

EVOLUCIÓN DE LA TEXTURA DEL CAQUI ALMACENADO EN FRÍO A DOS TEMPERATURAS MEDIANTE IMAGEN HIPERESPECTRAL

Salvador Castillo-Gironés^{*1}, Marina Lopez Chulia¹, Sergio Cubero¹, Sandra Munera³, Alejandro Rodríguez³, Juan Gómez-Sanchís², Nuria Aleixos³, José Blasco¹

1: Centro de Agroingeniería, Instituto Valenciano de Investigaciones Agrarias (IVIA), CV-315, km 10,7, Moncada (Valencia) 46113, Spain. castillo_salgirb@gva.es

2: IDAL, Departamento de Ingeniería Electrónica, Universidad de Valencia, Av. de la Universidad, S/N, 46100 Burjassot, Valencia (Spain),

3: Departamento de Ingeniería Gráfica. Universitat Politècnica de València. Camino de Vera, s/n, Valencia, 46022, Spain

Resumen: *Las alteraciones en la textura del caqui durante el almacenamiento pueden influir en la aceptación del consumidor. Por ello, este estudio utilizó imagen hiperespectral para predecir la firmeza de la pulpa y examinar los cambios espectrales de forma no destructiva. 1,750 caquis variedad 'Rojo Brillante' de almacenaron a 1 °C y 5 °C durante tres meses. Se adquirieron imágenes (420-1010 nm) de 250 frutos bajo cada condición en la cosecha y cada mes de almacenaje. Posteriormente, se midió con un texturómetro la curva de carga para romper la pulpa. Con ellas, los frutos se clasificaron en tres grupos (Duro, medio y blando) mediante K-Nearest Neighbours. Posteriormente, se extrajo el espectro medio de cada caqui y las muestras se dividieron aleatoriamente en conjunto de entrenamiento (70%) y prueba (30%). Se entrenaron tres modelos predictivos: Análisis Discriminante de Cuadrados Parciales (PLS-DA), Máquina de Vector Soporte (SVM) y XGBoost, que predijeron los tres grupos de firmeza con precisión superior al 98%. Además, se observaron diferencias notables en los espectros, especialmente en la región del agua (970 nm) debido a la degradación celular, picos de clorofila (680 nm) y carotenoides (475 nm). Por lo tanto, los resultados permiten concluir la mejor temperatura para el almacenamiento de caquis fue de 1 °C*

Palabras clave: Caqui, imagen espectral, almacenamiento, textura.

1. INTRODUCCIÓN

La calidad del caqui 'Rojo Brillante' puede sufrir cambios en su textura durante el periodo de almacenamiento después de la recolección si las condiciones no son óptimas. Por lo tanto, es crucial desarrollar herramientas precisas que permitan determinar la textura de esta fruta antes de su comercialización, algo de gran interés para los productores. El uso de imágenes hiperespectrales es una tecnología comprobada para predecir atributos internos de calidad de forma no destructiva [1], y puede ser aplicada para prever la textura de la pulpa [2], mediante métodos estadísticos quimiométricos.

Este trabajo tiene como objetivo evaluar la utilidad de la imagen hiperespectral Vis/NIR, analizada a través de tres modelos de aprendizaje automático diferentes: Análisis Discriminante de Cuadrados Parciales (PLS-DA), Máquina de Vector Soporte (SVM) y XGBoost, para detectar cambios en la textura de la pulpa del caqui 'Rojo Brillante' durante el almacenamiento a 1 °C y 5 °C durante tres meses.

2. MATERIALES Y MÉTODOS

2.1. Material vegetal.

Para este ensayo se empleó caqui cv 'Rojo Brillante', se seleccionaron un total de 1750 frutos y se almacenaron hasta tres meses a dos temperaturas (1 °C y 5 °C) y 90% de humedad relativa, para así observar los diferentes tipos de cambios en la textura de la pulpa del fruto. En el momento de la recolección y posteriormente cada mes, se adquirieron imágenes hiperespectrales de un conjunto aleatorio de frutos (250 frutos cada vez) de las condiciones de almacenamiento y posteriormente se realizó la medida de la firmeza de cada uno de los frutos

2.2. Medida y caracterización de la textura

La firmeza de la pulpa de estos frutos se midió con un texturómetro (Instron Corp., mod. 4301, Canton, MA, EE. UU.) utilizando un punzón de 8 mm de diámetro, registrando la curva de carga de rotura. Las curvas generadas de todos los frutos fueron procesadas utilizando el algoritmo de aprendizaje automático no supervisado k-Means. En este contexto, se empleó para agrupar los frutos según la textura estimada de las curvas. El número de grupos en los que se dividieron los frutos se determinó mediante el método del codo (Elbow), el cual implica trazar una curva que muestra la variación explicada en función del número de clústeres obtenidos por el algoritmo Kmeans, eligiendo el "codo" de la curva como el número óptimo de clústeres a utilizar [3], los frutos se clasificaron en tres clases distintas utilizando Kmeans como referencia

2.3. Toma y procesamiento de imágenes

Se adquirieron imágenes hiperespectrales de todos los frutos, para ello se utilizó una cámara hiperespectral (CoolSNAP ES, Photometrics, AZ, EE. UU.) y dos filtros sintonizables de cristal líquido en el visible e IR cercano (Varispec VIS-07 y NIR-07, Cambridge Research and Instrumentation, Inc., Ma, EE. UU.), cubriendo un rango espectral de 420-1010 nm. Las imágenes, con una resolución espacial de 1392x1040 píxeles y 0,14 mm/píxel, se capturaron cada 10 nm obteniendo un total de 60 longitudes de onda. Los frutos se colocaron dentro de una campana de iluminación semiesférica iluminado por doce lámparas halógenas de 37 W (Eurostar IR Halogen MR16, Ushio America, Inc., CA, EE. UU.) dispuestas de forma equidistante, ofreciendo luz indirecta. La reflectancia de las muestras se corrigió utilizando una referencia blanca (Spectralon, NH, EE. UU.) y negra (evitando la entrada de luz en la cámara).

Luego, se realizó la eliminación del fondo de las imágenes y se obtuvo el espectro medio de cada fruta al que se le aplicó Standard Normal Variate (SNV) para corregir la dispersión de la luz. Posteriormente, se emplearon tres métodos de aprendizaje supervisado para predecir las texturas a partir de las imágenes hiperespectrales. Los modelos se desarrollaron utilizando los espectros medios de los frutos como datos de entrenamiento, y las clases derivadas de las curvas mediante k-Means se utilizaron como variables de predicción. Las muestras se dividieron aleatoriamente en un conjunto de entrenamiento (70 %) y un conjunto de prueba externo (30 %).

2.3. Análisis y creación de modelos predictivos

Para extraer los datos de las imágenes y crear los modelos predictivos, se utilizó la versión 3.9 del software Python con las bibliotecas Scikit-learn, Scikit-image, Pandas, Matplotlib y Numpy. Se utilizó el método RandomizedsearchCV de Scikit-learn para optimizar los parámetros del clasificador y distinguir entre los grupos de textura maximizando precisión y minimizando error cuadrático medio (RMSE). Se utilizaron tres modelos de aprendizaje automático diferentes basados en Análisis Discriminante de Cuadrados Parciales

(PLS-DA), Máquina de Vector Soporte (SVM) y Extreme Gradient Boosting (XGBoost), basado en árboles de decisiones.

En el caso de PLS-DA, se obtuvo el RMSE más bajo de los parámetros de entrenamiento utilizando 26 variables latentes. Con SVM, los mejores parámetros fueron los siguientes: el kernel de función de base radial (RBF), peso de clase “equilibrado”, gamma de 10 y C de 4.97. Y en el caso de XGBoost, los mejores parámetros encontrados fueron: `colsample_bytree=0.5`, `gamma=0.3`, `learning_rate=0.25`, `max_depth=10`, `min_child_weight=1`, `n_estimators=100`.

3. RESULTADOS Y DISCUSIÓN

El estudio del efecto de las temperaturas de conservación en la textura de los caquis se puede predecir con el estudio de un sistema de imágenes hiperespectrales, para obtener resultados no destructivos para la determinación de la calidad del caqui.

3.1. Efecto de la conservación en la textura

Las curvas de rotura de pulpa (textura) medias para cada una de las condiciones de almacenamiento se muestran en la figura 1. Como se puede observar, la temperatura de almacenamiento es sumamente importante para mantener la firmeza de la fruta, por lo que el almacenamiento a 1°C parece ser el más idóneo, ya que mantiene la textura del caqui, durante todo el periodo de almacenamiento con valores superiores a los de 5°C. Obteniéndose para la temperatura de 1°C en el mes 3 unos valores similares a los del mes 2, aunque el tiempo de rotura de la pulpa sí aumenta respecto al mes 2, sugiriendo cambios en la textura de los mismos no asociados al valor de fuerza de rotura. El almacenamiento a 5°C causa cambios en la textura mucho mayores y, por tanto, valores de fuerza de rotura mucho menores.




Figura 1. Curvas de rotura de la pulpa del fruto de caqui para cada una de las condiciones de almacenamiento.

3.2. Predicción de la textura a partir de las imágenes hiperespectrales

Si se tiene en cuenta los espectros de las muestras analizadas, después de aplicar el SNV para corregir la dispersión de la luz, se presentan en la Figura 2. A lo largo del espectro, se observan regiones con una amplia gama de reflectancia, indicando que las diferencias entre las muestras se concentran en ciertas longitudes de onda específicas. Esto se confirma al representar gráficamente los espectros promedio de cada uno de las condiciones de almacenamiento, es donde se observan diferencias espectrales notables alrededor de los 960 nm, asociadas con un pico de absorción de agua [4], así como en las bandas de absorción relacionadas con carotenoides y clorofila (alrededor de 500 nm y 680 nm) [5]. Estos pigmentos están vinculados con la maduración de la fruta y los cambios en la estructura de la pulpa debido al almacenamiento a diferentes temperaturas.




Figura 2. Espectros medios para cada una de las condiciones de almacenamiento de caquis

Los resultados de la clasificación obtenidos por PLS-DA, SVM y XGBoost se muestran en las matrices de confusión de las Tablas 1, 2 y 3, respectivamente. Con PLS-DA, se obtuvo una clasificación correcta del 99% utilizando 26 componentes (el número de componentes que obtuvo la mayor precisión) para el conjunto de test independiente. Con SVM, se obtuvo una precisión del 98%, al igual que XGBoost. Sin embargo, como se muestra en las tablas de confusión, SVM funciona ligeramente peor al clasificar con firmeza media y blandos, mientras que XGBoost parece funcionar mejor para clasificar las texturas duras y medias.

Tabla 1. Matriz de confusión para los datos de test con PLS-DA

		Predicho		
		Duro	Medio	Blando
Real	Duro	150	0	0
	Medio	1	226	2
	Blando	0	0	137

Tabla 2. Matriz de confusión para los datos de test con SVM

		Predicho		
		Duro	Medio	Blando
Real	Duro	150	0	0
	Medio	5	222	2
	Blando	1	1	135

Tabla 3. Matriz de confusión para los datos de test con XGBoost

		Predicho		
		Duro	Medio	Blando
Real	Duro	149	1	0
	Medio	3	225	1
	Blando	1	3	133

4. CONCLUSIONES

Los frutos de caqui variedad 'Rojo Brillante' experimentan cambios de textura según las condiciones de almacenamiento. En este estudio, se analizaron diferentes condiciones de almacenamiento, así como las imágenes y curvas de fuerza de rotura de la pulpa. Tras analizar las curvas de rotura, se identificaron tres grupos de textura mediante k-Means. Donde se observó que el almacenamiento a 1°C parece ser el más favorable, ya que mantiene la textura del caqui hasta el tercer mes con valores similares al segundo mes, y muy superiores a los de los caquis conservados a 5 °C.

Además, el empleo de la imagen hiperespectral para clasificar la fruta de manera no destructiva según estos grupos, mostraron resultados prometedores cuando se emplearon todas las longitudes de onda y modelo de aprendizaje automático PLS con 26 variables, obteniendo una precisión del 99% en el conjunto de pruebas independiente. Lo que muestra que este puede ser un sistema idóneo para determinar la textura y por tanto su calidad en frutos como caquis de una forma no destructiva.

5. AGRADECIMIENTOS

Este trabajo ha sido parcialmente financiado a través de los proyectos AEI PID2019-107347RR-C31, C32 y C33 y fondos FEDER, y GVA CIPROM/2021/014. Salvador Castillo agradece a INIA por la beca FPI-INIA PRE2020-094491, con el apoyo de fondos FSE de la Unión Europea. Los autores agradecen a la Cooperativa Agrícola Ntra. Sra. Del Oreto Coop. V. (CANSO) por suministrar la fruta y por el apoyo técnico. Sandra Munera agradece el contrato postdoctoral Juan de la Cierva-Formación (FJC2021-047786-I) cofinanciado por el MICIN AEI/10.13039/501100011033 y la Unión Europea NextGenerationEU/PRTR.

REFERENCIAS

- [1] Lorente, D., Aleixos, N., Gómez-Sanchis, J., Cubero, S., García-Navarrete, O. L., & Blasco, J. (2012). Recent Advances and Applications of Hyperspectral Imaging for Fruit and Vegetable Quality Assessment. *Food and Bioprocess Technology*, 5(4), 1121–1142. <https://doi.org/10.1007/s11947-011-0725-1>.
- [2] Munera, S., Rodríguez-Ortega, A., Aleixos, N., Cubero, S., Gómez-Sanchis, J., & Blasco, J. (2021). Detection of Invisible Damages in 'Rojo Brillante' Persimmon Fruit at Different Stages Using Hyperspectral Imaging and Chemometrics. *Foods*, 10(9). <https://doi.org/10.3390/foods10092170>.
- [3] Madhulatha, T. S. (2012). An Overview on Clustering Methods. *IOSR Journal of Engineering*, 02(04), 719–725. <https://doi.org/10.9790/3021-0204719725>
- [4] Büning-Pfaue, H. (2003). Analysis of water in food by near infrared spectroscopy. *Food Chemistry*, 82(1), 107–115. [https://doi.org/https://doi.org/10.1016/S0308-8146\(02\)00583-6](https://doi.org/https://doi.org/10.1016/S0308-8146(02)00583-6)
- [5] Wellburn, A. R. (1994). The Spectral Determination of Chlorophylls a and b, as well as Total Carotenoids, Using Various Solvents with Spectrophotometers of Different Resolution. *Journal of Plant Physiology*, 144(3), 307–313. [https://doi.org/https://doi.org/10.1016/S0176-1617\(11\)81192-2](https://doi.org/https://doi.org/10.1016/S0176-1617(11)81192-2)