

Deteccción de variedad y estado de maduración del ciruelo japonés utilizando imágenes hiperespectrales y aprendizaje profundo

F. Chávez, B. Rodríguez-Puerta, F. J. Rodríguez-Díaz
Dpto. de Ingeniería en Sistemas Informáticos y Telemáticos
Universidad de Extremadura
06800 Mérida, España.
Email: {fchavez, brpuerta, fjrodriguez}@unex.es

Rafael M. Luque-Baena
Dpto. de Lenguajes y Ciencias de la Computación
Universidad de Málaga
29071, Málaga, España
Email: rmluque@lcc.uma.es

Resumen—En la actualidad, España ocupa el séptimo puesto como productor de ciruelas a nivel mundial y el tercero a nivel europeo según la Organización de las Naciones Unidas para la Alimentación y la Agricultura. La importancia que tiene el cultivo de esta fruta en nuestro país es evidente, siendo mayor en Comunidades Autónomas como la Extremadura, que centran su actividad económica en el sector primario. Lo que debe diferenciar una producción es su calidad, pero la calidad de los frutos tradicionalmente se hace en base a la experiencia de los agricultores y técnicos, basándose únicamente en su percepción visual. Esto puede generar errores en la determinación de la fecha óptima de recolección.

En este trabajo se propone un método novedoso basado en el análisis de imágenes hiperespectrales de los frutos del ciruelo japonés que, mediante técnicas de aprendizaje profundo (Deep Learning) y utilizando para ello redes neuronales convolucionales, se obtienen eficaces clasificadores de los frutos por su variedad y su fecha de maduración. Los resultados presentados en este trabajo permiten afirmar que es posible dotar a los agricultores y técnicos agrícolas de herramientas que les ayuden a la correcta toma de decisión en relación a la fecha de maduración de sus frutos, para poder obtener productos de mayor calidad y ser más competitivos en el sector.

I. INTRODUCTION

La Organización de las Naciones Unidas para la Alimentación (FAO) sitúa a España como el séptimo productor de ciruelas del mundo y el tercero a nivel europeo¹. La importancia económica que tiene el cultivo de este fruto en nuestro país es evidente. Si nos centramos en la comunidad autónoma de Extremadura, que es donde se está desarrollando el estudio aquí presentado, el Ministerio de Agricultura, Pesca, Alimentación y Medio Ambiente Español, cifra en 6500Has el territorio dedicado a esta actividad. Una mejora en el proceso de recolección, que puede ser recolectar el fruto en su momento óptimo con las herramientas que aquí se presentan, puede suponer una gran ventaja competitiva de las Empresas Extremeñas sobre sus competidoras.

La calidad de un producto es percibida por el consumidor como un conjunto de atributos que son evaluados de forma subjetiva, con el fin de escoger el mejor. Si nos centramos

en la fruta, esta calidad la mediremos por: apariencia, aroma, sabor, etc. Pero, ¿cómo obtenemos frutas de mayor calidad?, podemos utilizar técnicas para mejorar los procesos de cultivo o recolección del fruto en su momento óptimo. De esta forma, cuando llegue la fruta al consumidor, alcanzará la calidad deseada.

La clasificación de la ciruela por su estado de maduración es un proceso que se realiza de manera manual, lo que puede llevar a clasificaciones erróneas. Este proceso históricamente ha sido realizado por operarios humanos, agricultores o técnicos, que con la experiencia adquirida durante los años de trabajo, son capaces, de manera visual, de clasificar las ciruelas por su calidad. Este método tiene grandes limitaciones ya que las decisiones que se toman dependen en gran medida de la experiencia de éstos. Se trata pues de un método altamente subjetivo, que puede derivar en errores en la cosecha, ya sea por recoger el fruto antes de tiempo o incluso con una fecha posterior a su estado óptimo. Para intentar solucionar este problema y ayudar a los operarios del sector, se están introduciendo nuevas técnicas [1] que tienen como finalidad la de servir de apoyo en la correcta toma de decisiones. Entre estas técnicas novedosas se encuentran las técnicas basadas en visión por computador [3], [4] y algoritmos de *machine learning* [2]. Este tipo de algoritmos requieren de un proceso intensivo de aprendizaje, que una vez concluido, genera potentes clasificadores que ayudarán a los agricultores y técnicos a tomar la decisión más acertada en función a los parámetros óptimos de cosecha.

La correcta clasificación de las ciruelas por su estado de maduración es de gran importancia, debido principalmente a que ciertas propiedades internas del fruto (sólidos solubles, brix, firmeza...) están directamente relacionadas con su estado de maduración. Para poder conocer el estado de estas variables es necesario la utilización de técnicas analíticas en un laboratorio. Los principales inconvenientes de estas técnicas se resumen en la necesidad de la destrucción del fruto para conocer sus propiedades químicas y los complejos y costosos materiales que se utilizan para ello.

La incorporación al proceso de técnicas de *machine learning*

¹<http://www.fao.org/home/en/>

por las industrias alimentarias en los procesos selectivos es habitual [2], aplicando desde bosques aleatorios (*random decision forests*) [5], máquinas de vectores de soporte [6] y redes neuronales en la evaluación de la calidad del producto [7].

El objetivo del trabajo que aquí se presenta es la detección de la variedad de la ciruela en su fase temprana de maduración, así como su estado de maduración. Las variedades seleccionadas en este estudio son:

- Black Splendor
- Angeleno
- OwenT

El análisis de imágenes se realizará a través de imágenes hiperespectrales de las diferentes variedades de ciruelas, divididas en diferentes semanas de maduración. El uso de imágenes hiperespectrales para el análisis de calidad en productos agroalimentarios es ampliamente utilizado [9], [11], obteniendo buenos resultados. Se pretende localizar espectros de frecuencia que nos permitan, a través de las propiedades físico-químicas que describen, clasificar las ciruelas por variedad y maduración. Los resultados serán comparados con técnicas previas donde únicamente se utilizaban imágenes tipo RGB [15].

El resto del trabajo se divide de la siguiente forma: la sección II describe el estado del arte de técnicas similares a las descritas en este trabajo. La sección III describe la metodología que se ha utilizado en este trabajo. Por último, los resultados obtenidos junto con las conclusiones, son presentados en las secciones IV y V, respectivamente.

II. ESTADO DEL ARTE

Entre los trabajos más destacados en esta línea de investigación se encuentra [1], el cual tiene como objetivo el estudio y detección de la maduración en los frutos con hueso.

La aplicación de técnicas de visión artificial para el análisis de los alimentos ha aumentado considerablemente en los últimos años [2]. La diversidad de las aplicaciones depende, entre otras cosas, del hecho de que los sistemas de visión artificial proporcionan información sustancial acerca de la naturaleza y los atributos de los objetos presentes en una escena. Otra característica importante de tales sistemas es que abren la posibilidad de estudiar estos objetos en las regiones del espectro electromagnético donde el ojo humano es incapaz de operar, como en el ultravioleta (UV), infrarrojo cercano (NIR) o infrarrojo (IR).

Investigadores de todo el mundo han estudiado el potencial de diversas técnicas para conocer la calidad de la fruta [4]. Una de las más utilizadas han sido las diferentes técnicas de espectroscópicas, como la NIR [13]. El éxito de la utilización de estas técnicas reside en las ventajas que aportan a los investigadores, estas son las siguientes:

- El proceso de medición es simple y rápido.
- Se trata de una técnica no destructiva.
- Permiten conocer varias propiedades de la fruta a la vez.

El inconveniente que tienen las técnicas de espectroscopia es que solamente nos aportan información de los componentes

químicos y físicos de la fruta en el punto medido, para poder obtener más información, es necesario combinar esta técnica con la adquisición de imágenes. Por un lado, se tiene la información obtenida de la adquisición de la imagen del fruto, que se trata de una información espacial: morfología, tamaño, etc. Por otro lado, mediante la espectroscopia, se obtiene información sobre los componentes químicos y propiedades físicas que la componen. Sin embargo, si nos centramos en las técnicas espectrales de imágenes, nos permiten la obtención de imágenes de frutas e información espectral simultáneamente, con las ventajas de una alta resolución espectral y múltiples bandas de ondas. De acuerdo con la resolución espectral, la espectroscopia de imágenes se puede dividir en imágenes multiespectrales, imágenes hiperespectrales e imágenes ultra-espectrales. Las imágenes multiespectrales y las imágenes hiperespectrales son factibles para la medición de los parámetros de calidad de la fruta [12].

Una nueva técnica ha surgido en los últimos años con fuerza en el campo del aprendizaje profundo (Deep learning en inglés) [14], se trata de las redes neuronales convolucionales (CNN en inglés) [7]. Estas redes basan su funcionamiento en un aprendizaje jerarquizado en el cual estructuras de alto nivel son construidas de manera automática a partir de estructuras de más bajo nivel llamadas capas, comenzado por los datos sin procesar: los píxeles de una imagen. Deep learning surge como una alternativa frente a una mayoría de técnicas de aprendizaje que están basadas solamente en una o, a lo sumo, dos capas de transformaciones no lineales de características.

El aprendizaje profundo a través de CNNs [14] es una alternativa a los métodos clásicos de clasificación que requieran de una cuidadosa selección de las características realizada a mano. Los métodos clásicos han demostrado ser bastante eficaces para resolver problemas simples o problemas bien delimitados, pero tropiezan con dificultades para hacerlos frente con problemas complejos del mundo real tales como objetos y reconocimiento de voz. Es en estos problemas complejos donde el aprendizaje profundo está resultando ser verdaderamente efectivo, siendo el problema aquí presentado como un problema complejo de visión.

III. METODOLOGÍA

Será necesaria la generación de un conjunto de imágenes hiperespectrales de los frutos que se van recolectando en diferentes semanas de maduración. Para ello, se requerirá el uso de hardware especializado que nos permita la captura de imágenes de las frutas en un entorno controlado de laboratorio. Así como un software específico de control para todo el hardware, el cual se describe a continuación:

- Cabina de iluminación Matcher Modelo MM-4e equipada con cuatro fuentes de luz: Simulador de luz diurna 6500K y de 5000K y una fuente ultravioleta para medir la fluorescencia si es necesario.
- Cámara hiperespectral Cuber UHD 285. Dicha cámara cuenta con un rango de longitud de onda comprendido entre los 450 - 950 nm con un intervalo de submuestreo cada 4 nm. Los fabricantes garantizan 125 canales de

información hiperespectral, aunque la cámara es capaz de ofrecer hasta los 138 canales.

- Plataforma giratoria diseñada y controlada por arduino para girar 90 grados cada pieza de fruta de forma automática.
- Software diseñado con MatLab para el control semi-automático de la plataforma giratoria y toma de imágenes hiperespectrales.

Para poder entender mejor el aspecto de las frutas capturadas y las mínimas diferencias que existen para el ojo humano, en la Figura 1 podemos observar un conjunto de imágenes RGB de las frutas empleadas en este estudio.




Figura 1. Ejemplo imágenes RGB. Angeleno, Black Splendor y OwentT

Las imágenes que captura la cámara hiperespectral son imágenes tipo CUE, que deben ser post-procesadas para obtener imágenes tipo PNG, utilizadas en este trabajo, que representan las 138 capas del espectro que ofrece la cámara. La Figura 2 muestra un ejemplo de ciertas bandas convertidas a imagen PNG.



Figura 2. Ejemplo imágenes procesadas fichero tipo CUE

Una vez creados los conjuntos de datos correspondientes, se han utilizado técnicas de aprendizaje profundo para generar modelos de clasificación basados en CNNs, en concreto se ha utilizado *Alexnet* [16], que a través de un proceso de optimización, se han obtenido los clasificadores destinados a detectar la variedad y la maduración de los frutos del ciruelo japonés.

El entrenamiento de este tipo de redes requiere de una estructura muy específica que posibilita todo el proceso de aprendizaje de la red. En el trabajo aquí presentado se ha utilizado el framework llamado Caffe², que nos permite realizar el proceso de aprendizaje.

Todo proceso estocástico, como el que nos compete en este trabajo, requiere realizar el mismo proceso de aprendizaje un determinado número de veces, para poder consolidar los resultados obtenidos. Para ello, en este trabajo hemos utilizado la técnica llamada K-fold cross validation, donde K=5. Esta técnica nos obliga a dividir el conjunto de imágenes en 5 particiones, donde usará un conjunto compuesto por 4 de estas particiones para entrenar a la red y 1 para validar los resultados. El proceso debe repetirse tantas veces como subconjuntos

se hayan realizado, en nuestro caso 5. Posteriormente, con cada subconjunto se repite nuevamente un total de 6 veces para el ajuste de la red, obteniendo así un total de 30 ejecuciones, lo que nos permite consolidar los resultados que arroje la red, a través de la media de los mismos.

IV. RESULTADOS

Entre los objetivos citados en este estudio se encuentra el análisis de la información hiperespectral de las imágenes de fruta, para obtener las longitudes de onda más prometedoras para su clasificación por variedad y madurez. Esto nos permitirá desechar gran cantidad de información hiperespectral y centrarnos en las bandas más interesantes que, como se puede ver en esta sección, ofrecen resultados muy robustos en relación a la clasificación de la variedad de la fruta, así como sobre su maduración.

En este apartado se presentan los resultados obtenidos por los diferentes clasificadores que se han optimizado utilizando *Alexnet* como CNN base. La Tabla I muestra una descripción de los los diferentes *datasets* utilizados.

Tabla I
CARACTERÍSTICAS DE LAS CIRUELAS

Dataset	Número de Imágenes ³	Fecha de recolección	Semanas de maduración
MW1	121 x 138	9-13 Mayo	6 Angeleno, 7 Owent y 7 BlackSplendor
MW2	147 x 138	23-27 Mayo	8 Angeleno, 9 Owent y 9 BlackSplendor
MW3	127 x 138	13-17 Junio	11 Angeleno, 12 Owent y 12 BlackSplendor
MW4	130 x 138	4-9 of Julio	14 Angeleno, 15 Owent y 15 BlackSplendor
All_MW	525 x 138	-	-

El trabajo que se ha llevado a cabo ha conestado de la optimización de 138 clasificadores diferentes, ya que cada uno de ellos se debía especializar en una de las bandas obtenidas de las imágenes tomadas con la cámara hiperespectral. Para la optimización de este trabajo se ha utilizado un equipo compuesto por una GPU Tesla K20.

A continuación se presentan los resultados obtenidos por los clasificadores especializados en la variedad de la fruta, así como los especializados en la maduración.

IV-A. Resultados clasificación por variedad

El objetivo de esta tarea es analizar si en diferentes estados de maduración, podemos encontrar diferentes longitudes de onda que ayuden a la clasificación por variedad de las ciruelas. Se presenta un conjunto de gráficas que resumen el resultado de estos clasificadores, así como se puede observar en cada uno de ellos la presencia de ciertas bandas espectrales que obtienen excelentes resultados de clasificación.

Los resultados presentados en la Fig. 3 se corresponden con las diferentes semanas de maduración indicadas en la Tabla I. Si analizamos los resultados atendiendo a su semana de maduración, puede observarse que para el *dataset MW1* todos

²<http://caffe.berkeleyvision.org>




Figura 3. Resultado de clasificación por variedad. *Datasets*: arriba izquierda MW1, arriba derecha MW2, abajo izquierda MW3, abajo derecha MW4

los frutos se encuentran en una etapa muy temprana de su ciclo de maduración. Esto tiene como consecuencia que las ciruelas se encuentran poco desarrolladas y el parecido entre ellas es elevado, independiente de la variedad de las mismas. Como puede observarse en la figura, la línea de tendencia mostrada en los resultados, nos indica que entre las capas 25 y 35 se muestra una tendencia de mayor precisión en la clasificación, siendo la mejor de ellas la capa número 29 con una precisión de un 92,32 %.

Si atendemos a los datos del *dataset MW2*, se obtienen mejores resultados que con el *dataset MW1*. Esto es debido a que las frutas van avanzando en su proceso de maduración, lo que hace que se encuentren más desarrolladas y por tanto las diferencias entre variedades empiecen a ser palpables. Como puede observarse, atendiendo nuevamente a la línea de tendencia mostrada, las últimas capas, entre las 129 y 137, ofrecen los mejores resultados de clasificación por variedad, teniendo en cuenta que todas las capas se obtienen una precisión mayor al 75 %. En este proceso de optimización del clasificador por variedad, se ha alcanzado el óptimo en la capa 130 con un 96,95 % de aciertos.

A medida que avanzamos en la semana de maduración,

dataset MW3, el clasificador mejora su precisión en todas sus capas respecto a los resultados obtenidos con los *datasets* anteriores. Casi todas las capas hiperespectrales del *dataset MW3* obtienen una precisión superior al 75 %. La línea de tendencia nos ayuda a confirmarlo. A diferencia de los *dataset* anteriores, en éste se encuentran varias capas con una precisión superior al 96,48 %.

Los resultados obtenidos con el último *dataset* utilizado, *MW4*, aportan buenos resultados globales de todas las capas en cuanto a precisión media para clasificar las variedades de ciruelo estudiadas. En esta última fase de maduración las diferencias entre las variedades son notorias a simple vista y esto permite que su clasificación sea más sencilla, es por ese motivo por el cual los resultados globales obtenidos son mejores. La línea de tendencia presente en la gráfica muestra que todas las capas obtienen buenos datos, estando la mayoría de las capas por encima del 80 %. El óptimo se encuentra en la capa 55 con un valor de precisión del 100,00 % en la clasificación por variedad.

Hasta aquí, podemos observar que a medida que la fruta madura, es más sencillo detectar su variedad, obteniendo un conjunto de capas hiperespectrales con mayor precisión. Estas características también pueden deberse a las diferentes fases de maduración que tienen las variedades que se han utilizado en este estudio. La variedad *Angeleno* es la que tiene mayor ciclo de maduración, de ahí que la fruta presenta menos cambios a lo largo del periodo estudiado, pero el resto si que presenta modificaciones, lo que permite a la red clasificar mejor las variedades.

En el estudio que se detalla a continuación, se han mezclado todas las fases de maduración de las diferentes variedades, para poder desestacionar la componente del tiempo de maduración. Con esto se pretende no facilitar a la red la detección gracias a grandes cambios en ciertas variedades y cambios pocos significativos en las variedades de ciclo largo. La Figura 4 muestra los resultados obtenidos de este nuevo estudio.




Figura 4. Resultado clasificación por variedad, *Dataset ALL*

El *dataset* utilizado donde la fecha de maduración del fruto no es relevante, arroja resultados del 70 % de precisión como mínimo. Si observamos la línea de tendencia presente en la Fig. 4 se aprecia que entre las capas 17 - 47 se obtienen muy buenos resultados, siendo la mejor capa la 25 con un 85 % de precisión. Este dato nos indica que es posible la clasificación de ciruelas por su variedad, gracias a la precisión obtenida del

85 %, siendo indiferente la fase de maduración en la que se encuentre el fruto.

La Tabla II muestra un resumen de las propuestas estudiadas con los diferentes *dataset* empleados. En esta tabla se resumen las capas que han obtenido mayores resultados, así como el intervalo de capas donde se aprecian diferencias con respecto al resto de capas.

Tabla II
PROPOSICIÓN CAPAS PARA CLASIFICADOR

Semanas de maduración	<i>Dataset</i>	Capas	% acierto máximo
9–13 Mayo	MW1	29	92,32 %
23–27 Mayo	MW2	92, 130	96,95 %
13–17 Junio	MW3	15, 19, 75, 84, 101	96,48 %
4–9 of Julio	MW3	55	100,00 %
-	All_MW	25	89,45 %

Podemos observar, según los datos presentados, que a diferentes fases de maduración de los frutos, la información relevante para poder clasificar las variedades según las imágenes hiperespectrales, se encuentran en diferentes bandas del espectro.

Por otro lado, también podemos observar que los resultados son excelentes, si nos centramos en la capacidad de clasificación de las redes optimizadas, ya que, independientemente de las capas, es posible generar una buena clasificación de las variedades empleadas.

Si comparamos los datos obtenidos en el estudio que aquí se presenta, con los datos obtenidos en estudios similares, pero utilizando imágenes RGB, podemos observar ciertas diferencias. Anteriormente se ha abordado la problemática de la clasificación de ciruelas por su variedad mediante el uso de la misma CNN, *Alexnet* [15], pero con la diferencia que en este trabajo, las imágenes utilizadas eran imágenes RGB. Esta circunstancia nos permite comparar ambos estudios, resumiendo los datos en la Tabla III.

Tabla III
RESUMEN DE RESULTADOS UTILIZANDO IMÁGENES RGB FRENTE A IMÁGENES HIPERESPECTRALES

<i>Dataset</i>	RGB	Hiperespectral - Número capa
MW1	0.8960 ± 0.010	0.9232 ± 0.060 - 29
MW2	0.9299 ± 0.015	0.9695 ± 0.040 - 130
MW3	0.9739 ± 0.008	0.9648 ± 0.030 - 19
MW4	0.9674 ± 0.005	1.0000 ± 0.010 - 55
All_MW	0.9071 ± 0.010	0.8945 ± 0.030 - 25

Como puede observarse, los resultados obtenidos al clasificar ciruelas usando imágenes hiperespectrales son superiores a los resultados obtenidos anteriormente, independientemente si lo que buscamos es un conjunto de capas que nos indiquen propiedades físico-químicas de las ciruelas que nos permitan realizar la clasificación, aunque si realizamos un test estadístico para comparar ambas técnicas nos ofrece resultados no significativos, como indica la Tabla IV-A.

Tabla IV
TEST DE WILCOXON PARA COMAPRACIÓN DE TÉCNICAS

VS	R^+	R^-	P-value	P-value Asintótico
Híper	8.0	7.0	≥ 0.2	0.787406

Atendiendo a la capa que obtiene mejor resultado de clasificación, al utilizar imágenes hiperespectrales, y la misma red CNN *-Alexnet-*, los resultados son mejores que al utilizar imágenes RGB. Se podría afirmar que el estudio de la imagen hiperespectral, al contener propiedades físico-químicas del fruto, ofrece mejores resultados frente a una clasificación por imagen convencional, donde únicamente la forma, tamaño y color serían las componentes que intervienen en dicha clasificación.

IV-B. Resultados clasificación por estado de maduración

De igual forma que con los resultados presentados en la sección anterior, donde hemos obtenido buenos clasificadores que se centran en la variedad de la fruta analizada, en esta sección se presenta un nuevo estudio donde se optimizan clasificadores orientados a determinar la fecha de maduración de la misma.

En este caso, los *dataset* con los que se ha trabajado están agrupados por variedad y agrupados en 4 clases diferentes, cada una de las semanas de maduración cuando fueron recogidos los frutos. Se utilizan para este estudio nuevamente las imágenes hiperespectrales, donde se intenta encontrar un conjunto de bandas que nos permitan clasificar las frutas por su estado de maduración.

La Figura 5, muestra los resultados obtenidos.

Si observamos los resultados obtenidos por el clasificador de la variedad *Black Splendor* por semana de maduración, se observa que existe una gran diferencia entre las diferentes capas de las imágenes hiperespectrales. Como se puede ver en la Figura 5, la precisión obtenida se puede dividir en tres bloques que son claramente diferenciables. Un primer bloque, de la capa 1 - 65, con un buen índice de precisión, entorno al 96 %. El segundo bloque, rango comprendido entre la capa 66 - 113, donde la precisión decae hasta valores cercanos al 40 %. Un último bloque, 114 - 137, donde la precisión se sitúa de nuevo en el 96 %.

Por otro lado, los resultados obtenidos al clasificar imágenes hiperespectrales de la variedad *OwenT* muestran, que al igual que sucedía con los resultados obtenidos en la variedad *Black Splendor*, sus resultados pueden dividirse en tres bloques. En el primer bloque, que comprende de la capa 1 hasta la capa 17 tienen una precisión cercana al 98 %. El segundo bloque, capa 18 - 57, obtiene mala precisión, algunas de sus capas tienen una precisión del 25 %. De la capa 58 a la 137 la precisión crece situándose en un rango comprendido entre el 80 % y el 98 %.

Por último, a diferencia de lo que ocurre con las variedades *OwenT* y *Black Splendor* los resultados obtenidos al clasificar la variedad *Angeleno* por maduración son muy similares en todas sus capas. La precisión en ninguna de las capas es




Figura 5. Clasificación por maduración: *Black Splendor*, *OwenT*, *Angelino*.

inferior al 80 %. La capa que ofrece mejor precisión es la capa 30 con un 98,78 %. Esto puede ser debido a que esta variedad es una variedad de ciclo muy largo, y las fechas en las que se ha recolectado los frutos, debido a su ciclo de maduración, no son lo suficientemente significativas en el tiempo.

A continuación, en la tabla V se muestra un resumen de las capas que obtienen los mejores resultados para cada una de las variedades.

Tabla V
PROPOSICIÓN CAPAS PARA CLASIFICAR POR ESTADO DE MADURACIÓN

Variedad	Rango de capas	% máximo de acierto
<i>Angelino</i>	94 - 137	96 %
<i>Black Splendor</i>	1 - 65 / 114 - 137	98 %
<i>OwenT</i>	1 - 17 / 58 - 137	98,78 %

V. CONCLUSIONES

Los resultados presentados en este trabajo muestran que es posible clasificar, con un alto rango de acierto, las variedades de ciruelo japonés seleccionadas para este estudio por medio de las imágenes hiperespectrales tomadas en un entorno de laboratorio. Los datos obtenidos demuestran que es posible clasificar la variedad de la ciruela atendiendo a su información hiperespectral y la semana de maduración en la que se encuentra, se han obtenido resultados del 92,32 %, 96,95 %, 96,48 % y 100,00 % respectivamente, para las cuatro fases de maduración empleadas en este estudio. Por otro lado, si la fase de maduración no se tiene en cuenta, se obtiene unos

resultados del 89,45 %. Estos datos superan un estudio previo donde se emplearon imágenes RGB, permitiendo obtener clasificadores más eficaces.

Estos resultados nos permiten afirmar que es posible clasificar la variedad de una ciruela gracias al estudio de su espectro. Además, los datos obtenidos y presentados, nos permiten vislumbrar ciertas zonas de interés en el espectro de las diferentes variedades, atendiendo a su fecha de maduración, donde, con un estudio más profundo, se podrán obtener propiedades físico-químicas de los frutos a través de su espectro.

AGRADECIMIENTOS

Agradecemos el apoyo del Ministerio de Economía y Competitividad proyecto TIN2017-85727-C4-{2,4}-P, Junta de Extremadura, Consejería de Comercio y Economía, proyecto IB16035 a través del Fondo Europeo de Desarrollo Regional, “Una manera de hacer Europa”.

REFERENCIAS

- [1] Wang, H., Peng, J., Xie, C., Bao, Y., He, Y. “Fruit quality evaluation using spectroscopy technology: a review,” *Sensor* 15(5), 11889-11927, 2015.
- [2] Sergio Cubero, Nuria Aleixos, Enrique Moltó, Juan Gómez-Sanchis, and Jose Blasco. “Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables,” *Food and Bioprocess Technology*, 4(4):487–504, 2011.
- [3] M.T. Riquelme, P. Barreiro, M. Ruiz-Altisent, and C. Valero. “Olive classification according to external damage using image analysis,” *Journal of Food Engineering*, 87(3):371–379, 2008.
- [4] P.B. Pathare, U.L. Opara, and F. A. J. Al-Said. “Colour measurement and analysis in fresh and processed foods: A review,” *Food and Bioprocess Technology*, 6(1):36–60, 2013.
- [5] Pal, M. “Random forest classifier for remote sensing classification,” *International Journal of Remote Sensing*, 26(1), 217-222. 2005.
- [6] Danfeng Wang, Xichang Wang, Taiang Liu and Yuan Liu, “Prediction of total viable counts on chilled pork using an electronic nose combined with support vector machine,” *Meat Science*, Volume:90, pag:373 - 377, 2012.
- [7] Krizhevsky, A., Sutskever, I., Hinton “Imagenet classification with deep convolutional neural networks. In: *Bartlett, P., Pereira, F., Burges, C., Bottou, L., Weinberger, K. (eds.)* Advances in Neural Information Processing Systems 25, pp. 1106–1114, 2012
- [8] C. Yang, W.S. Lee, and P. Gader. “Hyperspectral band selection for detecting different blueberry fruit maturity stages,” *Computers and Electronics in Agriculture*, 109:23–31, 2014.
- [9] Lu, R., Ariana, D. P. “Detection of fruit fly infestation in pickling cucumbers using a hyperspectral reflectance/transmittance imaging system,” *Postharvest Biology and Technology*, 81, 44-50, 2013.
- [10] Haff, R. P., Saranwong, S., Thanapase, W., Janhira, A., Kasemsumran, S., Kawano, S. “Automatic image analysis and spot classification for detection of fruit fly infestation in hyperspectral images of mangoes,” *Postharvest Biol. Technol.* 86, 23-28, 2013
- [11] Dubey, S. R., Jalal, A. S. “Adapted approach for fruit disease identification using images,” arXiv preprint arXiv:1405.4930, 2014
- [12] Hailong Wang, Jiyu Peng, Chuanqi Xie, Yidan Bao y Yong He “fruit quality evaluation using spectroscopy”, *Sensor*, 21 mayo 2015
- [13] S. Edward Law. “Scatter of near-infrared radiation by cherries as a means of pit detection,” *Journal of Food Science*, 38(1):102 – 107, 1973.
- [14] LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. “Deep learning” *Nature* 521, no. 7553 436-444. 2015
- [15] Rodríguez, Francisco J., García, Antonio, Pardo, Pedro J., Chávez, Francisco, Luque-Baena, Rafael M., “Study and classification of plum varieties using image analysis and deep learning techniques” *Progress in Artificial Intelligence*, 7(2), 119-127, 2018
- [16] Krizhevsky, Alex and Sutskever, Ilya and Hinton, Geoffrey E., “Image-Net Classification with Deep Convolutional Neural Networks” *NIPS’12*, 1097–1105, 2012