

Artículo de divulgación

Método accesible para identificar adulteración en leche con IA y análisis morfológico

Affordable method to identify milk adulteration using AI and morphological analysis

Josías N. Molina-Courtois ^{1,3} , Yojana J. P. Carreón ^{2,3} , Jorge González-Gutiérrez ³ , Mario Castelan ^{1, *} 

¹ Robótica y Manufactura Avanzada, Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, Ramos Arizpe 25900, Coahuila, México.

² Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI), Ciudad de México 03940, México.

³ Facultad de Ciencias en Física y Matemáticas, Universidad Autónoma de Chiapas, Tuxtla Gutiérrez 29050, Chiapas, México.

* Autor para correspondencia: mario.castelan@cinvestav.edu.mx

Recibido:

31/10/2025

Aceptado:

28/03/2026

Publicado:

1/05/2026

RESUMEN

La leche es un alimento esencial para el ser humano, por lo que detectar su adulteración de manera rápida y confiable es una necesidad prioritaria en el control de calidad alimentaria. En este trabajo se presenta un método novedoso y accesible para la detección de adulterantes en leche, basado en el análisis de gotas secas combinado con inteligencia artificial (IA). Se emplearon muestras de leche entera y deslactosada adulteradas con diferentes concentraciones de agua y formuladas con distintas concentraciones de sal. La hipótesis del estudio propone que la adición controlada de sal puede promover la formación de patrones en las muestras de leche, facilitando su diferenciación mediante herramientas computacionales. La complejidad de los depósitos secos se evaluó mediante análisis de lagunaridad y aprendizaje profundo. Ambos métodos alcanzaron una alta precisión, superior al 99 % en muestras con 2 % de sal. En condiciones más complejas (4 % de sal), la precisión del modelo de IA aumentó del 79 % al 91 %. Los resultados confirman que la combinación de métricas morfológicas y redes neuronales permite identificar variaciones de adulteración imperceptibles para el ojo humano. La detección temprana de adulteración es un tema importante en ganadería ya que ayuda a resguardar el valor nutricional de la leche y sostiene a los productores que dependen de una cadena láctea justa y confiable.

Palabras clave: Adulteración de Leche; Lagunaridad; Gotas Secas; Redes Neuronales Convolucionales; Inteligencia Artificial.

ABSTRACT

Milk is an essential food for human development, so rapid and reliable detection of adulteration is a priority in food quality control. This work presents a novel and low-cost method for identifying adulterants in milk based on dry-drop analysis combined with artificial intelligence. Whole and lactose-free milk samples were adulterated with different water concentrations and formulated with different salt concentrations. The study proposes that controlled salt addition promotes the formation of patterns in the dried samples, which



supports their differentiation through computational tools. The complexity of the dry deposits was evaluated using lacunarity analysis and deep learning. Both methods reached high accuracy, above 99 percent in samples with 2 percent salt. In more challenging conditions with 4 percent salt, the accuracy of the AI model increased from 79 percent to 91 percent. The results confirm that combining morphological metrics and neural networks makes it possible to detect adulteration levels that are imperceptible to the human eye. Early detection supports milk nutritional value and protects producers who rely on a fair and trustworthy dairy supply chain.

Keywords: Milk Adulteration; Lacunarity; Dried Droplets; Convolutional Neural Networks; Artificial Intelligence.

INTRODUCCIÓN

La leche es un alimento básico en la mayoría de las culturas, especialmente importante durante los primeros años de vida. Sin embargo, en las últimas décadas, se ha convertido en uno de los productos más adulterados. Se han documentado casos en los que se le añade agua, almidón, urea, melamina o incluso detergente, con el fin de aumentar su volumen o mejorar su apariencia. Para detectar este tipo de adulteraciones existen técnicas altamente sofisticadas, entre ellas la cromatografía, la espectroscopía y los sensores electroquímicos (Nascimento et al., 2017). No obstante, sigue siendo necesario contar con métodos accesibles y confiables que permitan identificar alteraciones sin depender de laboratorios especializados.

Uno de estos métodos es la evaporación de las gotas. Cuando una gota, ya sea de agua, café o refresco, cae sobre una superficie, esperamos que se evapore. Apartamos la vista y, al volver la mirada, ya no está. En su lugar, ha quedado una mancha. Esa mancha, también conocida como depósito, puede contener mucha información. Si nos fijamos en la forma, el color, la textura, e incluso en cómo refleja la luz, probablemente podamos adivinar qué se ha derramado.

Si fotografiamos la mancha que dejó la gota al secarse, obtendremos una imagen digital que puede ser analizada automáticamente. En lugar de depender del ojo humano, sería posible aplicar técnicas estadísticas, físicas y computacionales que permitieran identificar el líquido que la originó.

Gracias a la inteligencia artificial (IA), un modelo computacional puede aprender a reconocer patrones a partir de las estructuras que se forman dentro de los

depósitos, sin que nadie le indique qué buscar. Para ello se utilizan las redes neuronales convolucionales, una herramienta que permite a las computadoras reconocer formas o patrones dentro de una imagen. Lo que nosotros vemos como una figura continua, la máquina lo interpreta como una matriz de datos, en la que cada píxel ocupa un lugar específico. La convolución consiste en realizar operaciones de suma y multiplicación sobre esa matriz, lo que permite al modelo computacional analizar la imagen desde distintos ángulos y resaltar detalles que a simple vista pasarían desapercibidos. Mediante esta herramienta, es posible analizar cientos o miles de ejemplos para detectar diferencias que a simple vista parecen invisibles. De este modo, se pueden clasificar distintos líquidos, aunque todos los depósitos parezcan similares.

Los patrones que se observan en estas manchas se originan a partir de estructuras internas que se forman dentro de la gota durante el proceso de evaporación. En algunos casos, es necesario añadir un aditivo que favorezca la formación de estructuras más complejas y repetibles. Uno de los más utilizados es el cloruro de sodio, también conocido como sal, ya que es químicamente estable y permite generar patrones bien delimitados que se repiten cada vez que se seca el mismo líquido. Esa repetición es clave para poder comparar y clasificar con precisión.

Entre los patrones más conocidos está el famoso anillo de café (ver Figura 1), el cual, gracias a los flujos capilares, se forma cuando las partículas suspendidas en el líquido son arrastradas hacia el borde por flujos internos. También existen flujos opuestos, como los de Marangoni, que empujan las partículas hacia el centro, produciendo depósitos secos más homogéneos. Ambos flujos compiten durante el secado, y es la composición química del líquido



la que determina cuál de ellos dominará (Mampallil and Eral, 2018).



Figura 1. Gota seca de leche entera pura. Se observa una periferia prominente, conocida como anillo de café.

¿Por qué nos interesan tanto estos patrones? Porque si una gota siempre deja una forma específica y, de pronto, aparece otra distinta, algo ha cambiado. Esa diferencia puede indicar una posible adulteración.

En este artículo, basado en los resultados de Molina-Courtois et al., 2025, se presenta un método accesible para detectar adulteraciones en la leche, basado en el análisis de los patrones formados al evaporarse pequeñas gotas. Primero se empleó la lagunaridad como herramienta para cuantificar la complejidad de estas manchas. Luego, se combinó esta técnica con aprendizaje profundo, entrenando un modelo con imágenes de leche adulterada añadiendo distintas proporciones de agua y sal. Esto permitió identificar alteraciones con alta precisión, incluso cuando las diferencias eran imperceptibles en las imágenes obtenidas con microscopio.

CÓMO HACER QUE LAS GOTAS FORMEN PATRONES

Como se mencionó anteriormente, muchos líquidos requieren ciertos aditivos para formar patrones que nos ayuden a extraer más información. Diversos estudios han demostrado que la adición de sal facilita la aparición de estructuras repetibles y bien definidas, incluso en soluciones alcohólicas y formulaciones farmacéuticas (González-Gutiérrez et al., 2017; Carreón et al., 2021). En el caso de la leche entera y deslactosada, las gotas secas tienden a formar manchas homogéneas, lisas y sin

estructuras aparentes. Por ello, se añade sal, lo que favorece la aparición de patrones más complejos y distinguibles, como se aprecia en la Figura 2.

Para poder asignar un valor numérico a estos nuevos patrones, es necesario utilizar herramientas de análisis. En nuestro caso, empleamos la lagunaridad, una medida especialmente útil para describir estructuras visuales. Como su nombre sugiere, la lagunaridad nos indica cuántos huecos tiene una imagen y cómo están distribuidos. Un valor alto corresponde a una estructura compleja, con vacíos y texturas variadas; un valor bajo indica una mancha más uniforme y lisa.

La lagunaridad ha demostrado efectividad en la detección de patrones en múltiples contextos, desde el análisis del movimiento de espermatozoides hasta la identificación de ciertos tipos de tumores (Ríos-Ramírez et al., 2018; Sy et al., 2022). Aunque a simple vista podemos notar algunas diferencias entre las manchas, el uso de esta medida permite obtener indicadores objetivos y cuantificables.

Pero ¿qué pasaría si dejamos que una computadora haga todo este trabajo por nosotros? Para eso, desarrollamos un algoritmo basado en redes neuronales convolucionales, capaz de distinguir entre distintos tipos de leche. Trabajos previos (Harindran et al., 2022; Mamgain et al., 2024), ya habían mostrado que este tipo de redes son eficaces para detectar leche adulterada. Sin embargo, al incorporar sal como revelador de patrones, logramos mejorar la precisión de la detección de adulterantes, logrando identificar diferencias sutiles entre muestras que, visualmente, parecían casi idénticas. Además, este enfoque tiene el potencial de generalizarse para detectar otros contaminantes en líquidos.

Las redes neuronales, en esencia, aprenden a partir de ejemplos. En nuestro caso, utilizamos alrededor de 120 imágenes de gotas secas con sal para cada tipo de muestra. Trabajos previos, como los de Acuña et al. (2023), habían demostrado que el análisis de regiones de interés dentro de gotas secas de diluciones de *Viscum album* puede mejorar significativamente la detección de patrones en fármacos basados en plantas.



En el presente estudio, empleamos la lagunaridad como descriptor, así como criterio para seleccionar las regiones de interés más relevantes dentro de cada imagen. A partir de dichas regiones, generamos miles de fragmentos, o parches, que son analizados por separado. Cada parche aporta datos únicos, lo que multiplica la cantidad de información útil. Así, la IA no solo observa lo que vemos, sino que descubre patrones que no sabíamos que están ahí.

DE LA EVAPORACIÓN A LA CLASIFICACIÓN

Algo extraordinario de la técnica que planteamos es que no requiere equipo especializado ni laboratorios complejos. Solo se necesita una caja donde depositar las

Para este estudio se utilizó un catálogo de gotas secas de leche elaborado específicamente para esta investigación. El catálogo contiene mil novecientos sesenta y cuatro imágenes de gotas secas de leche entera y deslactosada, con un volumen de 3 microlitros, depositadas sobre láminas de polimetilmetacrilato (acrílico). Las muestras se secaron bajo condiciones controladas de temperatura (entre 22 y 24 °C) y humedad relativa (entre 30 y 35 %). Se prepararon con diferentes niveles de adulteración: se añadieron 0 %, 20 %, 40 %, 60 % y 80 % de agua, y también se incorporaron concentraciones de sal del 0 %, 2 % y 4 %.

Una vez obtenidas las imágenes, utilizamos la lagunaridad de dos formas principales: primero, para comparar numéricamente los patrones formados por las




Figura 2. Gotas secas de leche entera y deslactosada con 0 %, 2 % y 4 % de sal, y diluidas al 0 %, 60 % y 80 %.

gotas para que se sequen, un microscopio, una cámara y una computadora. Aunque pueda parecer mucho, estos elementos son comunes en muchos laboratorios básicos, y su costo es muy inferior al de otros métodos de análisis, que pueden requerir equipos como espectrómetros de masas o sistemas de cromatografía líquida, cuyo valor supera varios miles de dólares.

diferentes mezclas; y segundo, para identificar las regiones de interés (ROIs) más representativas de cada imagen. A partir de estas regiones, se generaron miles de fragmentos o parches que alimentaron el modelo de IA.

Con esas regiones seleccionadas, se entrenó la red neuronal convolucional DenseNet121 con las miles de ROIs extraídas de las imágenes.

LO QUE LAS GOTAS REVELARON

En la figura 2 podemos ver los depósitos secos de las gotas de leche, es decir, las manchas que dejó la gota al evaporarse. A simple vista, notamos que tanto la leche entera como la deslactosada, sin sal añadida (0 %), no forman estructuras visibles; se trata de manchas homogéneas, con apenas algunos cambios sutiles en el color. Sin embargo, tenemos la presencia del patrón anillo de café. Esto ya nos aporta cierta información, pero cuando observamos las gotas con 2 % de sal, sin dilución en agua, aparecen pequeñas acumulaciones que podrían parecer grumos (denotados con flechas naranjas), pero que en realidad son cristales formados por la unión ordenada de los iones de sal.

Al aumentar el contenido de agua (60 % y 80 %), la leche pierde componentes como grasas y proteínas, lo que permite a la sal organizarse con mayor libertad. Así, comienzan a aparecer estructuras más complejas, similares a hojas ramificadas. A estos patrones se les conoce como dendritas (denotados con flechas verdes en la figura 2). Finalmente, en las muestras con 4 % de sal, observamos una saturación de estas estructuras, es decir, la mancha está dominada casi por completo por las dendritas, que se extienden por toda la superficie.

Ahora que contamos con estructuras más complejas, pasamos al análisis de lagunaridad. Como se muestra en las gráficas del lado izquierdo de la figura 3, esta técnica ofreció resultados sobresalientes cuando las muestras contenían un 2 % de sal. La precisión superó el 99 %, sin importar el tipo de leche ni la cantidad de agua añadida. Sin embargo, su rendimiento disminuyó en condiciones más exigentes, como en muestras con 4 % de sal y baja adulteración, donde las diferencias entre patrones se volvieron más sutiles.

En esos casos, el modelo basado en DenseNet121 demostró una clara ventaja. Fue capaz de identificar variaciones mínimas entre patrones que, a simple vista, parecían casi idénticos. Por ejemplo, en la leche deslactosada, adulterada con 20 % de agua y 4 % de sal, la precisión aumentó de 79 % (con lagunaridad) a 91 % usando DenseNet121. En muestras adulteradas con 40 % de agua, mejoró de 83 % a 93 %. Para niveles más altos de adulteración, como 60 % y 80 % de agua, ambos métodos funcionaron bien, aunque la IA mantuvo una precisión más constante.




Figura 3. Gráficas de eficiencia para la detección de agua en la leche entera (negro) y deslactosada (gris) con 0 %, 2 % y 4 % de sal y diluidas con 20 %, 40 %, 60 % y 80 % de agua. Los resultados con lagunaridad se muestran en los paneles izquierdos y los obtenidos con IA en los derechos.

LIMITACIONES

Como ocurre con cualquier herramienta de diagnóstico, este método también tiene sus límites. Aunque los resultados fueron muy precisos en la mayoría de los casos, no todas las combinaciones de agua y sal ofrecieron el mismo nivel de confiabilidad. En particular, cuando las muestras contenían 4 % de sal y apenas un poco de agua añadida, la lagunaridad perdió parte de su efectividad.

También es importante señalar que el estudio se realizó utilizando una sola marca de leche comercial. El desempeño del método aún debe evaluarse en otras formulaciones industriales, en productos artesanales y frente a otros adulterantes de interés. Además, antes de poder aplicar esta técnica de forma confiable, es necesario construir un catálogo de patrones secos para

cada tipo de muestra, lo cual requiere tiempo, cuidado y experiencia.

CONCLUSIONES

La adulteración de la leche representa un riesgo que no debería requerir laboratorios sofisticados para ser detectado. En este trabajo demostramos que una simple gota, combinada con análisis de imagen e IA, puede revelar mucho más de lo que parece. Al dejarla secar y analizar la mancha resultante, fue posible identificar la presencia de agua añadida con gran precisión, especialmente al incorporar un 2 % de sal como revelador de patrones.

Además, la IA basada en redes neuronales permitió automatizar el análisis, mejoró la consistencia de los resultados y la detección de diferencias sutiles que pasarían desapercibidas a simple vista.

Es importante mencionar la relevancia de la investigación interdisciplinar en este tipo de estudios, ya que no basta con aplicar algoritmos o métodos de análisis computacional para la obtención de resultados de reconocimiento confiables; también se requiere que personas que investigan en áreas de física y química trabajen en conjunto con especialistas en computación, o bien que adquieran habilidades de análisis computacional para una formación más integral en la resolución de problemas con IA.

En lo que respecta al impacto de este tipo de trabajos en la industria agroalimentaria, un método rápido y de bajo costo puede servir como primera línea de control en puntos estratégicos de la cadena láctea antes de recurrir a laboratorios especializados. Esto contribuye en la reducción de pérdidas económicas, pero también es una forma de desalentar prácticas desleales. El camino futuro implica validar el método con más tipos de adulterantes y condiciones de producción para fortalecer su utilidad en entornos reales.

Agradecimientos

Y. J. P. C. agradece el apoyo financiero otorgado por la beca posdoctoral de la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI). J. N. M. C. agradece la beca de posgrado proporcionado por la SECIHTI. Esta investigación fue financiada por, mediante el proyecto SECIHTI CF-2023-G-454.

Literatura citada

Acuña, C., Kokornaczyk, M.O., Baumgartner, S. and Castelán, M. 2023. Unsupervised Deep Learning

Approach for Characterizing Fractality in Dried Drop Patterns of Differently Mixed Viscum album Preparations. *Fractal and Fractional*. 7(10), p.733.

Carreón, Y.J.P., Díaz-Hernández, O., Escalera Santos, G.J., Cipriano-Urbano, I., Solorio-Ordaz, F.J., González-Gutiérrez, J. and Zenit, R. 2021. Texture Analysis of Dried Droplets for the Quality Control of Medicines. *Sensors*. 21(12), p.4048.

González-Gutiérrez, J., Pérez-Isidoro, R. and Ruiz-Suárez, J.C. 2017. A technique based on droplet evaporation to recognize alcoholic drinks. *Review of Scientific Instruments*. 88(7), p.074101.

Harindran, A., Hashmi, S. and Madhurima, V. 2022. Pattern formation of dried droplets of milk during different processes and classifying them using artificial neural networks. *Journal of Dispersion Science and Technology*. 43(12), pp.1838–1847.

Mamgain, A., Kumar, V. and Dash, S. 2024. Image-Based Detection of Adulterants in Milk Using Convolutional Neural Network. *ACS Omega*. 9(25), pp.27158–27168.

Mampallil, D. and Eral, H.B. 2018. A review on suppression and utilization of the coffee-ring effect. *Advances in Colloid and Interface Science*. 252, pp.38–54.

Molina-Courtois, J.N., Aguilar Morales, Y.J., Escalante-Zarate, L., Castelán, M., Carreón, Y.J.P. and González-Gutiérrez, J. 2025. Pattern Recognition in Dried Milk Droplets Using Lacunarity and Deep Learning. *Applied Sciences*. 15(10), p.5676.

Nascimento, C.F., Santos, P.M., Pereira-Filho, E.R. and Rocha, F.R.P. 2017. Recent advances on determination of milk adulterants. *Food Chemistry*. 221, pp.1232–1244.

Ríos-Ramírez, M., Reyes-Figueroa, A.D., Ruiz-Suárez, J.C. and González-Gutiérrez, J. 2018. Pattern formation of stains from dried drops to identify spermatozoa motility. *Colloids and Surfaces B: Biointerfaces*. 169, pp.486–493.

Sy, W., Jh, L., N, L., Yw, P., Ss, A., J, K., Jh, C., Sh, K. and Sk, L. 2022. Three-dimensional fractal dimension and lacunarity features may



noninvasively predict TERT promoter mutation status in grade 2 meningiomas. *PloS one*. **17**(10).

Aviso legal/Nota del editor: Las declaraciones, opiniones y datos contenidos en todas las publicaciones son exclusivamente de los autores y colaboradores, y no de Agraria ni de sus editores. Agraria y sus editores no se responsabilizan de ningún daño a personas o bienes que resulte de las ideas, métodos, instrucciones o productos mencionados en el contenido.

