dado un conjunto de ejemplos con sus correspondientes atributos y un valor o resultado, tratará de sintetizar las funciones necesarias que le permitan otorgar, para ejemplos no vistos, un valor real en consonancia con lo aprendido durante el entrenamiento. En general, SAFE sintetizará una función que estará definida generalmente a trozos, es decir, formada por varias subfunciones de forma que cada una de ellas asignará valor a los puntos que estén en su dominio, calculándose las zonas no cubiertas mediante interpolación. La determinación de estas subfunciones se realiza mediante el estudio de los intervalos significativos del problema. La complejidad de SAFE hace imposible una explicación mucho más amplia, por lo que para cualquier ampliación nos remitimos a la cita bibliográfica antes indicada.

## 6. Resultados experimentales

Como se ha expuesto con anterioridad, la resolución de nuestro problema pasa por la resolución de muchos subproblemas simples, tantos como variables o características se puntúan durante la calificación morfológica de un animal. Dentro de ese amplio grupo de problemas podemos distinguir dos tipos:

- **Variables o características con carácter lineal.** Normalmente son características cuya representación informática tiene un solo atributo medible en las fotos. Se calcula mediante regresión la función que mejor se ajuste a la nube de puntos que es el conjunto de entrenamiento.
- **Variables o características con linealidad desconocida.** Los problemas de este grupo,

suelen tener varios atributos en cuenta, son problemas n-dimensionales. En este caso, puede resultar imposible fijar un mecanismo directo de asignación de puntos como pasa en los problemas del grupo anterior.

En las pruebas experimentales se ha optado por analizar problemas de los dos tipos antes indicados, estudiando tanto las soluciones que aportan los expertos, como los resultados que proporcionan los sistemas de aprendizaje en comparación con ellos. La razón para realizar esta comparativa en las variables de las que conocemos su carácter lineal, es que sirven de perfecta ilustración de las peculiaridades del aprendizaje en estos problemas a las que aludíamos en el apartado 4.1.

### 6.1 Problemas con carácter lineal

Ni que decir tiene que los problemas en los que conocemos perfectamente su función de cálculo no precisan en absoluto de la ayuda que el Aprendizaje Automático puede ofrecer. Bastará que los expertos nos permitan recopilar una muestra representativa de sus puntuaciones para realizar una regresión.

Resulta especialmente gráfico el tratamiento de la puntuación de una variable tan evidente como la **Alzada a la Cruz**, que además es muy representativa de los problemas típicos del sistema de calificación.

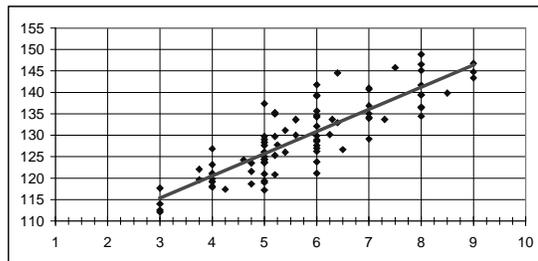
La recta de regresión obtenida permite calcular los puntos usando la siguiente fórmula:

$$\text{puntos} = \frac{\text{alzada a la cruz} - 89}{7}$$

Teniendo en cuenta la precisión del sistema informático a la hora de medir la variables simples, la aplicación de esta expresión es la mejor solución que se le puede dar al problema. Aún así, hemos comparado las soluciones que ofrecen los calificadores humanos y los sistemas de aprendizaje.

Estudiando en primer lugar las puntuaciones de los calificadores humanos, podemos observar que distan mucho de resultar óptimas. En la Figura 6 se muestran las puntuaciones que los expertos otorgaron (eje X) para un conjunto de animales calificados de los que se conoce la alzada *exacta* medida sobre las fotos (eje Y), y la recta de regresión de esas puntuaciones. Como puede verse, se dan los dos posibles errores: animales de la misma medida y distinta puntuación, y puntuaciones idénticas para animales de distinta medida. Es particularmente llamativo la disparidad de los animales que obtienen 6 puntos: van desde los 122 cm. hasta los 144 cm.,

medidas que se deberían corresponder con puntuaciones entre 4 y 8 puntos.



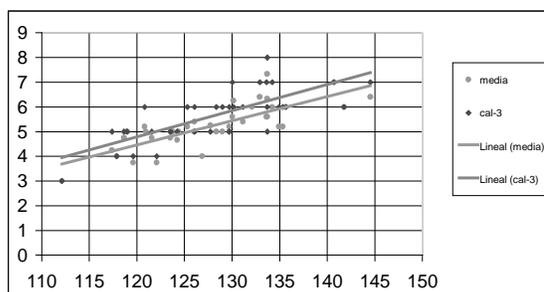
**Figura 6.** Puntuaciones de los expertos para la alzada a la cruz y recta de regresión.

A pesar de ello, si calculamos la correlación de las puntuaciones de los calificadores respecto a las medidas de los animales, observamos que alcanzan un nivel aceptable. Ahora bien, si comparamos esa misma correlación con la que obtienen los sistemas de aprendizaje empleados, podemos ver que tanto 2NNE como SAFE producen resultados mejores (véase Tabla 2).

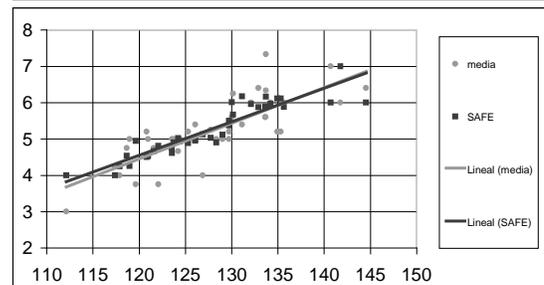
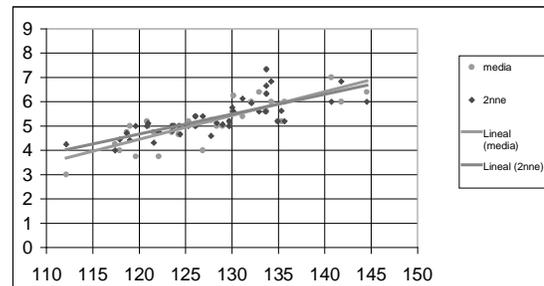
Las puntuaciones de la Alzada a la Cruz pueden observarse desde otro punto de vista. Dado que distintos expertos puntuaron a un grupo de animales, podemos tomar como indicador de sus puntuaciones la media de las que los expertos dieron a cada animal. El efecto es que se suavizan las dispersiones. En las Figuras 7, 8 y 9 comparamos las puntuaciones medias con las de uno de los calificadores y las de los sistemas 2NNE y SAFE respectivamente.

Calif1	Calif2	Calif3	2NNE	SAFE
0,719	0,757	0,751	0,774	0,923

**Tabla 2.** Correlación de las puntuaciones de los calificadores y la de los sistemas de aprendizaje frente a la medida de la alzada



**Figura 7.** Alzada a la cruz. Dispersión y rectas de regresión de las puntuaciones del Calificador 3 y la media de las puntuaciones dadas por todos los expertos.



**Figura 8.** Alzada a la cruz. Dispersión y rectas de regresión de las puntuaciones de 2NNE (arriba) y SAFE (abajo) y la media de las puntuaciones dadas por todos los expertos.

Como puede verse, parece que el Calificador 3 se caracteriza por otorgar puntuaciones ligeramente elevadas. Por otra parte, los sistemas de aprendizaje aproximan bastante mejor sus puntuaciones, sobre todo SAFE que obtiene unos resultados óptimos. Hay que destacar que dado que el problema solamente tiene un atributo, la altura medida de la alzada, resulta prometedor que los sistemas se comporten mejor que los calificadores humanos.

Las mismas conclusiones se pueden extraer del estudio de otros dos problemas similares: la **Anchura entre isquiones** (Tabla 3 y Figura 9) y la **Inclinación lateral de la grupa** (Tabla 4 y Figura 10). En el primero de los dos problemas puede apreciarse que ambos sistemas concluyen puntuaciones con una mayor correlación que los tres calificadores con las medidas obtenidas en las fotos, destacando sobre manera los resultados de SAFE. Lo mismo pasa en el problema de la Inclinación lateral de la grupa.

Calif1	Calif2	Calif3	2NNE	SAFE
0,60374	0,52065	0,55402	0,68798	0,85571

**Tabla 3.** Correlación de las puntuaciones de 3 calificadores y la de los sistemas de aprendizaje frente a la medida de la anchura entre isquiones.

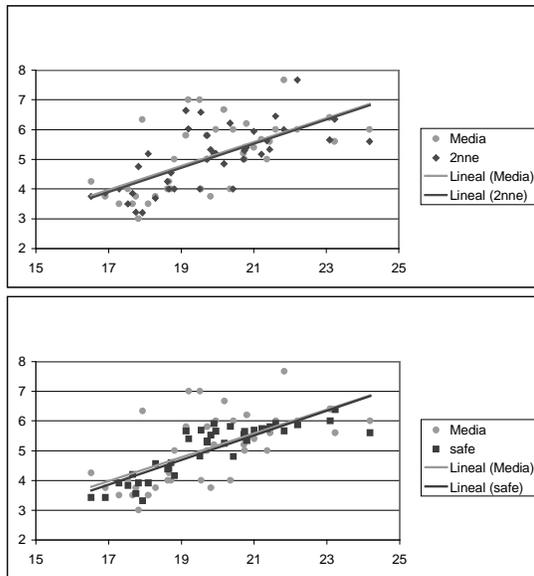


Figura 9. Grado de correlación de 2NNE (arriba) y SAFE (abajo) respecto a la anchura entre isquiones.

Calif1	Calif2	Calif3	2NNE	SAFE
-0,66412	-0,54272	-0,70683	-0,73138	-0,93180

Tabla 4. Correlación de las puntuaciones de 3 calificadores y la de los sistemas de aprendizaje frente a la medida de la inclinación lateral de la grupa.

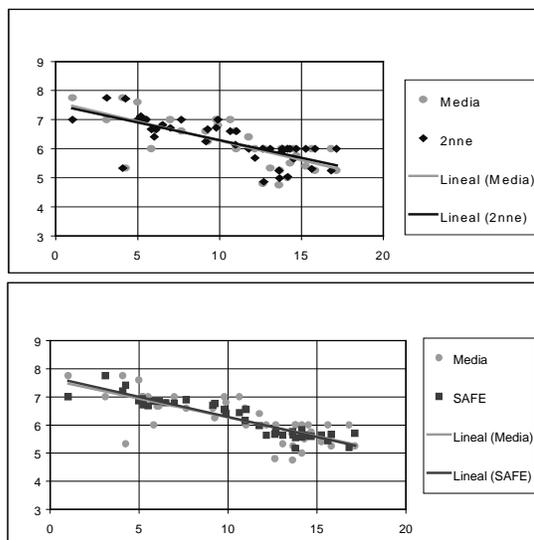


Figura 10. Grado de correlación de 2NNE (arriba) y SAFE (abajo) respecto a inclinación lateral de la grupa

## 6.2 Puntuación de variables no lineales

Hay un grupo de variables a puntuar para las que, a priori, no cabe pensar en una determinación directa y sencilla como ocurre en los problemas del anterior grupo. Un problema representativo de esta familia es el de la puntuación de la **Armonía de Conjunto**. Se trata de un problema donde intervienen varias cuestiones y donde la propia especificación del mismo abre la puerta para que los calificadores apliquen de una forma más subjetiva lo que entienden ellos por armonía del conjunto del animal (ver la discusión sobre su representación en el apartado 3). No pasa como en los problemas anteriores donde la puntuación se otorga en función de la observación unos pocos atributos medibles; en este caso no está tan claro qué se entiende por armonía de conjunto y, por tanto, la inducción de ese concepto resulta más interesante y compleja desde el punto de vista de su representación y del Aprendizaje Automático.

Para estimar la calidad de las puntuaciones que inducen nuestros sistemas de aprendizaje debemos en estos casos emplear una técnica clásica en aprendizaje. Partimos de conjuntos de entrenamiento formados por las puntuaciones de cada característica en 65 animales calificados por 6 expertos. El experimento realizado consistió en calcular un *leaving-one-out* sobre cada uno de los conjuntos de entrenamiento.

Un *leaving-one-out* consiste en entrenar el algoritmo de aprendizaje con todos los ejemplos menos uno y a partir del conocimiento extraído durante el entrenamiento, puntuar el ejemplo restante. Los errores que aparecen en la Tabla 5, representan la media del error absoluto, entendiendo que el error absoluto es la diferencia entre la puntuación que da el sistema o el experto calificador y la media de las puntuaciones de los propios los expertos, ya que es con estas puntuaciones medias con las que se realiza el entrenamiento.

Como se puede apreciar en los datos de la tabla adjunta, SAFE obtiene un error ligeramente menor que 2NNE, pero en ambos casos su error está lejos del error cometido por los calificadores. En este aspecto, hay que indicar que la comparación realizada en esos términos favorece claramente a los calificadores humanos, ya que sus puntuaciones sirven de base para el cálculo de la puntuación media que es la que aparece en los conjuntos de entrenamiento y con la que se miden los errores. Es decir, la puntuación del calificador influye en la media con la que luego se compara, por lo que es lógico que sus errores sean menores que los de SAFE y 2NNE. Teniendo en cuenta ese detalle, las

Problema	Calif1	Calif2	Calif3	Calif4	Calif5	Calif6	SAFE	2NNE
Ampulosidad	0,467	0,502	0,326	0,671	0,430	0,452	0,836	0,940
Anchura Muslo	0,406	0,434	0,396	0,343	0,422	0,371	0,688	0,854
Anchura Pecho	0,279	0,298	0,353	0,454	0,483	0,351	0,557	0,646
Armonía Conjunto	0,584	0,698	0,458	0,318	0,346	0,422	0,718	0,660
Compacidad	0,579	0,650	0,543	0,324	0,416	0,565	0,699	0,756
Convexidad Espalda	0,397	0,448	0,342	0,397	0,402	0,295	0,660	0,971
Convexidad Grupa	0,471	0,430	0,350	0,356	0,418	0,373	0,869	1,198
Curvatura Nalga	0,255	0,270	0,222	0,184	0,210	0,219	0,750	0,624
Desarrollo Lomos	0,476	0,277	0,321	0,368	0,412	0,360	0,922	1,173
Desarrollo Muscular Cuello	0,394	0,359	0,449	0,508	0,391	0,387	0,691	0,879
Diámetro Caña	0,457	0,541	0,368	0,422	0,410	0,515	0,446	0,547
Frontal Manos	0,258	0,154	0,305	0,263	0,204	0,221	0,352	0,420
Lateral Manos	0,065	0,232	0,083	0,086	0,092	0,084	0,127	0,182
Lateral Patas	0,238	0,282	0,397	0,352	0,350	0,248	0,308	0,406
Posterior Patas	0,117	0,141	0,132	0,324	0,275	0,173	0,271	0,328
Profundidad Muslo	0,449	0,366	0,391	0,530	0,486	0,395	0,601	0,716
Profundidad Vientre	0,441	0,393	0,428	0,324	0,363	0,366	0,522	0,576
Tamaño Cabeza	0,386	0,395	0,305	0,340	0,312	0,289	0,508	0,662
Media Error Absoluto	0,373	0,382	0,343	0,365	0,357	0,338	0,585	0,697

**Tabla 5.** Errores absolutos medios de los 6 calificadores, SAFE y 2NNE en cada uno de los problemas del Sistema de Calificación Morfológica cuyo carácter a priori no es lineal. Los errores se computan como desviaciones en valor absoluto respecto a la puntuación media de los calificadores en cada animal. El experimento se realizó con 65 animales. El método de estimación del error de los sistemas de aprendizaje fue el *leaving-one-out*.

diferencias entre los calificadores humanos y los sistemas no son significativas.

En todo caso, el error de ambos sistemas está muy por debajo de la unidad, lo que puede considerarse satisfactorio de acuerdo al uso final de los algoritmos. Cometer un error de prácticamente medio punto es muy poco significativo dentro del proceso de calificación morfológica, por lo que se cumplen plenamente los objetivos marcados. Hay que tener en cuenta, además, que el proceso de calificación se encuentra en fase de implantación y, por tanto, los propios calificadores humanos no han alcanzado el grado de experiencia óptimo, lo que sin duda se refleja en la calidad de sus puntuaciones como se demostró en apartados anteriores. La solución definitiva precisará de conjuntos de entrenamiento más adecuados, esto es, más grandes y mejor calificados por los expertos humanos. Es de esperar que con conjuntos de entrenamiento de ese tipo los errores disminuyan aún más.

## 7. Conclusiones

Se ha descrito un Sistema Inteligente de Calificación Morfológica de bóvidos de la Raza Asturiana de los Valles. Su diseño y construcción es un problema complejo y poco habitual dentro del campo de aplicación de la Inteligencia Artificial por las dificultades de representación y las relativas a la adquisición posterior del conocimiento que el sistema ha de manejar. En este caso, en buena

medida, se han utilizado técnicas de Aprendizaje Automático, para lo que ha sido necesario desarrollar y adaptar algoritmos de aprendizaje de acuerdo a las características del problema. Por una parte, se ha adaptado un algoritmo simple, el del vecino más próximo, y por otro lado, se ha utilizado un algoritmo mucho más complejo que induce funciones. Ambos algoritmos abren un nuevo camino dentro del aprendizaje ya que tratan un nuevo problema de clasificación: aquél en el que la clase es un entero (o algo muy próximo a un entero) que se sitúa en una escala numérica.

Los sistemas desarrollados tienen en cuenta las consideraciones semánticas de esa característica y la incluyen en sus mecanismos de aprendizaje. La unión de estos algoritmos junto con técnicas de visión artificial, nos ha permitido desarrollar una aplicación práctica que obtiene resultados satisfactorios, hasta el punto de poder servir de ayuda para el entrenamiento y mantenimiento de los calificadores expertos humanos.

Además, a partir del prototipo desarrollado, será posible construir sistemas para usos industriales específicos.

## 8. Bibliografía

AHA, D. W.: *A Study of Instance-based Algorithms for Supervised Learning Tasks: Mathematical, Empirical, and Psychological*

- Evaluations*. Ph. D. Dissertation. University of California at Irvine, (1990).
- CIMA, M. (1986). *Estudio biotipológico de las razas bovinas autóctonas del Principado de Asturias*. Graficas Summa, Oviedo, 82 pp.
- DEL COZ, J. J., LUACES, O., QUEVEDO, J.R., ALONSO, J., RANILLA, J., & BAHAMONDE, A. (1999). *Self-Organizing Cases to Find Paradigms*. Lecture Notes in Computer Sciences, Springer-Verlag, Vol. 1606, 527-536.
- DEL COZ, J.J., BAHAMONDE, A.: *Mapas autoorganizados con atributos discretos*. CAEPIA'99-TTIA'99 VIII Conferencia de la Asociación Española para la Inteligencia Artificial - III Jornadas de Transferencia Tecnológica de Inteligencia Artificial - Libro de Actas - Vol. I, pp. 117-124, 1999.
- DUNNER, S., CAÑON, J., GUTIERREZ, J.P., VALLEJO, M., ALONSO, L., GOYACHE, F. (1993). *La Race Bovine Asturienne des Vallées*. AGRI, 16: 75-84.
- GOYACHE, F., VILLA, A., BARO, J.A., ALONSO, L. (1999). *Aplicación de un sistema de calificación morfológica continua en la raza Asturiana de los Valles*. FEAGAS, 16: 54-68.
- QUEVEDO, J. R., BAHAMONDE, A.: *Aprendizaje de Funciones Usando Inducción sobre Clasificaciones Discretas*. CAEPIA'99-TTIA'99 VIII Conferencia de la Asociación Española para la Inteligencia Artificial - III Jornadas de Transferencia Tecnológica de Inteligencia Artificial - Libro de Actas - Vol. I, pp. 64-71, 1999.
- QUINLAN, J. R.: *Combining instance-based and model-based learning*. En Proceedings Tenth International Machine Learning Conference, Amherst, MA, Morgan Kaufmann, (1993).