

ANÁLISIS DE LA COMPOSICIÓN DE LA LECHE EN TIEMPO REAL MEDIANTE UN SENSOR DE INFRARROJO CERCANO *IN-SITU*

Díaz-Olivares¹, J.A., Adriaens^{1,2}, I., Stevens³, E., Saeys², W. y Aernouts¹, B.

¹KU Leuven, Department of Biosystems, Biosystems Technology Cluster, Campus Geel, Kleinhoefstraat 4, 2440 Geel, Belgica; ²KU Leuven, Department of Biosystems, Division Mechatronics, Biostatistics and Sensors, Kasteelpark Arenberg 30, 3001 Leuven, Belgica; ³Province of Antwerp, Hooibeekhoeve, Hooibeeksedijk 1, 2440 Geel, Belgica; jose.diaz@kuleuven.be

INTRODUCCIÓN

La monitorización de la composición de la leche, cuando esta se realiza *in-situ*, puede ayudar a controlar el metabolismo y la salud de las ubres de las vacas lecheras. En estudios anteriores, la espectroscopia de infrarrojo cercano (NIR, en inglés), aplicada al análisis de la leche, ha demostrado ser útil para predecir los principales componentes de la leche cruda (grasa, proteína y lactosa). En esta contribución, se presenta y evalúa una herramienta precisa para el análisis de la composición de la leche en la granja *in-situ* y en tiempo real.

MATERIAL Y MÉTODOS

Para cada ordeño, el analizador en tiempo real recopila y analiza automáticamente una muestra de leche representativa. El sistema adquiere los espectros de transmisión NIR de las muestras de leche en el rango de longitud de onda de 960 a 1690 nm y luego predice su composición. Durante un período de prueba de 8 semanas, el sistema recopiló 1165 espectros de transmitancia NIR de muestras de leche cruda procedentes de 36 vacas, para las cuales también se obtuvieron valores de referencia para grasa, proteína y lactosa. Para el mismo sistema sensor en tiempo real se evaluaron dos escenarios de calibración: modelos de predicción *post-hoc* entrenados en un conjunto representativo de muestras de calibración ($n = 319$), adquiridas durante todo el período de prueba con diferentes vacas en el conjunto de prueba y calibración; y modelos de predicción entrenados en tiempo real exclusivamente con las muestras adquiridas en la primera semana del período de prueba ($n = 308$).

RESULTADOS Y DISCUSIÓN

Los modelos de predicción obtenidos se evaluaron en todas las muestras restantes no incluidas en los conjuntos de calibración (siendo $n = 846$ y 857 , respectivamente). En concreto, para los modelos de predicción *post-hoc*, esto resultó en un error de predicción general (error cuadrático medio de predicción, RMSEP en inglés) menor a 0.080% (todos los % están en peso/peso) para la grasa, proteína y lactosa en leche, con un coeficiente de determinación R^2 de 0.989, 0.947 y 0.689 para grasa, proteína y lactosa, respectivamente. Por otro lado, para los modelos de predicción en tiempo real, el RMSEP fue menor a 0.092% para la grasa y lactosa, y 0.110% para la proteína, con un R^2 de 0.989 (grasa), 0.894 (proteína) y 0.644 (lactosa). Las predicciones de lactosa para este modelo podrían mejorarse (RMSEP = 0.088%, $R^2 = 0.675$) tomando en cuenta el sesgo específico de cada vaca.

CONCLUSIÓN

El sistema sensor presentado, centrado en la predicción en tiempo real, puede utilizarse para una monitorización detallada y autónoma de la composición de la leche *in-situ* después de cada ordeño individual, ya que su precisión está dentro de los requisitos del Comité Internacional de Registro Animal (ICAR, en inglés) para analizadores de leche *in-situ*, e incluso cumple con los estándares para sistemas de análisis de laboratorio para grasa y lactosa. Para este enfoque de predicción en tiempo real se observó una desviación en las predicciones, especialmente para las proteínas. Por tanto, se requiere más investigación para el desarrollo de técnicas de mantenimiento de calibración en tiempo real para corregir esta desviación del modelo y mejorar el rendimiento de este sistema sensor.

REFERENCIAS BIBLIOGRÁFICAS

- Abd El -Fattah, A.M. 2012. BMC Vet. Res. 8, 19.
- Aernouts, B. 2011. J. Dairy Sci. 94, 5315–5329.
- Aernouts, B. 2015. Colloids Surfaces B Biointerfaces 126, 510–519.
- Aernouts, B. 2015. J. Dairy Sci. 98, 6727–6738.
- Bogomolov, A. 2013. Chemom. Intell. Lab. Syst. 126, 129–139.
- Forsbäck, L. 2010. J. Dairy Sci. 93, 3569–3577.
- Haaland, D.M. 1988. Anal. Chem. 60, 1193–1202.
- Kawamura, S. 2007. Sens. Instrum. Food Qual. Saf. 1, 37–43.
- Kawasaki, M. 2008. Comput. Electron. Agric. 63, 22–27.
- Melfsen, A. 2012. J. Dairy Sci. 95, 6465–6476.
- Saeys, W. 2008. Anal. Chem. 80, 4951–4959.
- Saranwong, S. 2008. Near Infrared Spectrosc. 16, 389–398.
- Tsenkova, R. 2001. Int. Dairy J. 11, 779–783.
- Zamora-Rojas, E. 2013. Food Sci. Emerg. Technol. 19, 218–226.