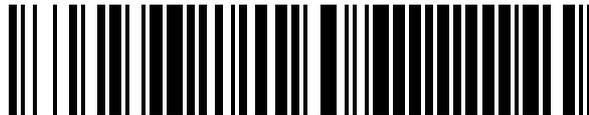


19



OFICINA ESPAÑOLA DE  
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **1 257 877**

21 Número de solicitud: 202032072

51 Int. Cl.:

**G06N 3/02** (2006.01)

**G06T 1/20** (2006.01)

**G01N 21/71** (2006.01)

12

SOLICITUD DE MODELO DE UTILIDAD

U

22 Fecha de presentación:

**24.06.2019**

43 Fecha de publicación de la solicitud:

**04.12.2020**

71 Solicitantes:

**UNIVERSIDAD COMPLUTENSE DE MADRID**

**(100.0%)**

**Avenida de Séneca, 2**

**28040 Madrid ES**

72 Inventor/es:

**TORRECILLAS VELASCO, José Santiago;**

**IZQUIERDO HERRERA, Manuel y**

**LASTRAS MEJIAS, Miguel**

54 Título: **DETECCIÓN IN SITU DE ADULTERACIONES EN ALIMENTOS POR TERMOGRAFÍA  
INFRARROJA Y ALGORITMOS INTELIGENTES**

ES 1 257 877 U

## DESCRIPCIÓN

### Equipo para la detección *in situ* de adulteraciones en alimentos por termografía infrarroja y algoritmos inteligentes

5

#### SECTOR DE LA TÉCNICA

La presente invención se encuadra en el campo de control de calidad alimentaria. De forma más concreta, se refiere a un equipo de detección de adulteración en alimentos combinando la termografía infrarroja y el tratamiento de imágenes por medio de algoritmos inteligentes resultando sencillo, rápido y sensible.

10

#### ANTECEDENTES DE LA INVENCION

15 La adulteración es un método de fraude alimenticio que provoca un fuerte impacto en la sociedad tanto en el ámbito económico como social suponiendo, además, una amenaza para la salud pública. Ante esta situación, se han venido desarrollando diferentes métodos de detección de adulteración en alimentos.

20 Ejemplos de alimentos comúnmente adulterados son la miel (adulterada con siropes, azúcar de caña o maíz), el aceite de oliva virgen extra (adulterado con aceites de peor calidad o, incluso, aceites caducados) y la leche (adulterada con agua o mezcla con sueros procedentes del sector lácteo). Para detectar tales adulteraciones se han aplicado diferentes técnicas analíticas de autenticación como RMN o HPLC (Cao et al.

25 *Detection of honey adulteration with starch syrup by high performance liquid chromatography*. Food Chemistry, 172 (2014), 669-674; Ribeiro et al. *Detection of honey adulteration of high fructose corn syrup by Low Field Nuclear Magnetic Resonance (LF 1H NMR)*. Journal of Food Engineering, 135 ( 2014), 39-43), o espectroscopia en el rango visible, infrarrojo cercano (Ma et al., *Qualitative and quantitative detection of honey adulterated with high-fructose corn syrup and maltose syrup by using near-infrared spectroscopy*. Food Chemistry, 218 (2016), 231–236), infrarrojos combinados con quimiometría (Ferreiro-González et al. *Rapid quantification of honey adulteration by visible-near infrared spectroscopy combined with chemometrics*. Talanta, 188 (2018),

30

288–292) o Raman (Oroian, Ropciuc, & Paduret, *Honey Adulteration Detection Using Raman Spectroscopy*. *Food Analytical Methods*, 11(4) (2018), 959–968), entre otras. Todas ellas, sin embargo, presentan limitaciones debido a la similitud de las composiciones químicas de los alimentos adulterados y los adulterantes por lo que sigue  
5 existiendo la necesidad de nuevos métodos de detección *in situ* de adulteraciones mediante equipos transportables, rápidos y sensibles, con capacidad de detección con el mayor grado de fiabilidad, seguridad y rapidez.

Para dar otra solución alternativa a este problema, el equipo de detección de la presente  
10 invención se basa en las propiedades térmicas de los alimentos detectando variaciones a través de una cámara termográfica. La tecnología de la cámara termográfica ha sido ya aplicada a distintos procesos en la industria alimentaria como el control de temperatura del producto, nivel de llenado de botes, detección de fragmentos sólidos, sellado de envases o como método de control de frutas en el sector agrario. Sin  
15 embargo, no se ha utilizado para determinar la diferente composición química de varias muestras del mismo tipo de alimento para poder detectar adulteraciones con un alto grado de fiabilidad y de forma rápida y sencilla.

## EXPLICACIÓN DE LA INVENCION

20 La presente invención se refiere a un equipo de detección *in situ* de adulteraciones de alimentos por termografía infrarroja empleando una cámara termográfica como recurso principal y, posteriormente, complementando el análisis de resultados con el entrenamiento y modelaje de algoritmos no lineales mediante modelos matemáticos  
25 centrados en redes neuronales convolucionales como sistema para identificación y cuantificación de adulteraciones.

La cámara termográfica es capaz de determinar la radiación infrarroja emitida por la muestra y que es característica de su propia composición química; a partir de estas  
30 emisiones de infrarrojos de las muestras, se forman imágenes que son analizadas y comparadas mediante algoritmos inteligentes capaces de detectar variaciones en tales imágenes y, por tanto, en las muestras de las que proceden.

El equipo emplea un método de análisis que comprende varias etapas. Inicialmente, las muestras objeto de estudio son calentadas a una temperatura hasta un 60 % superior a la temperatura ambiente, para posteriormente captar las imágenes termográficas de las muestras durante su proceso de enfriamiento. Con estas imágenes se genera una base de datos compuestas por las termografías de muestras adulteradas y sin adulterar. Para su análisis y clasificación se diseña una red neuronal convolucional que se entrena utilizando la base de datos para muestras adulteradas y sin adulterar antes mencionada. Se plantean modelos matemáticos que se validan y testan para cada uno de los alimentos probados. Una vez probadas y validadas los modelos matemáticos, se utilizan para analizar imágenes de muestras sospechosas de adulteración consiguiendo precisiones mayores del 95% tanto en la detección como en la cuantificación de la concentración de adulterantes presentes en la muestra.

La emisión de la muestra no requiere utilizar una radiación incidente sobre la misma ya que la muestra emite una radiación característica de su composición por el mero hecho de estar a una temperatura superior a los  $-273,15\text{ }^{\circ}\text{C}$ , lo cual permite mantener la integridad de la muestra sin alterarse la estabilidad de la misma. Por todo ello, la detección es rápida, sencilla y segura.

La cámara utiliza sensores infrarrojos para la detección de emisiones infrarrojas de onda larga emitidas en el espectro electromagnético. Estas emisiones se relacionan con la temperatura de la superficie de la muestra medida. El resultado de la medición es un mapa escalado por colores en función de la temperatura (Figura 4), representando de forma visible la distribución de temperaturas de la superficie. La cámara termográfica permite configurar este mapa de colores en función de su disponibilidad para distinguir las mayores diferencias visuales de temperatura. Como parámetro fundamental para el control de las condiciones de análisis, el equipo dispone de un sensor de temperatura interno encargado de la medida de la temperatura ambiente

La temperatura ambiental del laboratorio donde se realizan las medidas se mantiene entre  $25\text{ }^{\circ}\text{C}$  -  $25,8\text{ }^{\circ}\text{C}$ . Las muestras calentadas se introducen en un recinto parcialmente adiabático con una apertura frontal que permite que la radiación que emite la muestra sea captada directamente por la cámara termografica (Figura 1). Para ello, la muestra

se coloca a una distancia fija de la cámara y se toman videos para analizar el periodo de decremento de temperatura. Después, se separan y analizan las imágenes, para, posteriormente incluirlas en una base de datos para el diseño de los algoritmos inteligentes.

5

Los algoritmos inteligentes tratan la información que suministra la cámara termográfica. En concreto, el modelo matemático utilizado en la presente invención utiliza redes neuronales convolucionales (CNN) que consisten en algoritmos supervisados basado en la extracción de características de imágenes. Esta utilidad se ha empleado en esta invención para la clasificación de muestras de alimentos y detección de adulterantes si los hubiera. La función de las CNNs se basa en cuatro pilares: conexiones locales, pesos compartidos, agrupamiento y empleo de grupos de capas. Los pesos compartidos y las conexiones locales relacionan cada pixel del mapa de características con una neurona reduciendo así el tamaño de cálculo y el *overfitting*. La combinación de las capas convolucionales con las agrupaciones permite extraer el conjunto de todas las características desde los niveles inferiores a superiores, estos últimos resultando de las combinaciones de las capas anteriores.

Existen tres grupos de capas diferentes: convolucionales, *pooling* y *fully connected layers*. Las dos capas iniciales conforman una herramienta útil para la extracción de características mientras que la capa *fully connected* es responsable del mapeo de las características extraídas previamente.

En la Figura 2 se muestra un esquema de capas que conforman el modelo CNN general junto a los filtros característicos en las etapas de *pooling* o convolución.

La capa de convolución es una operación lineal entre la matriz que conforma las imágenes (bidimensionales) y una matriz (llamada filtro de *kernel*) extractora de características optimizables. Esta operación consiste en la multiplicación de los valores de cada posición de la matriz de entrada frente al filtro de *kernel* y da como resultado los mapas característicos para cada una de las imágenes.

En las redes convolucionales, los parámetros más importantes son: el tamaño y número

de filtros (señala la cantidad de neuronas convolucionales que se asocian a la misma región de entrada), el *padding* (esencial para mantener las dimensiones de las imágenes de entrada, permitiendo la incorporación de más números de capas favoreciendo así un análisis más exhaustivo de las características), el *stride* (distancia entre dos posiciones del filtro en la convolución). Es de destacar que el resultado de la convolución precisa de la aplicación de una función de activación no lineal. El objetivo de la activación es obtener una representación dispersa favoreciendo la estabilidad de los datos ante cambios y optimizando el trabajo computacional. Previamente a cada activación se aplica una capa de normalización para acelerar la función de aprendizaje de la red y limitar su influencia en las etapas iniciales reduciendo, con todo ello, el riesgo de *overfitting* (aprendizaje de la información irrelevante de las imágenes).

Las capas convolucionales trabajan complementadas con las capas de *pooling* como un extractor de características en función de los píxeles de las imágenes.

En la capa de *pooling* se consigue la reducción de las dimensiones de la imagen de la entrada (*downsampling*), lo cual favorece la pérdida de información no relevante evitando la sobrecarga de trabajo en las redes y el sobreajuste en las clasificaciones. El resultado de esta etapa es la obtención de un vector unidimensional.

Al final del conjunto de capas convolución-*pooling* se incluye la capa *fully connected*, responsable de la interpretación y correlación de las características detectadas en la imagen.

En la capa *fully connected* cada vector unidimensional se asocia a una capa donde cada neurona se corresponde a una clase en las que se puede clasificar la imagen. Por tanto, esta capa tiene como salida el número de clases a las que se ajusta el modelo. La relación de clase-características específicas en cada imagen se identifica y ajusta a la probabilidad correspondiente a cada entrada. Para ello, es necesario el uso de una función de probabilidades que se introduce a continuación.

La **función de error** participa en la determinación de los parámetros de aprendizaje en

función del acercamiento entre la clase calculada y la etiqueta correspondiente a la imagen de entrada. Se aplica en la determinación de los *kernels* y los pesos de las capas establecidas. La función típica de error combina la función *softmax* (que normaliza los valores obtenidos en la capa *fully connected* para el cálculo de probabilidades de cada clase) y la pérdida cruzada. La función de error **se optimiza** mediante el método de gradiente descendente, que actualiza los parámetros anteriores en función del coeficiente de aprendizaje en dirección inversa al gradiente de error. El coeficiente de aprendizaje es uno de los parámetros más importante en la inicialización de la optimización del modelo.

10

El conjunto de imágenes utilizadas como base de datos necesita dividirse en tres grupos según la fase del modelo: imágenes de entrenamiento, validación y test. La selección de las imágenes que componen cada uno de estos conjuntos se realiza de forma aleatoria. El grupo de entrenamiento se emplea en el cálculo de los errores y optimización de los parámetros de aprendizaje. El conjunto de validación se utiliza para la verificación de los parámetros característicos del modelo y la elección del modelo final. Finalmente, el conjunto de test certifica la precisión final del modelo propuesto. Para construir un modelo que evite el *overfitting* se necesita que las imágenes de los dos primeros conjuntos estén completamente separadas del grupo de test. Por otra parte, ninguna de las imágenes figura en más de uno de los tres conjuntos.

20

## BREVE DESCRIPCIÓN DE LOS DIBUJOS

Para complementar la descripción de la invención se muestran figuras en donde, con carácter ilustrativo y no limitativo, se ha representado lo siguiente:

25

**Figura 1.** Esquema del sistema de adquisición de imágenes conformado por un recinto parcialmente adiabático (2) donde se aloja la cubeta con la muestra (1) que emite en el rango infrarrojo (3) separada una distancia (4) de la cámara termográfica (5) y ordenador con software termográfico (6).

30

**Figura 2.** Esquema de bloques que conforman la red neuronal.

**Figura 3.** Esquema del modelo de CNN implementado para imágenes termográficas donde se muestran capas convolucionales con ReLU (7), capas de *pooling* (8), capas *fully connected* con *softmax* (9) y posibles salidas (10).

5 **Figura 4.** Imagen ejemplo de una muestra de miel y la paleta de colores usada en la distribución de temperaturas de imágenes termográficas, señalizando en rojo la muestra estudiada.

10 **Figura 5.** Comparativa de imágenes erróneas en el análisis cualitativo de la miel adulterada: (a) miel de acacia Pajuelo pura y (b) misma miel adulterada en un 1%.

15 **Figura 6.** Comparativa de muestras de mieles adulteradas frente a muestras de miel pura: (a) miel de limón pura (a1) frente a miel de limón adulterada al 8% (a2); (b) miel de acacia *luna de miel* (b1) frente a la misma miel adulterada al 2% (b2) y 8% (b3) ; (c) miel de acacia Pajuelo pura (c1) frente a misma miel adulterada en un 8% (c2).

**Figura 7.** Comparativa de imágenes erróneas en la clasificación cuantitativa del modelo acacia Pajuelo: (a) miel de acacia Pajuelo pura y (b) misma miel adulterada en un 1%.

20 **Figura 8.** Comparativa de imágenes erróneamente clasificadas en el modelo combinado de limón y acacia Pajuelo: (a) miel de limón pura, (b) muestra A de miel de limón adulterada al 1% con sirope de arroz y (c) muestra B de miel de limón adulterada al 1% con sirope de arroz.

25 **Figura 9.** Comparativa de muestras de aceite de oliva virgen extra (AOVE) puras y muestras adulteradas: (a) AVOE Picual puro; (b) adulterado con aceite de girasol al 2% (b1) y al 8% (b2); (c) adulterado con aceite refinado al 2% (c1) y al 8% (c2); (d) adulterado con aceite de orujo al 2% (d1) y al 8% (d2)

30 **Figura 10.** Precisión de los modelos para estudios cualitativos (área color amarillo) y cuantitativos (color verde) de detección de adulteraciones en aceites de oliva virgen extra.

**REALIZACIÓN PREFERENTE DE LA INVENCION**

La presente invención se ilustra mediante los siguientes ejemplos los cuales no pretenden ser limitativos de su alcance.

**5 Ejemplo 1.**

Este ejemplo se refiere a la preparación de muestras de alimentos adulterados y sin adulterar para su posterior análisis. En concreto, este ejemplo se refiere a miel.

- 10 Se emplean tres marcas diferentes para dos mieles monoflorales. En la tabla 1 se presentan sus detalles comerciales y el sirope de arroz empleado como adulterante de las mieles.

- 15 Se preparan un total de 56 muestras adulteradas en un rango desde el 1% al 8% en peso. De estas muestras, 8 corresponden a muestras puras de miel (acacia y limón), 16 a muestras adulteradas en un 1 % en peso, otras 16 a muestras adulteradas en un 4 % y 16 a muestras adulteradas en un 8%, divididas entre las 4 marcas de miel (variedades monoflorales de acacia y limón, Tabla 1).

20

**Tabla 1.** Mieles y adulterante utilizados

MARCA COMERCIAL	VARIEDAD	ORIGEN	FECHA CADUCIDAD
Miel Pajuelo	Acacia	Hungría	01/2021
Luna de miel	Acacia	Francia	10/2020
Miel de limón Carrefour	Limón	España	09/2019
DANIVAL	Sirope de arroz	Moulin d'Andiran (Francia)	05/2020

**Ejemplo 2.**

- 25 Este ejemplo se refiere al equipo empleado (Figura 1) y el método de análisis para obtener datos termográficos de las muestras analizadas.

Se utiliza una cámara termográfica OPTRIS PI 450 con una precisión de  $\pm 2^{\circ}\text{C}$  y *un frame rate* de 80Hz. Su resolución óptica se recoge en las dimensiones de 382x288 pixel con

un rango espectral de 7,5 - 14  $\mu\text{m}$ .

La distancia entre la cámara termográfica y la muestra a analizar se mantiene en 25 cm. El coeficiente de emisividad de la miel utilizada se ha ajustado a 1. El resultado de la  
5 medida son videos de 15 minutos donde se analiza el periodo de decremento de temperatura (de 40 a 36 °C) que corresponde, aproximadamente, a tiempos de 3-5 minutos de los que se extraen imágenes cada 15 centésimas de segundo. Después de analizar cada imagen, todas son incluidas en la base de datos para el diseño de los algoritmos inteligentes, lo que completa una base de datos de, aproximadamente,  
10 80.000 imágenes.

Las imágenes termográficas se extraen del decremento de temperatura en la muestra de miel desde los 40°C hasta los 36°C. Se toman imágenes cada quince centésimas de segundo.

15 Las imágenes se clasifican en mieles adulteradas y no adulteradas. En el primer grupo se agrupan todas las concentraciones medidas y en el segundo solamente las mieles puras preparadas.

20 Se constituyen un total de cinco redes neuronales convolucionales, tres de ellas referidas a cada una de las marcas de mieles utilizadas, una combinando las dos marcas de miel de Acacia y la última recogiendo todas las marcas de miel utilizadas en el estudio.

### 25 **Ejemplo 3.**

Este ejemplo describe el diseño de una red convolucional para el tratamiento de resultados termográficos de las muestras (Figura 3)

30 Para cada una de las capas de las redes convolucionales se utilizan los siguientes parámetros:

- En la capa de convolución, el tamaño de filtros y números seleccionados para

5 las redes convolucionales es de 3 x 3 y 8 filtros, respectivamente. El *padding* se trata de un relleno de ceros (*zero padding*) cuya técnica se caracteriza por rellenar filas y columnas de ceros, manteniendo las mismas dimensiones después de aplicar la capa de convolución. El filtro en la convolución se ajusta con salto común en estas redes que es de 1. El resultado de la convolución precisa la aplicación de una activación que, en este caso, es la función de activación no lineal rectificadora (ReLU) que calcula la función  $f(x) = \max(0, x)$ . Anterior a cada activación, se aplica la capa de normalización para acelerar la velocidad de aprendizaje y limitar su influencia en las etapas iniciales reduciendo el riesgo de *overfitting*.

10 - En la capa de *pooling* se emplea el método de *maxpooling* como complemento ideal a la red neuronal de convolución. Las dimensiones del *pooling* son 2x2 con un *stride* (distancia entre dos posiciones del filtro en la convolución) de 2x2.

15 - A la capa *fully connected* se asocia el vector unidimensional resultante del *pooling* donde cada neurona se corresponde a una clase en las que se puede clasificar la imagen. Para clasificar cada clase de imagen se aplica la función *softmax*:

20

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}$$

25 Siendo  $\sigma(z)_j$  el valor de probabilidad de cada clase estipulada,  $e^{z_j}$  el exponencial del valor (j) del vector de entrada y  $\sum_{k=1}^K e^{z_k}$  el sumatorio de exponenciales de los valores del vector de entrada. Se asocia cada clase de salida a la propia probabilidad calculada en la función mencionada.

30 En la Tabla 2 se muestra un esquema de capas que conforman el modelo de CNN junto a los filtros característicos en las capas de *pooling* o convolución.

**Tabla 2.** Esquema de capas del modelo convolucional

Nº CAPA	CAPA	TAMAÑO	FILTRO
1	Entrada	288 x 382 x 3	
2	Capa convolucional	3 x 3	8
3	Capa de normalización		
4	Función de activación RELU		
5	Capa <i>Max-pooling</i>	2 x 2	
6	Capa convolucional	3 x 3	16
7	Capa de normalización		
8	Función de activación RELU		
9	Capa <i>Max-pooling</i>	2 x 2	
10	Capa convolucional	3 x 3	32
11	Capa de normalización		
12	Función de activación RELU		
13	Capa <i>fully connected</i>		
14	Capa <i>softmax</i>		
15	Clasificación		

**Ejemplo 4.**

Este ejemplo se refiere al entrenamiento de los modelos matemáticos.

5

El algoritmo de retropropagación usado para el entrenamiento de las CNNs tiene como objetivo reducir las diferencias entre las estimaciones y las clases reales correspondientes a la base de datos de imágenes. Se basa en la optimización de los filtros de kernels propios de la convolución y los pesos en la capa *fully connected* a través de la función de error y gradiente descendente. El gradiente descendente actualiza los parámetros anteriores en función del coeficiente de aprendizaje y en dirección inversa al gradiente de error siguiendo la ecuación:

10

$$w = w - \alpha \times \frac{\partial L}{\partial w}$$

15

donde  $w$  representa los pesos de ponderación que son los valores ajustable del modelo,  $L$  es la función de error y  $\alpha$  es el coeficiente de aprendizaje que constituye uno de los parámetros más relevantes en la inicialización de la optimización del modelo. En este

caso,  $\alpha$  se inicia con el valor 0,0001 y un *rate drop* de coeficiente de aprendizaje de 0,1. Además, esta especificación utiliza un conjunto de datos de entrenamiento llamado *mini-batch*, responsable de la actualización de los parámetros, denominado gradiente estocástico (SGD). Para este caso, se fija en todos los modelos con 64 imágenes.

5

### **Ejemplo 5.**

Este ejemplo se refiere a la validación de los modelos.

10 Las imágenes obtenidas como base de datos se dividen en tres grupos aleatoriamente según la fase del modelo: entrenamiento (75%), validación (15%), y test (10%). El primer grupo se emplea para calcular errores y optimizar los parámetros de aprendizaje, el segundo para verificación de los parámetros del modelo y la elección del modelo final y el tercero para certificar la precisión final del modelo.

15

Se desarrollan modelos identificadores de adulteraciones en muestras (cualitativos) y modelos optimizados para cuantificación de la concentración de adulterantes en las muestras adulteradas.

### **Ejemplo 6.**

En este ejemplo se describe la toma de imágenes termográficas de mieles puras y adulteradas para la detección cualitativa de adulteraciones.

25 Las imágenes (Figura 4) se clasifican en mieles adulteradas y no adulteradas. En el primer grupo se agrupan todas las muestras de mieles con concentraciones no nulas de sirope de arroz y en el segundo solamente las mieles puras preparadas.

30 Se constituyen un total de cinco redes neuronales, tres de ellas referidas a cada una de las marcas de mieles utilizadas, una combinando las dos marcas de miel de Acacia y la última recogiendo todas las marcas de miel utilizadas en el estudio (Tabla 3).

En la tabla 3 se muestra una comparativa de la cantidad de imágenes dedicada en cada

red.

**Tabla 3.** Comparativa de base de imágenes utilizada en cada modelo (nº imágenes)

CLASES DE IMÁGENES	RED 1	RED 2	RED 3	RED 4	RED 5
	Limón	Acacia Luna de miel	Acacia Pajuelo	Mezclas marcas Acacia	Mezclas florales
Muestras de miel	35.454	10.942	31.733	42.675	78.129
Precisión validación (%)	99,70	95,49	99,03	99,75	95,25
Precisión test (%)	99,67	95,25	99,05	99,77	95,04
Imágenes de test	4.267	3.545	1.094	3.173	7.182

- 5 Analizando individualmente cada red se puede comprobar que los modelos planteados se ajustan en todos los casos a la base de imágenes de entrenamiento y validación seleccionadas aleatoriamente, lo cual evidencia las diferencias en el comportamiento térmico de las muestras.
- 10 El resultado de las cinco redes entrenadas muestra una precisión mayor del 95% en todos los casos. Se puede afirmar que las redes permiten detectar las mieles adulteradas en un 99% independientemente de orígenes florales distintos. Además, el resultado comparativo entre las dos marcas de miel Acacia ha permitido aseverar que el algoritmo implementado alcanza una precisión del 99,75% en la selección de las
- 15 muestras adulteradas. Estas diferencias se justifican con la influencia que tiene el tratamiento y las propias condiciones florales y climáticas en la composición final de la miel. Todas estas especificaciones originan mieles con variadas características perfectamente diferenciadas analíticamente.
- 20 Se realiza un sistema que contiene todas las mezclas de las variantes de miel presentadas. La red convolucional alcanza un rendimiento del 95 % para este caso, lo cual implica que la estructura elegida en estas redes relaciona y clasifica las variantes presentadas entre mismas marcas y diversos orígenes florales. La precisión de los modelos simulados para la detección cualitativa se presenta también en la Tabla 3. La
- 25 precisión media de todos los modelos alcanza el 99 %.

### Ejemplo 7.

En este ejemplo se muestra el comportamiento de la red en relación con los errores de detección.

- 5 A partir de los resultados del ejemplo 6, para comprender mejor el comportamiento de la red, se observa dónde se encuentran los errores de clasificación más característicos de los modelos mediante comparativa entre el resultado clasificatorio de las imágenes de simulación frente al etiquetado real de estas imágenes.
- 10 Como resultado, se puede concluir que hay determinados errores en la identificación de adulteraciones de muestras con concentraciones menores (1% o 2%). Como se aprecia en la Figura 5, la distribución de temperaturas en muestra pura y adulterada al 1% presenta un comportamiento térmico muy parecido. Para ambas concentraciones menores el error reside en imágenes a temperaturas de 39°C lo cual implica una
- 15 distribución de temperaturas bastante extendida en todo el intervalo térmico de colores seleccionado. Esto facilita la correlación de características en el modelo. El error solamente supone un 2,4% del conjunto total de concentraciones de sirope añadido entre el 1% y el 2%, lo cual refrenda la elevada sensibilidad de método de detección.

## 20 **Ejemplo 8.**

En este ejemplo se describe la detección cuantitativa de sirope como adulterante de mieles.

- 25 Las imágenes de cada variedad de miel monofloral, obtenidas según se describe en el ejemplo 1, se organizan en función de las concentraciones de adulterantes y mezclas puras. Se analizan las diferencias apreciables visualmente en el perfil de temperatura con respecto a la concentración de adulterante (Figura 6). Las diferencias observables en el mapa térmico se pueden asociar a la concentración de hidroximetilfurfural (HMF)
- 30 ya que este compuesto se ha identificado como un indicador de degradación de la miel asociado, principalmente, a calentamientos inadecuados en la miel o a adulteración con siropes de arroz.

Como consecuencia de las condiciones de experimentación, las CNNs se centran en estudiar la relación entre las concentraciones de adulterantes y las diferencias entre sus mapas de características. Así, como se aprecia en la Figura 6 (a) y (c) para adulteraciones del 8%, las diferencias mencionadas se pueden apreciar a simple vista  
 5 frente a la miel pura. Para concentraciones tan bajas de adulterante como el 2% (Figura 6b) sí es necesario emplear las CNNs para apreciar tales diferencias.

Las CNNs se centran en estudiar la relación entre las concentraciones de adulterantes con las diferencias entre sus mapas de características. Según la Figura 6, en diferentes  
 10 tipos de mieles la distribución de temperatura cambia con respecto a la concentración de adulterante. Incluso, para concentraciones de adulterante del 8%, las diferencias se aprecian a simple vista respecto a la muestra pura. Sin embargo, para concentraciones más bajas es necesario emplear métodos como CNNs como complemento a la cámara termográfica para apreciar diferencias.

15 En este caso se plantean cuatro modelos clasificadores de muestras en función de la concentración de adulterante. Las cuatro clases de muestra elegidas son: miel pura, miel adulterada al 1%, miel adulterada al 4% y miel adulterada al 8%. El resultado obtenido para cada modelo CNN entrenado se presenta en la tabla 4.

20

**Tabla 4.** Modelos entrenados para identificación cuantitativa de miel adulterada.

RED	RED 1	RED 2	RED 3	RED 4
	Limón	Acacia Luna de miel	Acacia Pajuelo	Acacia Pajuelo + Limón
Precisión validación (%)	95,07	97,81	97,94	92,90
Precisión test (%)	95,58	96,89	98,26	92,75
Imágenes de test	3.173	3.545	1.094	4.267

25 Los valores conseguidos en las CNNs durante el periodo de entrenamiento identifican muestras adulteradas en las concentraciones anteriores aproximadamente en un 97%. Además, los valores obtenidos se verifican con un batch de imágenes de test y, de esta manera, se consigue una precisión del 98%.

**Ejemplo 9.**

En este ejemplo se muestra el comportamiento de la red en relación con los errores de cuantificación.

5

A partir de los resultados del ejemplo 8, para comprender mejor el comportamiento de la red, se observa dónde se encuentran los errores de cuantificación más característicos de los modelos mediante comparativa de la coincidencia entre los resultados de los tests y las clases reales. En este caso, se han detallado los errores más destacables observados, en primer lugar, de la red de Acacia Pajuelo y, en segundo lugar, el modelo combinado. En la Figura 7 se muestra una de las imágenes erróneamente clasificada. El 2% de error acometido por la red se ha identificado en su mayoría con muestras adulteradas del 1%. Aunque en su totalidad estos errores se consideran despreciables, parte de la dificultad de clasificación reside en el mapa térmico representado. Las imágenes correspondientes al 1% erróneas coinciden con la distribución de colores de una muestra a 36°C, lo cual da lugar a un mapa térmico simple con dos colores (Figura 7), lo que dificulta la detección de características térmicas específicas a la concentración de adulterante.

20 En el modelo de cuantificación combinado se señalan como errores característicos la identificación de miel adulterada al 1%, específicamente en mapas característicos de temperaturas de 37°C - 36°C. Este punto coincide al detalle con el modelo de Acacia representado en la Figura 7.

25 Para el modelo combinado se detallan las imágenes erróneas adulteradas en muestras de miel de limón (Figura 8) y se observa que los errores son coincidentes con el del modelo individual de Acacia Pajuelo. Esto permite aseverar que los errores son justificables debido a la alta sensibilidad de los modelos.

30 El modelo combinado se ofrece como una alternativa interesante en el análisis cuantitativo para un mayor número de tipos de mieles monoflorales con límites de detección inferiores al 1% de adulterante.

**Ejemplo 10.**

En este ejemplo se describe la detección de adulterantes en Aceites de Oliva Virgen Extra (AOVE).

5

Se selecciona un AOVE (variedad Picual) y se adultera de forma artificial con tres tipos de aceite de peor calidad: aceite de girasol, aceite de oliva refinado y aceite de orujo de oliva (Tabla 5). Para ello, se preparan mezclas binarias hasta el 8% en peso de adulterante. El total de muestras se organiza equitativamente entre los tres aceites de peor calidad en concentraciones de 2%, 4% y 8%. Las muestras puras y adulteradas suman un total de 24 muestras.

10

**Tabla 5.** Aceites y adulterantes utilizados

ACEITE	VARIEDAD	MARCA	ORIGEN	FECHA CADUCIDAD
<b>AOVE</b>	Picual	DELICIOUS	Granada (España)	08/2018
<b>Aceite de girasol</b>	-	KOIPE SOL	Córdoba (España)	01/2020
<b>Aceite refinado</b>	-	AUCHAN	Madrid (España)	08/2020
<b>Aceite de orujo</b>	-	DIA	Tortosa (España)	09/2019

15

Las muestras se analizan empleando el equipo descrito en el ejemplo 2 tomando imágenes del comportamiento de cada mezcla durante un periodo de decremento de temperatura de 39°C a 36°C.

20

Las diferencias térmicas entre las mezclas estudiadas se deben a la composición de los triacilgliceroles que contienen. Este componente forma parte fundamental de los aceites de origen vegetal o animal y su contenido es función de la procedencia del aceite de oliva. En la Figura 9 muestran imágenes termográficas de diferentes muestras y se puede deducir que la apreciación de diferencias puede llegar a ser inapreciable por el

25

ojo humano por lo que requiere la aplicación de modelos CNNs para alcanzar valores altos de sensibilidad.

Para desarrollar el modelo CNN las imágenes se agrupan de forma individual en función

del adulterante utilizado y después se optimiza con el total de imágenes. Se realizan estudios cualitativos y cuantitativos. Se emplean un total de ocho modelos diferentes. Los valores de precisión de entrenamiento para ambos estudios se muestran en la Figura 10, donde se aprecia que se alcanzan rendimientos próximos al 100%.

5

**REIVINDICACIONES**

- 5 1. Equipo para la detección *in situ* de adulteraciones en alimentos caracterizado porque que comprende un recinto parcialmente adiabático (2) donde se aloja una cubeta con la muestra a analizar (1) que emite en el rango infrarrojo al variar su temperatura (3) y que se encuentra separada a una distancia (4) de una cámara termográfica (5) acoplada a un ordenador con software termográfico (5).
- 10 2. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 1, donde la distancia entre la muestra a analizar y la cámara termográfica es de 25 cm.
- 15 3. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 1, caracterizado porque utiliza un método de método de detección que comprende:
- 20 a) Generar una base de datos de imágenes termográficas de muestras adulteradas y sin adulterar tomando dichas imágenes mediante una cámara termográfica durante un periodo de decremento de temperatura de las muestras.
- b) Diseñar una red neuronal convolucional para el tratamiento de las imágenes tomadas.
- c) Entrenar la red neuronal convolucional utilizando la base de datos para diferenciar muestras adulteradas y sin adulterar siguiendo modelos matemáticos.
- 25 d) Validar los modelos matemáticos.
- e) Testar la red neuronal convolucional diseñada utilizando muestras previamente adulteradas.
- f) Generar imágenes termográficas de muestras sospechosas de adulteración y analizarlas empleando la red neuronal convolucional
- 30 previamente entrenada y validada.
4. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 2, donde previamente las muestras son calentadas a una

temperatura hasta un 60 % superior a la temperatura ambiente y se introducen en un recinto parcialmente adiabático con una apertura frontal que permite que la radiación infrarroja emitida al enfriarse sea captada directamente por la cámara termográfica.

5

5. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicaciones anteriores, donde el alimento es miel con posible adulteración con sirope de arroz en un porcentaje entre el 1 y el 8 % en peso.

10

6. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 5, donde el decremento de temperatura en la muestra va desde los 40°C hasta los 36°C durante el cual se toman imágenes termográficas cada quince centésimas de segundos completando una base de datos de, aproximadamente, 80.000 imágenes.

15

7. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicaciones 1 a 4, donde el alimento es aceite de oliva virgen extra (AOVE) variedad Picual adulterado con tres tipos de aceite de peor calidad (aceite de girasol, aceite de oliva refinado y/o aceite de orujo de oliva) en un porcentaje entre el 2 y el 8%.

20

8. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 7, donde el decremento de temperatura en la muestra va desde los 39°C hasta los 36°C.

25

9. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 3, donde la red neuronal convolucional presenta tres tipos de capa: convolucional, capa *pooling* y capa *fully connected* y una función de error que participa en la determinación de los parámetros de aprendizaje.

30

10. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 9, donde la capa convolucionales constan de 8 filtros de kernel de tamaño 3x3, relleno *zero padding*, un *stride* de 2x2 y requieren una función de activación no lineal.

35

11. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicación 9, donde la función de activación no lineal es la función de activación no lineal rectificadora (ReLU) y anterior a ella se aplica una capa de normalización reduciendo el riesgo de *overfitting*.
- 5
12. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicaciones 9 a 11, donde la capa de *pooling* emplea el método *maxpooling* como complemento a la convolución con una dimensión de 2x2.
- 10
13. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicaciones 9 a 12, donde la capa *fully connected* aplica la función *softmax* para calificar cada imagen.
- 15
14. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicaciones 9 a 13, donde el entrenamiento de la red neuronal utiliza un algoritmo de retropropagación para la optimización de los filtros kernel y los pesos de la capa *fully connected* a través de la función error y el gradiente descendente iniciando el coeficiente de aprendizaje con el valor 0,0001, fijando un *rate drop* del mismo de 0,1 y utilizando un conjunto de datos de entrenamiento (*minibatch*) denominado gradiente estocástico (SGD).
- 20
15. Equipo para la detección *in situ* de adulteraciones en alimentos, según reivindicaciones 9 a 14, donde la validación y prueba de los modelos se realiza dividiendo de forma aleatoria las imágenes termográficas obtenidas en tres grupos: entrenamiento (75%), validación (15%) y test (10%), de forma que el primer grupo se emplea para calcular errores y optimizar parámetros de aprendizaje, el segundo para verificación de parámetros del modelo y el tercero para comprobar la precisión final del modelo.
- 25

30

35

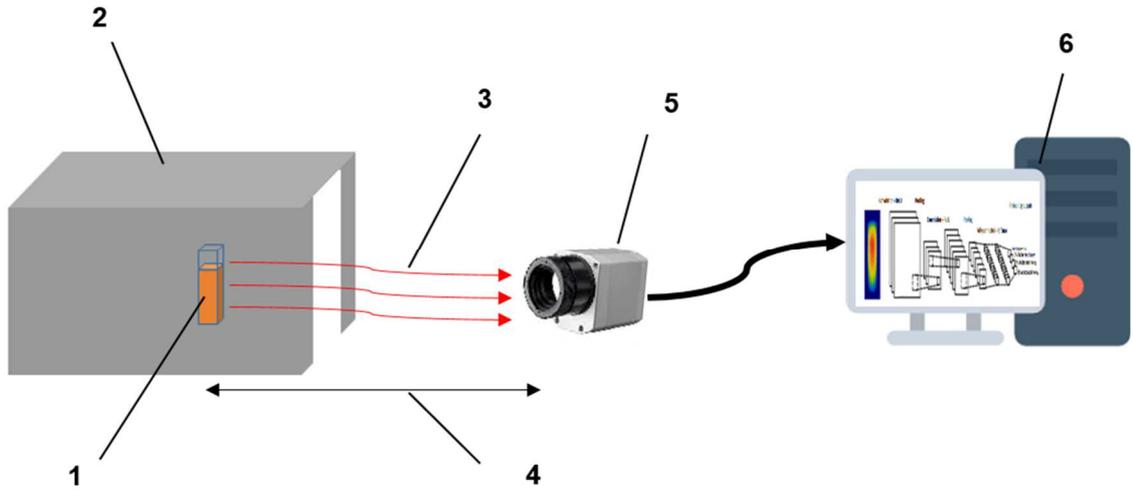


Figura 1

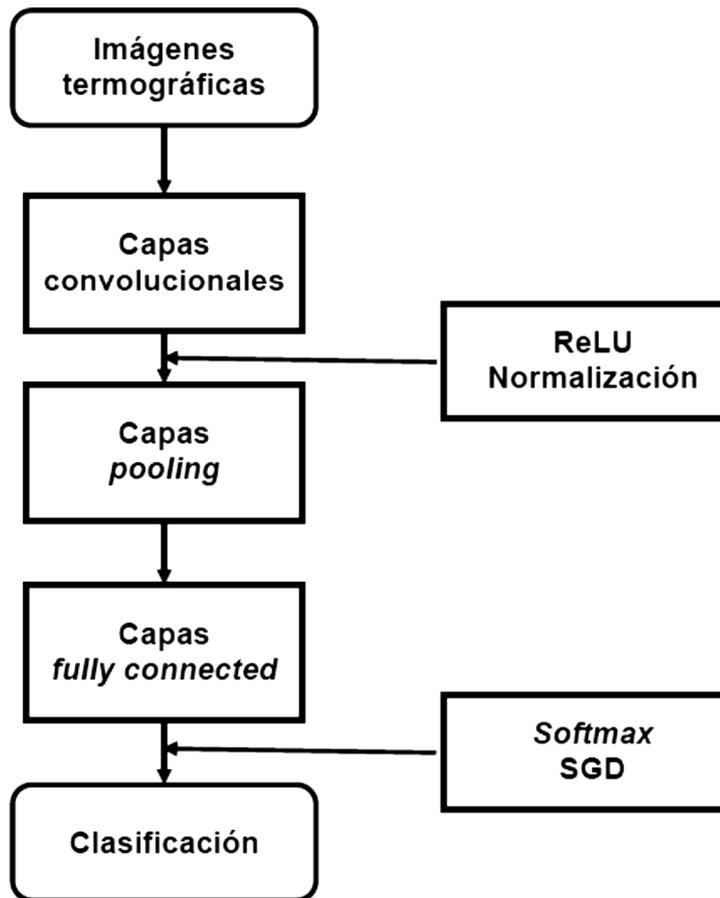


Figura 2

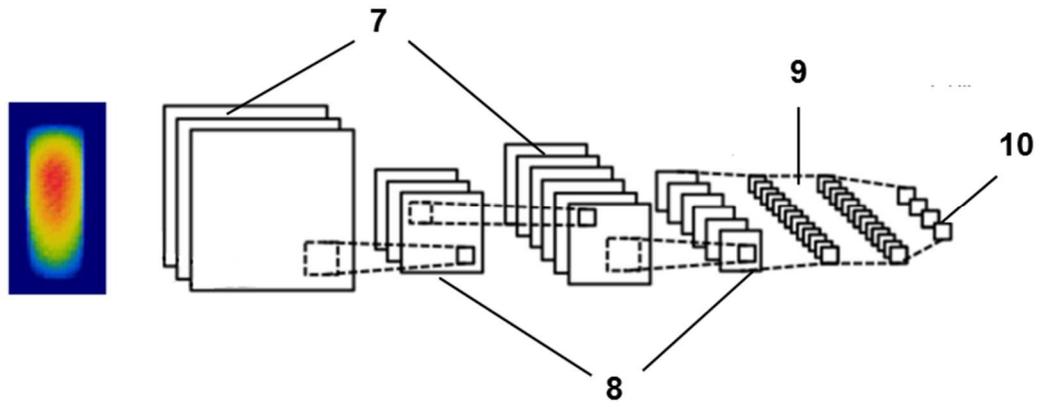


Figura 3

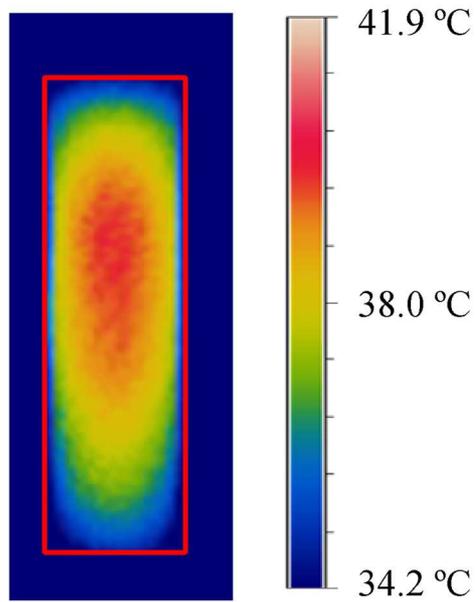


Figura 4

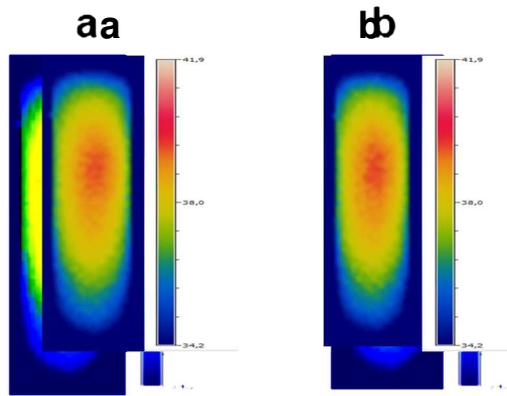


Figura 5

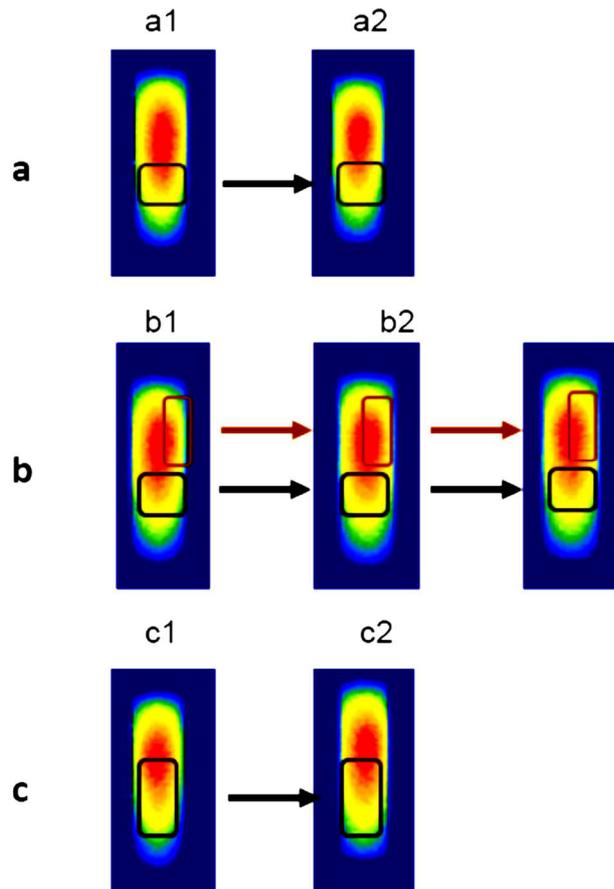


Figura 6

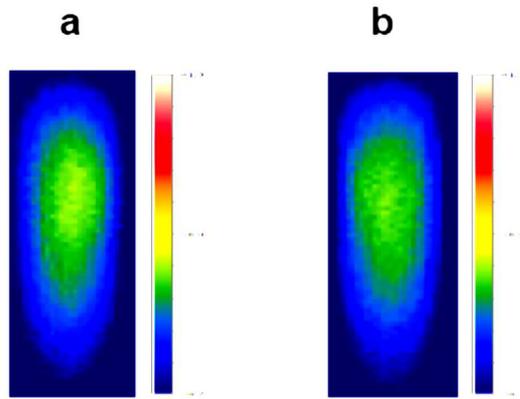


Figura 7

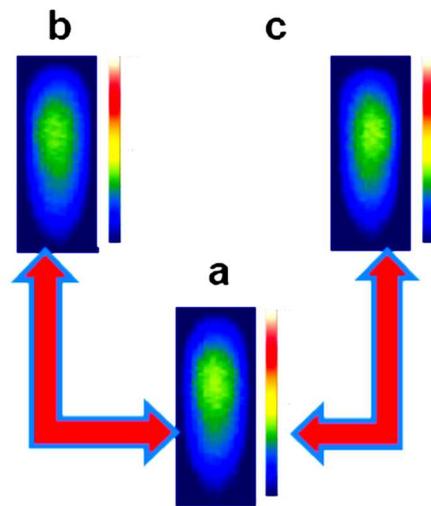


Figura 8

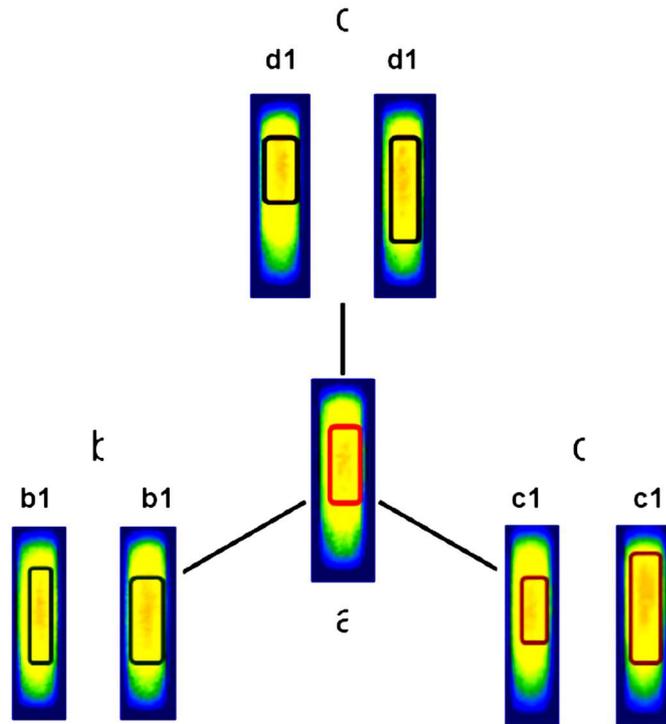


Figura 9

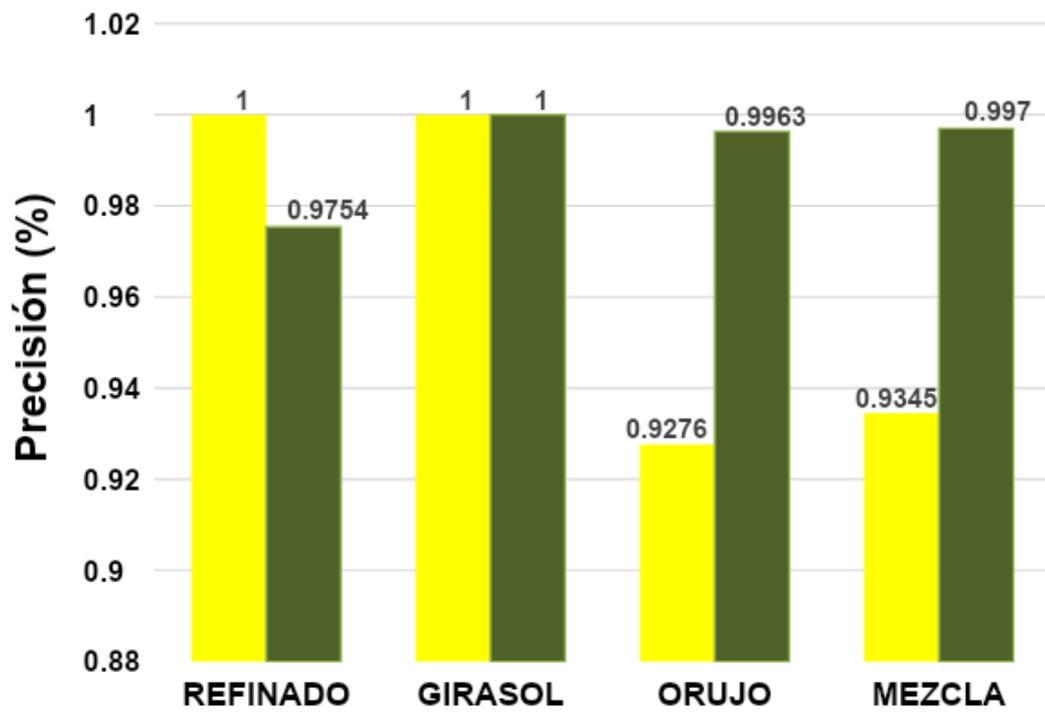


Figura 10