

USO DE ACCELERÓMETROS PARA CUANTIFICAR EL NIVEL DE ACTIVIDAD DE CONEJOS EN CRECIMIENTO MEDIANTE LA PREDICCIÓN DE SU COMPORTAMIENTO

Piles^{1*}, M., Sánchez¹, J.P., Riaboff², L., David³, I. y Mora¹, M.

¹Instituto de Investigación y Tecnología Agroalimentaria (IRTA), Torre Marimón.

²School of Computer Science, University College Dublin. ³GenPhySe, Université de Toulouse, INRAE

*miriam.piles@irta.cat

INTRODUCCIÓN

Uno de los retos de la ganadería de precisión es encontrar herramientas que permitan cuantificar de manera individual el tiempo que dedican los animales a cada una de las diferentes actividades. Con este fin se ha propuesto el uso de acelerómetros tri axiales, que, por su pequeño tamaño y coste asequible, pueden ser útiles para mejorar el bienestar y la producción de los animales (Chapa *et al.*, 2020). Estos sensores miden la aceleración en las tres direcciones (x,y,z) permitiendo detectar patrones en el comportamiento. El objetivo de este trabajo es predecir, usando algoritmos de inteligencia artificial, el tipo de actividad que en cada momento desarrollan los conejos en crecimiento a partir de diversos parámetros extraídos de los registros tomados por el acelerómetro.

MATERIAL Y MÉTODOS

Los datos corresponden a señales de acelerómetros e imágenes de 8 gazapos: 4 alimentados bajo restricción limitando el periodo de acceso al pienso a 12 h al día, y 4 alimentados a voluntad. Se utilizó el sensor AX3 (Axivity Ltd.) con una frecuencia de muestro de 25 Hz. Éste se fijaba a la espalda del gazapo con una cinta elástica manteniendo la misma orientación en todos los animales de modo que, el eje "x" detectara la dirección arriba-abajo, el eje "y" la dirección derecha-izquierda y el eje "z" la dirección delante-atrás. Un total de 4,5 horas de video fueron anotadas con el programa *BORIS*, identificando 7 tipos de actividad: comer (C), beber (B), moverse *in-situ* (M), andar (A), lamerse (L), descansar tumbado (T) y descansar sentado (S). Estos tipos se agruparon en 4 clases de actividades: comer (C), beber (B), descansar (D, T+S) y movimiento general (MG, M+A+L). Las señales de los acelerómetros y las anotaciones de los videos se sincronizaron manualmente. La señal se segmentó en ventanas de 2 s en las que se calcularon un total de 47 parámetros de las señales en los 3 ejes: de posición (media, mediana...), parámetros de dispersión (varianza, mínimo, máximo, cuartiles ...) y parámetros relacionados con la variación de movimiento (pitch, roll...). Tras eliminar las ventanas que tenían asociada más de una clase se retuvieron un total de 6.658 registros. En el conjunto de entrenamiento (80 %) se implementó una validación cruzada en 3 partes para optimizar los hiperparámetros y seleccionar los 20 parámetros más informativos con *random forest* (Ho, 1995). Este mismo algoritmo se implementó para construir el modelo de predicción con todos los datos de entrenamiento dados los hiperparámetros previamente obtenidos.

RESULTADOS Y DISCUSIÓN

De las 6.658 ventanas, el 50 % pertenecían a la clase D, el 23 % a la clase MG y C y el 4 % a la clase B. La tasa global de acierto en la clasificación fue de 0,74. Entre los parámetros más informativos los destacaron aquellos relacionados con la posición. La clase mejor predicha fue C con una precisión y una *recall* de 0,83 y 0,75, respectivamente. La clase peor predicha fue MG con una precisión y una *recall* de 0,66 y 0,50, respectivamente, estando principalmente confundida con la clase D. Se espera que estos resultados mejoren aumentando los datos de las clases menos frecuentes de manera sintética y/o anotando más imágenes en otros lotes de animales.

CONCLUSIÓN

El acelerómetro parece ser una buena herramienta para cuantificar el tiempo que los gazapos dedican a diferentes actividades diarias. No obstante, es necesario recoger más información para mejorar los entrenamientos, probar otros algoritmos y mejorar los modelos predictivos.

REFERENCIAS BIBLIOGRÁFICAS

• Chapa, *et al.* 2020. Behavioural Processes 181. 10.1016/j.beproc.2020.104262. • Ho. 1995. Random decision forests 1: 278-28. doi: 10.1109/ICDAR.1995.598994.

Agradecimientos: Este trabajo está financiado por el proyecto PID2021-128173OR-C21 (GENEF3). MM cuenta con una beca FPI asociada al proyecto RTI2018-097610R-I00.