

Predicción del consumo de materia seca de forraje en vacas lecheras mediante el uso de acelerómetros

Ricardo Rosero-Noguera*, Sebastián Bedoya-Mazo y Sandra L. Posada-Ochoa

Facultad de Ciencias Agrarias, Universidad de Antioquia, Grupo de Investigación en Ciencias Agrarias (GRICA), Medellín, Colombia (Correo-e: jaime.rosero@udea.edu.co; bedoya.2705@gmail.com; sandra.posada@udea.edu.co)

* Autor a quien debe ser dirigida la correspondencia

Recibido Dic. 6, 2021; Aceptado Feb. 4, 2022; Versión final Mar. 23, 2022, Publicado Ago. 2022

Resumen

Este trabajo evaluó el uso de acelerómetros para determinar el consumo de materia seca de pasto (CMSp) en vacas lecheras. Conocer el consumo de materia seca es fundamental para balancear raciones. Datos provenientes de quince vacas Holstein, que portaron un acelerómetro en la región atlanto-occipital, fueron empleados para construir y validar un modelo de predicción. Se construyó una red neuronal artificial (RNA) para predecir el CMSp con base en la posición angular de la cabeza. La validación de las predicciones de la RNA fue determinada empleando diferentes criterios estadísticos. El tiempo de consumo estimado por la RNA fue de 480.4 ± 73 minutos/día. El CMSp observado y predicho por la RNA fue de 13.1 ± 1.8 y 13.8 ± 2.1 kg/día, respectivamente. Se concluye que la distancia residual entre los valores observados y predichos muestra que con el uso de acelerómetros es posible predecir con alto grado de aproximación el CMSp.

Palabras clave: alimento de ganado; consumo de pasto seco; balance de raciones; uso de acelerómetros

Predicting forage dry matter intake in dairy cows by using accelerometers

Abstract

This research study evaluated the use of accelerometers to determine grass dry matter intake (DMI_g) in dairy cows. Knowing dry matter intake is essential to balance rations. Data from fifteen Holstein cows fitted with an accelerometer in the atlanto-occipital region were used to build and validate a predictive model. An artificial neural network (ANN) was constructed to predict DMI_g based on the angular position of the head. Validation of ANN predictions was determined using statistical criteria. The results showed that ANN's intake time estimate was 480.4 ± 73 minutes/day. The DMI_g observed and predicted by ANN was 13.1 ± 1.8 and 13.8 ± 2.1 kg/day, respectively. In conclusion, the residual distance between the observed and predicted values showed that by using accelerometers it was possible to predict the DMI_g with a high degree of accuracy.

Keywords: cattle food; dry grass intake; ration balance; modeling; use of accelerometers

INTRODUCCIÓN

Determinar con precisión el consumo de materia seca (CMS) es fundamental en la producción ganadera. A partir de este valor se establecen planes de manejo nutricional y estrategias de suplementación acordes con los requerimientos animales en procura de un uso eficiente y racional de los nutrientes. En la práctica, determinar el CMS en vacunos es una tarea difícil, laboriosa y costosa. Diferentes metodologías han sido desarrolladas para cuantificar el CMS. Estas metodologías se pueden dividir en dos grupos: métodos directos que incluyen aforos a la entrada y salida de los animales del potrero y en el caso de animales estabulados, por diferencia entre el forraje ofrecido y rechazado (Macon et al., 2003); los métodos indirectos emplean marcadores indigestibles (Cr_2O_3 , TiO_2 , n-alcanos, lignina, entre otros) (Mayes y Dove, 2000), espectroscopia de infrarrojo cercano (Evangelista et al., 2021), evaluación del comportamiento animal y modelos matemáticos para predecir el consumo (De Souza et al., 2019). Inevitablemente, todas las metodologías presentan limitantes, que en el caso de los marcadores indigestibles, están asociadas con la dosis, la frecuencia de suministro, la palatabilidad, la tasa de recuperación y el costo de su determinación (Velásquez et al., 2018).

Los aforos de forraje a la entrada y salida de los animales del potrero están sujetos a errores en la determinación de la disponibilidad de forraje y la altura de pastoreo, además de no permitir mediciones individuales del consumo (Dulphy y Demarquilly, 1994). Por su parte, la amplia gama de modelos matemáticos disponible en la literatura centra sus predicciones en características del animal (requerimiento de energía, peso vivo, días en leche, producción y composición de la leche) y del alimento (concentraciones de fibra, almidones, proteína y lignina), dejando de lado variables importantes que determinan el consumo, como son la condición corporal, el número de lactancias, las señales quimiostáticas, la disponibilidad de forraje y condiciones ambientales como temperatura y humedad relativa (Mazumder y Kumagai, 2006).

Recientemente en la producción pecuaria ha crecido de manera vertiginosa el uso de sensores remotos, drones, análisis de imágenes e internet, tecnologías que se han orientado a la captura de información en tiempo real buscando facilitar la toma de decisiones (Lovarelli et al., 2020). Dentro de este grupo de dispositivos los acelerómetros han cobrado relevancia para monitorear el comportamiento animal por su bajo costo, autonomía, reducida interferencia con el comportamiento animal y minimización del error humano (Bidder et al., 2014). Recientes investigaciones relatan el uso de acelerómetros para describir el comportamiento alimentario de vacunos basados en la posición de la cabeza al momento de la ingestión de alimento (Arcidiacono et al., 2017; Grinter et al., 2019). Brevemente, un acelerómetro es un dispositivo que mide la fuerza generada por el cambio de movimiento de un cuerpo (aceleración) y al mismo tiempo determina la dirección en que se sucede esa aceleración. El acelerómetro se acompaña de un giroscopio que mide la velocidad angular, que, al ser integrada con respecto al tiempo, hace posible determinar el desplazamiento angular de un cuerpo estableciendo así su posición. En este contexto, este trabajo tuvo por objetivo evaluar el uso de acelerómetros para determinar el consumo de materia seca de pasto (CMSp) en vacas lecheras.

METODOLOGÍA

El experimento fue realizado en la hacienda “La Montaña”, propiedad de la Universidad de Antioquia, localizada en el municipio de San Pedro de los Milagros (Ant., Colombia), a 2468 msnm, con una temperatura y precipitación media anual de 14.2° C y 2923 mm, respectivamente. De acuerdo con la clasificación propuesta por Köppen, el clima de la región se cataloga como templado húmedo de montaña.

Animales y manejo

Quince vacas Holstein en segundo tercio de lactancia (155 ± 60 días en leche), con una producción media de 22 ± 3.2 l/día y con un peso vivo promedio de 545 ± 30 kg fueron estabuladas en un galpón abierto, con ventilación e iluminación natural en corrales individuales (6 m^2) que disponían de comedero y bebedero. El comedero tenía las siguientes dimensiones 55 cm x 100 cm x 55 cm (largo x ancho x alto) y el bebedero estaba provisto con válvula de llenado automático que garantizó una oferta continua de agua fresca y limpia. Las instalaciones contaban con techo para proteger a los animales de la radiación solar directa y evitar el estrés térmico. Para prevenir lesiones pódalas y aislar a los animales de la humedad, el piso de concreto del galpón se cubrió con tapetes de caucho. Un periodo de 21 días fue establecido para adaptar a los animales a las condiciones de estabulación y manejo.

Los animales fueron divididos en dos grupos, un grupo de construcción del modelo de CMSp ($n = 5$) y un grupo de validación del modelo ($n = 10$). Los animales se alimentaron con pasto Kikuyo (*Cenchrus clandestinus*) fresco, el cual era cortado en horas de la mañana y suministrado a cada animal en su comedero. Para estimular el consumo y garantizar la oferta continua de pasto verde, los comederos fueron abastecidos con pasto en tres horarios (a las 8, 12 y 16 horas), previo pesaje para determinar la cantidad ofrecida. Para garantizar un consumo *ad libitum*, las sobras debían corresponder al 20% del alimento suministrado en el día.

El consumo diario de pasto se determinó por diferencia entre el alimento ofrecido y rechazado. Adicionalmente, los animales fueron suplementados al momento del ordeño (5 y 14 horas) con 5.5±0.8 kg de alimento concentrado. Los tiempos de consumo de concentrado no fueron considerados para la construcción del modelo porque las tasas de consumo de pastos y suplementos concentrados son disimiles.

Análisis químico del alimento

Muestras diarias del pasto ofrecido y rechazado fueron colectadas y analizadas en el laboratorio para determinar sus concentraciones de materia seca (MS) por secado en estufa de ventilación forzada a 65° C hasta alcanzar peso constante. Las concentraciones de proteína cruda, fibra en detergente neutro, fibra en detergente ácido, fibra cruda, almidón, extracto etéreo y cenizas en el pasto y el concentrado fueron realizadas a través de espectroscopia de infrarrojo cercano (NIRS). La energía bruta de los alimentos se determino en bomba calorimétrica. En la Tabla 1 se describe la composición química del pasto Kikuyo y el suplemento concentrado consumido por los animales durante el periodo experimental.

Tabla 1: Composición química del pasto Kikuyo (*Cenchrus clandestinus*) y del suplemento concentrado, valores expresados como porcentaje de la materia seca (MS)

Composición	Kikuyo	Concentrado
Materia seca, %	17.1	86.3
Proteína cruda	20.2	16.9
Fibra detergente neutro	58.9	--
Fibra detergente ácido	27.3	--
Fibra bruta	--	5.4
Almidón	--	47.7
Extracto etéreo	3.1	3.9
Materia orgánica	86.5	93.6
Cenizas	13.5	6.4
Energía bruta (Mcal/kg MS)	4.3	4.4

Captura de datos para la construcción del modelo

Los cinco animales del grupo de construcción del modelo de predicción del CMSp portaron un acelerómetro (WitMotion-model BWT61CL) ajustado en la región atlanto-occipital mediante un cabezal. El acelerómetro se programó para medir la posición angular de la cabeza en tres ejes (x, y, z) 14 veces/segundo en periodos de 24 horas. Dado que la predicción del modelo se fundamenta en la asociación entre la posición de la cabeza y la actividad del animal, una aplicación para teléfono celular fue desarrollada. La aplicación se sincroniza con el tiempo de medición del acelerómetro y personal entrenado registra simultáneamente las mediciones del acelerómetro y el comportamiento alimentario del animal ("0" = no consume; "1" = consume). La actividad alimentaria de cada animal fue registrada durante 4 horas continuas por día (0800 a 1200 horas), durante un periodo de 5 días, obteniendo en total 1.008.000 datos/animal/5 días. Posteriormente, las bases de datos de la aplicación móvil y el acelerómetro se fusionaron para ser procesadas (Figura 1).

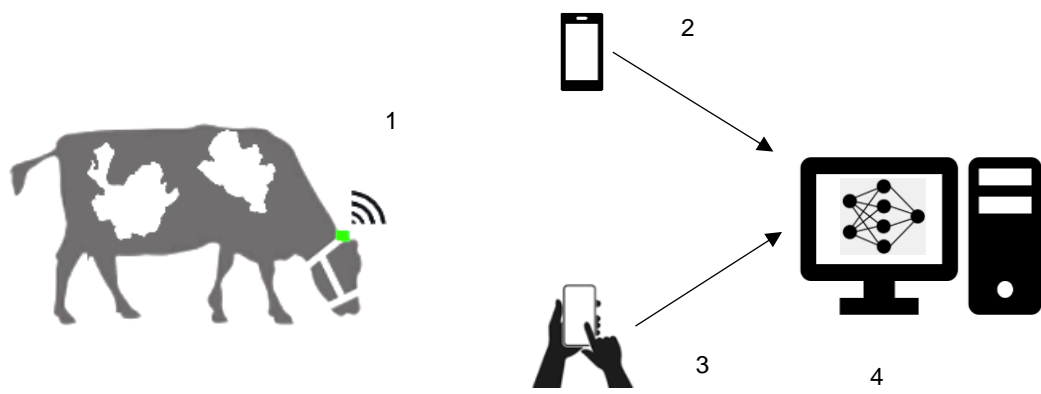


Fig. 1: Captura y flujo de información. Un acelerómetro (1) registra y almacena en un celular (2) la posición angular de la cabeza. Un observador (3) registra la actividad del animal, los datos se fusionan y procesan en un ordenador (4).

Construcción y calibración del modelo

Se diseñó una red neuronal artificial de perceptrón multicapa (RNA) (Villada et al., 2016) capaz de predecir el tiempo de consumo basado en los ángulos de posición de la cabeza. La base de datos para la construcción del modelo fue dividida en dos grupos. El primer conjunto de datos correspondió al 70% de la base de datos y se destinó para el entrenamiento de la RNA, el 30% restante de los datos constituyó el segundo grupo y se empleó para la verificación de la capacidad de predicción de la RNA.

La RNA tuvo la siguiente arquitectura: una neurona de entrada, que correspondió al ángulo de posición de la cabeza en el eje "y", tres capas ocultas con 2, 5 y 1 neuronas, respectivamente y, una neurona de salida correspondiente a la actividad alimentaria del animal (no consume = "0", consume = "1"). El número de capas y neuronas en cada capa fue determinado probando diferentes arquitecturas, estableciendo como criterio de selección la arquitectura con menor número de iteraciones y menor valor del error de predicción. La estructura general del RNA fue:

$$Y_j = \theta \left(\alpha_i + \sum_{i=1}^m \omega_i x_i \right) \tag{1}$$

Donde el j-ésimo valor predicho (Y_j) por la red neuronal corresponde a la sumatoria del producto del i-ésimo valor de entrada (ω_i) por su peso sináptico (x_i) más el sesgo (α_i), multiplicado por una función de activación (θ).

La RNA fue entrenada con el método de aprendizaje supervisado, el cual fundamenta su aprendizaje en la relación entre los valores de entrada y salida, evaluando que tan cerca está su predicción de los valores reales de la variable de salida. El proceso de aprendizaje termina cuando, a través de múltiples iteraciones, la diferencia entre los valores observados y predichos se torna tan pequeña como sea posible (se aproxime al valor cero). Una vez que la RNA fue diseñada para establecer el número de intervalos de tiempo en que el animal se encuentra en la actividad de consumo de pasto, la sumatoria de estos intervalos representa el tiempo de consumo de pasto por día. El tiempo de consumo establecido por la RNA se multiplicó por el factor 0.029 (tasa de consumo (kg/min) determinada en mediciones previas realizadas en el mismo local experimental) para obtener así el CMSp predicho.

Validación del modelo

Para validar el modelo, 10 vacas Holstein, previamente adaptadas a las condiciones experimentales, portaron un acelerómetro (WitMotion-model BWT61CL) que registró la posición angular de su cabeza (14 veces/segundo) en periodos de 24 horas durante cinco días continuos. Los datos registrados por el acelerómetro fueron almacenados en un dispositivo móvil empleando tecnología bluetooth para su posterior análisis (Figura 1). El CMSp observado (real), determinado por diferencia entre la materia seca de pasto ofrecido y rechazado por día, fue comparado con el CMSp predicho por la RNA.

Análisis estadístico

El análisis estadístico de la información fue realizado con ayuda del paquete estadístico R (R Core Team, 2020). Para la construcción de la RNA se empleó la librería neuralnet versión 1.44.2. El desempeño del modelo fue evaluado empleando los siguientes criterios. Raíz del error cuadrático medio (RMSE):

$$RMSE = \sqrt{\left(\frac{\sum_{i=1}^n (O_i - P_i)^2}{n} \right)} \tag{2}$$

Donde n es el número de observaciones, O_i es el i-ésimo valor observado y P_i es el i-ésimo valor predicho por el modelo. Error de predicción relativo (RPE):

$$RPE = \left(\frac{RMSE}{X_0} \right) * 100 \tag{3}$$

Donde X_0 es la media de los valores observados. Error absoluto medio (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \tag{4}$$

Error porcentual absoluto medio (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - P_i}{O_i} \right| * 100 \tag{5}$$

Coefficiente de correlación de concordancia de Lin (CCC):

$$CCC = \frac{2\sigma_{xp}}{\sigma^2_x + \sigma^2_p + (X_o - P_o)^2} \tag{6}$$

Donde, X_o y P_o corresponden a la media de los valores observados y predichos, respectivamente. σ^2_x y σ^2_p son las varianzas de los valores observados y predichos, correspondientemente. σ_{xp} es la covarianza, que se calcula como:

$$\sigma_{xp} = \frac{1}{n} \sum_{i=1}^n (O_i - X_o)(P_i - P_o) \tag{7}$$

Raíz del error de predicción cuadrático medio (RMSPE):

$$RMSPE = \sqrt{\frac{\sum_{i=1}^n \left[\frac{(O_i - P_i)^2}{O_i} \right]}{n - 1}} * 100 \tag{8}$$

Índice de correspondencia (IC):

$$IC = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - X_o| + |O_i - X_o|)^2} \tag{9}$$

RESULTADOS

Los modelos matemáticos que predicen el consumo de materia seca en vacas lecheras se fundamentan en la búsqueda de relaciones lineales entre el consumo y las características del alimento y del animal. El comportamiento alimentario es una variable de naturaleza multifactorial, lo que hace imposible concentrar en un único modelo, todas las variables que condicionan esa respuesta. Este estudio busca establecer que las mediciones realizadas por los acelerómetros concentran todos los efectos de las variables que determinan el consumo y que una RNA es capaz de predecir el consumo de forraje asociando la posición de la cabeza con la actividad alimentaria.

La Figura 2 presenta la arquitectura y parámetros de la RNA. La RNA esta conformada por una capa de entrada de una sola neurona, tres capas ocultas, con 2, 5 y 1 neuronas y una capa de salida correspondiente al valor predicho. El valor de entrada multiplicado por su respectivo peso sináptico determina el “impulso nervioso” que reciben las neuronas en la siguiente capa. Estos valores se procesan en el interior de la red neuronal mediante una función de activación (sigmoidea, tangente hiperbólica, ReLU, softmax, entre otras) que finalmente devuelve un valor de salida o valor predicho. En este experimento, el error estimado de predicción fue de 1.2%, indicando la gran capacidad predictiva del modelo tomando como base la posición angular de la cabeza.

La RNA desarrollada fue capaz de identificar el comportamiento alimentario del animal en periodos de 24 horas conociendo la posición de la cabeza. La sumatoria de los intervalos en que la RNA predice que el animal se encuentra consumiendo alimento, corresponde al tiempo de consumo. Conocido el tiempo que el animal destina a consumir alimento (min/día), este valor se multiplicó por una tasa de consumo expresada en kg de materia seca de forraje / minuto. La tasa de consumo empleada en este experimento fue de 0.029, valor que fue adoptado por ser medido en experimentos previos con este mismo tipo de animales y manejo.

En la Tabla 2 se presentan las variables asociadas al comportamiento alimentario de los animales. El CMSp observado para los animales del grupo de validación del modelo fue de 13.1 kg/día. La RNA predijo un CMSp de 13.8 kg/día, valor 5.34% superior. El uso de acelerómetros permitió determinar que el tiempo destinado al consumo de pasto por las vacas Holstein estabuladas fue 480.4 minutos/día, alcanzando una tasa de ingestión de forraje de 27 g/min. La capacidad de predicción del modelo fue evaluada a través de estadígrafos que permiten determinar el error de predicción y establecer que tan cerca están los valores predichos por el modelo de los valores esperados. En la Tabla 3 se presentan los indicadores estadísticos utilizados para evaluar la capacidad de ajuste y el poder de predicción de la RNA.




Fig. 2: Arquitectura y parámetros de la RNA. ω_i = neurona de entrada; Y_j , = neurona de salida; α_i , $\alpha_{(i+1)}$, $\alpha_{(i+2)}$ y β_k = sesgos de las neuronas en la capa oculta y salida, respectivamente; $X_{(i)} \dots X_{(i+3)}$ = pesos sinápticos.

Tabla 2. Valores medios de variables asociadas al comportamiento alimentario de vacas Holstein estabuladas con sus respectivas desviaciones estándar (DE)

Variable	Media	DE
Consumo materia seca de pasto observado, kg/día	13.1	1.8
Consumo materia seca de pasto predicho, kg/día	13.8	2.1
Tiempo de consumo		
minutos/día	480.4	73.7
minutos /kg de materia seca de pasto	37.4	3.8
minutos/kg de fibra detergente neutro de pasto	63.4	6.4
Tasa de consumo, kg materia seca de pasto/min		
observada	0.029	-
predicha	0.027	0.003

Tabla 3. Criterios para establecer la capacidad de ajuste y el poder de predicción del modelo

Indicador estadístico	Valor
Raíz del error cuadrático medio (RMSE)	1.16
Error de predicción relativo (RPE)	8.82
Error absoluto medio (MAE)	1.06
Error porcentual absoluto medio (MAPE)	8.13
Raíz del error de predicción cuadrático medio (RMSPE)	9.33
Coefficiente de correlación de concordancia (CCC)	0.81
Índice de correspondencia (IC)	0.90

DISCUSIÓN

En este experimento, el CMSp fue estimado multiplicando la tasa de consumo (g de MS/minuto) por el tiempo destinado al consumo de alimento. La tasa de consumo y el tiempo de consumo son afectados por variables asociadas a las características del animal y la pastura. Grant y Albright (2000) agrupando múltiples investigaciones, indicaron que las vacas lecheras manejadas en confinamiento y alimentadas con dietas tipo TMR gastaron entre 248 y 392 min/día consumiendo alimento. Johnston y DeVries (2018) evaluando la asociación entre el comportamiento alimentario y la producción de leche en vacas Holstein, reportaron tiempos de consumo de 279.6 ± 51.7 minutos. Los tiempos de consumo reportados por estos autores difieren de los encontrados en esta investigación (480.4 ± 73.7 minutos) (Tabla 2). Esta disparidad en los tiempos de consumo puede ser explicada por diferencias en los contenidos de FDN entre de las dietas. Mayores concentraciones de FDN en la pastura son responsables por un mayor número de masticaciones por kg de materia seca ingerida, mayores tiempos de retención ruminal, lentas tasas de pasaje y menores consumos (Arelovich et al., 2008). Las dietas tipo TMR reportadas por Grant y Albright (2000) y Johnston y DeVries (2018) presentaron contenidos de FDN entre 32 y 35%, en tanto que el pasto consumido por los animales de este experimento registró un valor de 58.9%. Incrementos en los tiempos de consumo asociados a incrementos en los contenidos de FDN de la dieta han sido reportados por Zebeli et al. (2007) y Adin et al. (2009).

Las pasturas tropicales se caracterizan por sus altos contenidos de FDN que condicionan variables como la tasa de consumo, el número de masticaciones y la cantidad de MS y FDN ingeridos por minuto. Trabajos realizados por Costa et al., (2015) y Santana et al., (2020) trabajando con vacas cruzadas (Gir x Holstein) y Holstein que consumieron dietas con valores de FDN superiores al 55% encontraron tiempos de consumo que variaron entre 436 y 576 minutos. El tiempo de consumo estimado por la RNA se ubicó dentro de este rango (480.4 ± 73.7 minutos). Bargo et al., (2003) en una extensa revisión de literatura relacionando el efecto de la suplementación concentrada sobre el comportamiento alimentario de vacas Holstein en pastoreo reportan tasas de consumo de 0.025 kg de MS/minuto, valor ligeramente inferior al encontrado en este trabajo (0.027 kg de MS/minuto) con pasto Kikuyo.

Diferentes criterios de comparación entre los datos observados y los predichos por la RNA fueron determinados. El RMSE es una métrica que determina la distancia promedio entre los valores predichos por el modelo y los valores reales en el conjunto de datos, por tanto, cuanto menor sea su valor, mejor será el ajuste del modelo. El valor calculado para este parámetro nos muestra que la diferencia media entre los consumos observados y los predichos por la RNA fue de 1.16 kg MS/día. Diferentes autores evaluando modelos empíricos utilizados para predecir el CMS en vacas lecheras reportan errores de predicción que varían entre 1.62 y 3.85 kg MS/día (Krizsan et al., 2014; Jensen et al., 2015) A pesar de que el error de predicción de la RNA (1.16 kg MS/día) fue menor al reportado para modelos empíricos citados en este trabajo, es necesario considerar que una mejor estimativa de este parámetro requiere un mayor volumen de información.

El RPE representa la RMSE pero expresada en términos porcentuales respecto el valor medio observado, indicando que los valores predichos por la RNA se desviaron de los valores reales en un 8.82% (Tabla 3). Porcentajes superiores a los encontrados en este trabajo son reportados por Carruthers y Brayant (1983) y De Souza et al., (2014) que evaluando el uso de marcadores indigestibles para predecir el CMS en vacas lecheras concluyen que estas metodologías sobreestiman el consumo en un rango que varía entre -0.59% y 29.5%. Los autores concluyen que esta amplia variación se debe a los bajos porcentajes de recuperación de los marcadores (< 92%) y sesgos asociados la determinación de la digestibilidad requerida para la estimación del CMS. El MAE corresponde a la media de los errores absolutos y se obtiene del promedio de las diferencias absolutas entre la predicción y la observación real, donde todas las diferencias individuales tienen el mismo peso, sin importar si el modelo sobre o subestima el valor real. En este estudio el valor del MAE indica que la RNA se aleja de los valores reales en 1.06 kg MS/día.

El MAPE y la RMSPE son indicadores de evaluación críticos empleados para evaluar la capacidad de ajuste y precisión del modelo. Criterios de interpretación de estos parámetros son discutidos por DeLurgio (1998). De acuerdo con este autor, valores de MAPE y RMSPE <10% corresponden a modelos con alta precisión de predicción, en tanto que valores entre 10–20% se asocian con buena capacidad de predicción, entre 20–50% con razonable capacidad de predicción y superiores al 50% con limitada capacidad de predicción. Los valores de MAPE (8.13%) y RMSPE (9.33%) encontrados para la RNA en este estudio permiten concluir que el modelo presentó alta precisión de predicción.

El coeficiente de correlación de concordancia (CCC) varía entre 0 y 1, y mide simultáneamente la precisión y la exactitud de la predicción del modelo frente al conjunto de datos observados. Landis y Koch (1977) indican que CCC iguales a 0 son indicativos de no concordancia, entre 0-0.20 concordancia insignificante, 0.21-0.40 baja concordancia, 0.41-0.60 concordancia moderada, 0.61-0.80 concordancia sustancial, y entre 0.81-1 muy

buena concordancia. El CCC de la RNA fue de 0.81, indicando que el modelo posee un alto grado de convergencia, ajuste y poder predictivo. Esta afirmación también es soportada por el valor del IC (0.90). El IC al igual que el CCC varía entre 0 y 1, un valor de 1 indica coincidencia perfecta y un valor de 0, divergencia completa entre los valores observados y predichos. Krizsan et al., (2014) evaluando cinco modelos empíricos para la predicción del consumo de materia seca en vacas lecheras, reportan CCC que varían entre 0.52 y 0.85; el CCC del presente estudio se aproxima al valor superior del reportado por este autor.

La RNA construida demostró ser capaz de predecir con precisión y exactitud la actividad alimentaria del animal basada en la posición de la cabeza. La RNA aprende a través de un proceso iterativo (entrenamiento) en el que examina los registros individuales, genera una predicción para cada registro y en función del resultado que obtenga, se modifican los pesos de las neuronas (Figura 2). El proceso se repite hasta lograr el menor error de predicción. La eficiencia de la RNA fue claramente establecida a través de diferentes criterios estadísticos (Tabla 3).

Bargo et al (2003) en su revisión de literatura, resumen el comportamiento alimentario de vacas Holstein en pastoreo, reportando un número de bocados por día promedio de 34963. Asumiendo una frecuencia de 1.2 bocados por segundo (Oudshoorn et al., 2013), los animales en este estudio presentaron un número total de bocados por día de 34589, valor próximo del reportado por Bargo et al., (2003). Conociendo el número de bocados por día (34589) y el tiempo de consumo (480.4 min) es posible estimar el número de bocados por minuto (69.6). Valores de la literatura reportan 63.9 bocados por minuto para vacas Holstein en condiciones de pastoreo (Bargo et al., 2003).

Diferentes métodos que incluyen la determinación de la biomasa de la pastura antes y después del pastoreo, el uso de marcadores indigestibles y cambios en el peso corporal de los animales se han empleado para determinar el consumo de materia seca de vacunos (Decruyenaere et al., 2009). Los resultados de este trabajo demuestran que variables asociadas con el comportamiento animal también pueden ser empleadas para tal fin. Esta afirmación es corroborada por Carpinelli et al., (2019), que evaluando el uso de acelerómetros para estimar el CMS en vacas Holstein, manifiestan que las vacas tienen movimientos específicos altamente correlacionados con el consumo de alimento, lo que hace posible la construcción de modelos de predicción. Simanungkalit et al., (2021) empleando acelerómetros en el cuello y la oreja de vacas tipo carne, reportan que los acelerómetros ubicados en el cuello generan señales más consistentes de aceleración y orientación de la cabeza. Estos mismos autores modelando los datos generados por los acelerómetros con algoritmos de aprendizaje automático, lograron determinar el comportamiento alimentario con una exactitud que varió entre el 88 y 98%.

La creciente oferta de dispositivos electrónicos de bajo costo y mayores capacidades de computo y análisis de datos hacen que sea posible realizar un seguimiento individualizado de los animales dentro del rebaño. En este estudio, los acelerómetros se mostraron eficientes para predecir el consumo de materia seca de forraje, variable fundamental para ajustar los planes de alimentación, proyectar las necesidades de forraje, establecer las áreas de pastoreo, programar la rotación de praderas y calcular la eficiencia de utilización de la pastura, factores que impactan en gran medida sobre el desempeño animal.

CONCLUSIÓN

Basados en los diferentes criterios de evaluación, concluimos que el CMSp puede ser determinado con muy buena precisión y exactitud utilizando acelerómetros. La significativa correlación entre la posición de la cabeza y el comportamiento alimentario del animal permitió construir un modelo de predicción robusto que haciendo uso de las tecnologías actuales puede determinar el consumo de alimento de forma rápida y a bajo costo en comparación con los métodos tradicionales.

AGRADECIMIENTOS

Los autores manifiestan su agradecimiento al Ministerio de Ciencia, Tecnología e Innovación – Minciencias de la República de Colombia por la financiación de este trabajo a través de los proyectos 58414 (convocatoria 745 de 2016) y 66737 (convocatoria 836-2019).

REFERENCIAS

- Adin, G., Gelman, A., y otros 9 autores, Effects of Cooling Dry Cows under Heat Load Conditions on Mammary Gland Enzymatic Activity, Intake of Food Water, and Performance during the Dry Period and after Parturition, <https://doi.org/10.1016/j.livsci.2009.01.014>, *Livest. Sci.*, 124, 189-195 (2009)
- Arcidiacono, C., Porto, S.M.C., Mancino, M., y Cascone, G., Development of a threshold-based classifier for real-time recognition of cow feeding and standing behavioural activities from accelerometer data, <https://doi.org/10.1016/j.compag.2017.01.021>, *Comput. Electron. Agric.*, 134, 124e134 (2017)

- Arelovich, H.M., Abney, C.S., Vizcarra, J.A., y Galyean, M.L., Effects of Dietary Neutral Detergent Fiber on Intakes of Dry Matter and Net Energy by Dairy and Beef Cattle: Analysis of Published Data, [https://doi.org/10.15232/S1080-7446\(15\)30882-2](https://doi.org/10.15232/S1080-7446(15)30882-2), *Prof. Anim. Sci.*, 24(5), 375-383 (2008)
- Bargo, F., Muller, L.D., Kolver, E.S., y Delahoy, J.E., Invited review: Production and Digestion of Supplemented Dairy Cows on Pasture, [https://doi.org/10.3168/jds.S0022-0302\(03\)73581-4](https://doi.org/10.3168/jds.S0022-0302(03)73581-4), *J. Dairy Sci.*, 86, 1-42 (2003)
- Bidder, O.R., Campbell, H.A., y otros 7 autores, Love thy neighbour: Automatic animal behavioural classification of acceleration data using the k-nearest neighbour algorithm, <https://doi.org/10.1371/journal.pone.0088609.g001>, *PLoS ONE*, 9(2), e88609 (2014)
- Carpinelli, N. A., Rosa, F., Graziotin, R. C. B., y Osorio, J. S., Technical note: A Novel Approach to Estimate Dry Matter Intake of Lactating Dairy Cows Through Multiple on-cow Accelerometers, <https://doi.org/10.3168/jds.2019-16537>, *J. Dairy Sci.*, 102(12):11483-11490 (2019)
- Carruthers, V. R., y Bryant, A. M., Evaluation of the Use of Chromic Oxide to Estimate the Feed Intake of Dairy Cows, <https://doi.org/10.1080/00288233.1983.10427057>, *New Zealand J. Agric. Res.*, 26(2), 183-186 (1983)
- Costa, E.I., Carvalho, G.G., y otros 6 autores, Feeding Behavior and Responses in Grazing Lactating Cows Supplemented with Peanut Cake, <https://doi.org/10.1590/S1806-92902015000400002>, *Braz. J. Anim. Sci.*, 44, 138-145 (2015)
- Decruyenaere, V., Buldgen, A. y Stilmant, D., Factors Affecting Intake by Grazing Ruminants and Related Quantification Methods: A Review, *Biotechnol. Agron. Soc. Environ.*, ISSN 1370 6233, 13(4), 559-573 (2009)
- DeLurgio, S.A., *Forecasting Principles and Applications* by Hercher, D., 802, ISBN:6-256-13433-2, McGraw-Hill Education, Burr Ridge, IL, USA (1998)
- De Souza, J., Batistel, F., y otros 4 autores, Evaluation of External Markers to Estimate Fecal Excretion, Intake, and Digestibility in Dairy Cows, <https://doi.org/10.1007/s11250-014-0674-6>, *Trop. Anim. Health Prod.*, 47(1), 265-268 (2014)
- De Souza, R.A., Tempelman, R.J., Allen, M.S., y VandeHaar, M.J., Updating Predictions of Dry Matter Intake of Lactating Dairy Cows, <https://doi.org/10.3168/jds.2019-16176>, *J. Dairy Sci.*, 102, 7948-7960 (2019)
- Dulphy, J. P., y Demarquilly, C., The Regulation and Prediction of Feed Intake in Ruminants in Relation to Feed Characteristics, [https://doi.org/10.1016/0301-6226\(94\)90147-3](https://doi.org/10.1016/0301-6226(94)90147-3), *Livest. Prod. Sci.*, 39(1), 1-12 (1994)
- Evangelista, C., Basiricò, L., y Bernabucci, U., An Overview on the Use of Near Infrared Spectroscopy (NIRS) on Farms for the Management of Dairy Cows, <https://doi.org/10.3390/agriculture11040296>, *Agriculture*, 11, 296 - 327 (2021)
- Grinter, L.N., Campler, M.R., y Costa, J.H.C., Technical note: Validation of a Behavior-Monitoring Collar's Precision and Accuracy to Measure Rumination, Feeding, and Resting Time of Lactating Dairy Cows, <https://doi.org/10.3168/jds.2018-15563>, *J. Dairy Sci.*, 102 (4), 3487-3494 (2019)
- Grant, R. J., y Albright, J.L., *Feeding behaviour, Farm Animal Metabolism and Nutrition* by D'Mello, J.P., 365-382, CABI Publishing, ISBN: 0851993788, Wallingford, Oxon, UK (2000)
- Jensen, L. M., Nielsen, N. I., y otros tres autores, Evaluation of Five Models Predicting Feed Intake by Dairy Cows Fed Total Mixed Rations, <https://doi.org/10.1016/j.livsci.2015.03.026>, *Livest. Sci.*, 176, 91-103 (2015)
- Johnston, C., y DeVries, T.J., Short Communication: Associations of Feeding Behavior and Milk Production in Dairy Cows, <https://doi.org/10.3168/jds.2017-13743>, *J. Dairy Sci.*, 101(4), 3367-3373 (2018)
- Krizsan, S. J., Sairanen, A., Höjer, A., y Huhtanen, P., Evaluation of different feed intake models for dairy cows, <https://doi.org/10.3168/jds.2013-7561>, *J. Dairy Sci.*, 97(4), 2387-2397 (2014).
- Landis, J.R., y Koch, G.G., The Measurement of Observer Agreement for Categorical Data, <https://doi.org/10.2307/2529310>, *Biometrics*, 33, 159-174 (1977)
- Lovarelli, D., Bacenetti, J., y Guarino, M., A review on dairy cattle farming: Is precision livestock farming the compromise for an environmental, economic and social sustainable production?, <https://doi.org/10.1016/j.jclepro.2020.121409>, *J. Clean. Prod.*, 262, 1-13 (2020)
- Macon, B., Sollenberger, L.E., y otros 4 autores, Comparison of three Techniques for Estimating the Forage Intake of Lactating Dairy Cows on Pasture, <https://doi.org/10.2527/2003.8192357x>, *J. Anim. Sci.*, 81:2357-2366 (2003)
- Mayes, R.W., y Dove, H., Measurement of Dietary Nutrient Intake in free-ranging Mammalian Herbivores, <https://doi.org/10.1079/095442200108729025>, *Nutr. Res. Rev.* 13: 107-138 (2000)
- Mazumder, M., y Kumagai, H., Analyses of Factors Affecting Dry Matter Intake of Lactating Dairy Cows, <https://doi.org/10.1111/j.1740-0929.2006.00320.x>, *Anim. Sci. J.*, 77(1), 53-62 (2006)
- Oudshoorn, F.W., Cornou, C., y otros 5 autores, Estimation of Grass Intake on Pasture for Dairy Cows using Tightly and Loosely Mounted di- and tri-axial Accelerometers combined with Bite Count, <https://doi.org/10.1016/j.compag.2013.09.013>, *Comput. Electron. Agric.*, 99, 227-235 (2013)
- R Core Team, *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, <https://www.R-project.org/> (2020)

Santana, P.F., Rocha, V.R., y otros 8 autores, Nutritional, Behavioral and Performance Parameters of F1 Holstein X Zebu Cows at different Lactation Stages, <https://doi.org/10.1590/1678-4162-11659>, Arq. Bras. Med. Vet. Zootec., 72(04), 1469-1478 (2020)

Simanungkalit, G., Barwick, J., y otros 3 autores, A Pilot Study Using Accelerometers to Characterize the Licking Behaviour of Penned Cattle at a Mineral Block Supplement, <https://doi.org/10.3390/ani11041153>, Animals, 11, 1153 - 1168 (2021)

Velásquez, A. V., da Silva, G. G., y otros 7 autores, Evaluating internal and external markers versus fecal sampling procedure interactions when estimating intake in dairy cows consuming a corn silage-based diet, <https://doi.org/10.3168/jds.2017-13283>, J. Dairy Sci., 101(7), 5890-5901 (2018)

Villada, F., Muñoz, N., y García-Quintero, E., Artificial neural networks applied to the prediction of the gold price, <https://doi.org/10.4067/S0718-07642016000500016>, Inf.Tecnol., 27(5), 143-150 (2016)

Zebeli, Q., Tafaj, M., y otros 4 autores, Effects of Varying Dietary Forage Particle Size in two Concentrate Levels on Chewing Activity, Ruminal Mat Characteristics, and Passage in Dairy Cows, <https://doi.org/10.3168/jds.2006-354>, J. Dairy Sci., 90(4), 1929-1942 (2007)