

Clasificación de estados activos e inactivos de conejos en crecimiento a partir de datos de acelerómetro utilizando algoritmos de aprendizaje automático

M. Mora^{1*}, M. Piles¹, I. David², J.P. Sánchez¹, L. Riaboff^{2,3,4}

¹ *Animal Breeding and Genetics, Institute of Agrifood Research and Technology (IRTA), Caldes de Montbui, 08140 Barcelona, Spain.*

² *GenPhySE, Université de Toulouse, INRAE, ENVT, 31326 Castanet Tolosan, France*

³ *School of Computer Science, University College Dublin, Dublin, Ireland*

⁴ *VistaMilk SFI Research Centre, Ireland*

*Corresponding author: Mónica Mora. monica.mora@irta.cat

Resumen

Los sistemas automatizados para monitorear el comportamiento animal están ganando popularidad tanto para la investigación como para el manejo de los animales. Debido al pequeño tamaño y la versatilidad de los datos producidos, los acelerómetros portátiles han sido ampliamente investigados para este propósito. En este estudio, el objetivo fue detectar automáticamente los estados de actividad/inactividad de los conejos a partir de datos de acelerómetro en conejos en crecimiento. Con ese fin, 16 animales fueron equipados con un acelerómetro y grabados durante 2 semanas. Se anotaron manualmente un total de 10 horas de video en todos los conejos utilizando el software Boris, identificando 6 clases de comportamientos diferentes: acostado, comiendo, moviéndose, lamiéndose, caminando y bebiendo, que, posteriormente, fueron agrupados en dos clases: activo e inactivo. La señal del acelerómetro y las anotaciones de video se sincronizaron manualmente. Los componentes estáticos y dinámicos de la señal se aislaron aplicando un filtro paso bajo y un filtro paso alto, y se derivaron 4 series de tiempo adicionales a partir de estos componentes. La señal se segmentó en ventanas de tiempo de diferentes tamaños: 1, 3, 5, 7 y 9 segundos. Para cada ventana, se extrajeron un total de 41 características en el dominio del tiempo y de la frecuencia. Se utilizaron diferentes subconjuntos de datos que contenían un número creciente (de 5 a 25 en saltos de 5) de las características más informativas identificadas con el algoritmo *random forest* (RF) para entrenar un modelo de clasificación binaria (inactivo como clase positiva). Se evaluó el rendimiento de la clasificación de RF, *support vector machine* (SVM) y *gradient boosting* (GB). Se implementó una validación cruzada anidada (CV) con una CV externa *Leave-One-Animal Out* y una CV interna de tres *folds* para ajustar los hiperparámetros. Se implementó el mismo remuestreo para cada tamaño de ventana y cada clasificador para que los modelos fueran evaluados con los mismos conjuntos de datos. El rendimiento se evaluó en los conjuntos de datos de test utilizando diferentes métricas: precisión, *recall*, *F1 score* y *accuracy*. Los resultados mostraron que los clasificadores funcionaron de manera muy similar. Con la mejor configuración (tamaño de ventana de 9 s y con las 5 características más importantes), el modelo de RF alcanzó una precisión mediana de 1 (Q1=0.99, Q3=1) y una *recall* mediana de 0.93 (Q1=0.89, Q3=0.97). Estos resultados mostraron que el modelo es altamente confiable en la clasificación correcta de instancias positivas. Además, lograr una *recall* de 0.93 enfatiza la efectividad del modelo en capturar una parte sustancial de instancias positivas. Por lo tanto, los acelerómetros combinados con modelos de aprendizaje automático tienen un gran potencial para monitorear la actividad de los conejos y para una variedad de aplicaciones en la ciencia animal.

Keywords: Acelerómetro, conejo, clasificación, monitoreo, machine learning