

Estudio y caracterización de variedades de ciruelas utilizando análisis de imagen y técnicas de Deep Learning

Francisco J. Rodríguez, Antonio García, Pedro J. Pardo, Francisco Chávez, and Rafael
M. Luque-Baena

Centro Universitario de Mérida
C/Santa Teresa de Jornet 35, Mérida
Universidad de Extremadura, España

{fjrodriguez, antoniogv, pjpardo, fchavez, rmluque}@unex.es

Resumen Este trabajo está enfocado a la distinción y análisis de diferentes variedades de ciruelas utilizando técnicas de tratamiento de imágenes y minería de datos. En concreto, se analizan cuatro conjuntos de datos en los que se presentan tres variedades de ciruela en fase de maduración temprana: *Black Splendor*, *Owent* y *Angelino*. La principal dificultad es que la identificación visual de la variedad no es evidente e incluso al personal experto le cuesta discernir entre las tres categorías en este fase. Se ha utilizado un clasificador basado en redes neuronales convolucionales en el que no es necesario realizar una extracción de características explícita de la imagen, sino que el método determina aquello más interesante para su categorización. Los resultados obtenidos son prometedores, con una tasa de acierto superior al 90 % y utilizando sólo imágenes en el espacio de color RGB.

Keywords: redes neuronales convolucionales, procesamiento de imagen, ciruela

1. Introducción

España es considerada como uno de los mayores productores de ciruelas de la Unión Europea. En los últimos años ha venido creciendo el volumen de toneladas producidas, de las cuales su gran mayoría son exportadas, creando así un fuerte mercado de exportación. Según datos de Ministerio de Medio Ambiente, Merdio Rural y Marino del Gobierno de España (MARM), España ha producido en 2011 unas 200.000 toneladas de ciruelas. Las principales regiones productoras de ciruelas han sido Extremadura, Región de Murcia y Andalucía. Esta notable producción de ciruelas se debe a las condiciones de cultivo de las diferentes regiones productoras que permiten una maduración temprana de la ciruela, lo que repercute en una ventaja competitiva frente a otros mercados. Pero cabe destacar que la producción no está exenta de problemas, entre ellos problemas estructurales como la sensibilidad al virus Sharka que afecta la calidad del producto, la autoincompatibilidad floral debido a la inmensa mayoría de variedades y la calidad del producto que en ocasiones es mediocre.

F. J. Rodríguez et al

La aplicación de técnicas de visión artificial para el análisis de los alimentos ha aumentado considerablemente en los últimos años [9,1,10]. La diversidad de las aplicaciones depende, entre otras cosas, en el 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. Existen numerosos trabajos que analizan frutas y verduras mediante sistemas de visión por computador basados en imágenes en color, obtenidas habitualmente utilizando cámaras que capturan en el espectro visible [1,8,3].

Con objeto de mejorar la calidad del producto y realizar un seguimiento, en este trabajo hemos considerado necesario un análisis preventivo de la producción de ciruelas, con la necesidad de la identificación automática de la variedad en fases de maduración de la misma, tarea que acometemos en este trabajo preliminar mediante análisis de imágenes. En concreto, la diferenciación se realizará en etapas de maduración temprana no aptas aún para el consumo, pero cuyo interés principal radica en su dificultad para discernir entre categorías de forma visual. Así, si conseguimos buenas tasas de acierto en la diferenciación entre clases en estas etapas, podemos asegurar que en etapas posteriores (la diferencia entre variedades es más clara) el resultado será más favorable. Una vez identificada correctamente la variedad, podremos acometer nuevos análisis que deben repercutir muy positivamente en la calidad de la producción final. Como técnica de clasificación haremos uso de las redes neuronales convoluciones, cuya principal ventaja radica en que no necesitamos extraer previamente las características de la imagen a considerar, sino que se toma como entrada la imagen *raw* en color RGB y la propia red genera un conjunto de filtros válidos para realizar la clasificación que se requiere.

El trabajo se estructura como sigue: la Sección 2 describe los datos a analizar y los diferentes dispositivos hardware utilizados para el estudio; la Sección 3 presenta la metodología propuesta dividida en dos etapas: segmentación de la imagen capturada y sistema de clasificación utilizado; la Sección 4.2 describe el estudio experimental realizado, mientras que finalmente la Sección 5 esboza las conclusiones obtenidas en este trabajo.

2. Marco preliminar

En esta sección describiremos los datos a procesar y los dispositivos *hardware* empleados en este estudio. Para ello, hemos comenzado a analizar 3 variedades muy características de ciruelas del campo extremeño. Estas variedades son: *Black Splendor*, *OwenT* y *Angelino*. Las variedades incluidas en este análisis las hemos ordenado por fecha estimada de recolección y hemos intentado incluir un espectro de recolección desde variedades tempranas, como la *Black Splendor*, fecha de recolección mediado de junio, *OwenT*, fecha de recolección primeros de julio y *Angelino*, una variedad muy tardía con fecha de recolección final de agosto. A continuación detallamos las características de cada una de las variedades utilizadas en este estudio.

- *Black Splendor*:
 - Fecha de maduración: Temprana.
 - Origen: ARS, California, EE.UU.
 - Titular: USDA, California, EE.UU.

Title Suppressed Due to Excessive Length

- Árbol: hábito de crecimiento estándar, vigor mediano, auto-incompatibles con floración intensa floración (polinizador recomendada: Mirabolano Rosso)
- Productividad y conducta: producción temprana, elevado y constante rendimiento.
- Fruto: tamaño grande, redonda, de piel oscura, carne roja, muy firme, excelente sabor dulce.
- En general: variedad temprana con bajo requerimiento de frío (200 horas) con frutos grandes sabroso atractivo; fácil manejo en campo, producción alta y consistente.
- *OwenT*:
 - fecha de maduración: Media.
 - Origen: USDA, California, EE.UU.
 - Árbol: hábito de crecimiento estándar, de vigor alto; autoestériles con intensa floración, (polinizadores recomendada: Fortuna, Negro Ámbar, selección de Myrobalan - Mirabolano Rosso).
 - Productividad y conducta: producción temprana, rendimiento elevado y constante
 - Fruto: grande, redonda achatada, piel negro, carne de color amarillo claro, muy firme, excelente sabor.
 - En general: variedad media con gran fruta sabrosa atractiva; fácil manejo en campo, alto y rendimiento consistente.
- *Angelino*:
 - fecha de maduración: Tardía.
 - Origen: Sun World International, EE.UU.
 - Titular: Equipo Cultivo de frutas, Italia.
 - Árbol: hábito de crecimiento estándar, muy alto vigor, auto-incompatibles (recomendado polinizador: Mirabolano Rosso)
 - Productividad y conducta: consistentemente productiva sólo en condiciones ideales, lento inicio de conducta.
 - Fruto: tamaño grande, redondo, piel negro, floración cerosa; carne amarilla, firme, buen sabor.
 - En general: variedad tardía de mucho interés para el aspecto y la vida poscosecha de fruta, se deben plantar con polinizadores para fomentar la producción.

Para la captura de imágenes se ha utilizado una cámara digital científica Qimaging Retiga-Exi. Esta cámara está provista de un sensor CCD color Sony ICX285 de escaneado progresivo con una resolución de 1392 x 1040 píxeles cuadrados y 12 bits por píxel. La montura del objetivo es tipo C y la interfaz de comunicaciones es FireWire, lo que le permite proporcionar hasta 10 frames por segundo a máxima resolución y profundidad de bit. Presenta como una de sus principales características la gran sensibilidad y la linealidad en la respuesta en un extenso rango de valores de luminancia. Además presenta muy poco ruido térmico debido a su sistema de refrigeración basado en una célula Peltier termoeléctrica.

La captura de imágenes se ha realizado en una cabina de iluminación GTI Mini-Matcher modelo MM-4e dotada de 4 fuentes luminosas: Simulador de iluminante D65, Simulador de iluminante D50, simulador de iluminante A y fuente ultravioleta para

F. J. Rodríguez et al



Figura 1. Imagen del proceso de captura de datos. La cámara digital científica utilizada es la mostrada en color negro en el centro de la imagen.

medir fluorescencias. En concreto, se ha utilizado para todas las capturas el simulador D65, ampliamente utilizado en colorimetría. La cabina presenta un fondo gris espectralmente neutro N7 que facilita las tareas de segmentación de la imagen y es robusto frente a cambios de fuente luminosa (Figura 1).

Finalmente, para la implementación de la red neuronal convolucional hemos utilizado la librería Caffe¹, realizando el entrenamiento de la red en una GPU Nvidia Tesla K20 con 5GB de memoria RAM y 2496 nodos de computo.

3. Sistema de estudio y caracterización de ciruelas

En esta sección se describe en detalle el sistema propuesto en este trabajo para el estudio y la caracterización de variedades de ciruelas. Este sistema se compone de dos elementos principales: las imágenes obtenidas tras el proceso de captura son sometidas a una etapa de segmentación para extraer la zona de la imagen en la que aparece la ciruela (Sección 3.1). Finalmente, utilizamos un clasificador basado en redes neuronales convolucionales para identificar la variedad de ciruela (Sección 3.2).

3.1. Segmentación

En esta sección resumiremos el proceso de segmentación a partir de la imagen de entrada (imagen de la derecha en la Figura 2). Inicialmente, en cada sesión de captura se obtendrá una imagen del fondo de la escena sin ninguna pieza, con objeto de utilizarlo para obtener cada pieza de ciruela analizada. El objetivo es segmentar la pieza y quedarnos sólo con la parte que nos interesa, como puede observarse en la imagen de la izquierda de la Figura 2. Los pasos a seguir para realizar dicha segmentación son los siguientes:

¹ <http://caffe.berkeleyvision.org/>

Title Suppressed Due to Excessive Length




Figura 2. La imagen de la derecha muestra un ejemplo de la captura de datos realizada. La imagen de la izquierda muestra las tres variedades analizadas segmentadas: *Angelino*, *Black Splendor* y *OwenT* en la primera, segunda y tercera fila, respectivamente. Se observa el parecido existente entre las tres variedades.

1. Se procede a realizar una resta entre la imagen del fondo y la imagen capturada con la pieza en el espacio de color RGB. Este proceso implica que los píxeles con mayor diferencia de tonalidad se corresponderán con la pieza de ciruela.
2. Umbralización de la imagen con umbral fijo (40 en este trabajo). Esta región es una versión preliminar de la obtendremos finalmente.
3. Dada la región obtenida anterior, nos quedamos con una franja del fondo alrededor de la pieza de fruta, mediante la aplicación del operador morfológico de dilatación. Obtenemos el valor mediano de los píxeles de esta franja para utilizarlo en la obtención de una máscara más cercana a la real y evitar variaciones de iluminación entre capturas.
4. Como sabemos que el fondo es gris y los píxeles de la ciruela de color verdoso, umbralizamos la imagen de diferencias con el valor mediano sabiendo que las variaciones de color entre canales, si se trata de la ciruela, serán mayores que un valor relativamente pequeño (en este trabajo se ha utilizado un umbral de 10).
5. Posteriormente limpiamos la máscara rellenando huecos y aplicando erosión y dilatación.
6. Para quedarnos con la segmentación final multiplicamos la máscara por la imagen original y la encuadramos en una región de 250x250. Este último paso es importante debido a que la red neuronal convolucional tendrá como entrada imágenes de este tamaño concreto.

3.2. Clasificación mediante redes neuronales convolucionales

Durante los últimos años, ha emergido un nuevo área dentro del aprendizaje automático conocida como *deep learning* [2]. Este nuevo área engloba diversas técnicas que se caracterizan fundamentalmente por la utilización de un proceso de aprendizaje jerárquico, en el que partiendo de estructuras de bajo nivel se construyen estructuras de más alto nivel a través de múltiples capas.

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

F. J. Rodríguez et al

no lineales de características. Ejemplos de dichas técnicas son las máquinas de vectores soporte o la regresión logística. Estas técnicas han demostrado su utilidad para resolver problemas bien delimitados o simples, sin embargo, encuentran dificultades cuando afrontamos problemas reales complejos como el reconocimiento del habla o la identificación de objetos. Es precisamente en estas áreas donde se ha extendido el uso de técnicas de *deep learning*, obteniendo reducciones muy significativas de la tasa de error en dichas tareas.

En este trabajo, nos centramos en un tipo de técnica de *deep learning* para aprendizaje supervisado conocida como redes neuronales convolucionales [4,6], que ha demostrado un excelente rendimiento para el reconocimiento de objetos en imágenes.

Las redes neuronales convolucionales se benefician de la estructura espacial de los datos de entrada, en este caso imágenes. Para ello, utilizan una arquitectura que se basa en tres principios fundamentales [7] :

- Campos receptivos locales. Cada neurona de las capas intermedias está conectada a una pequeña región de la capa de entrada. Este tipo de capas se conocen como capas convolucionales.
- Parámetros de pesos y *bias* compartidos. Todas las neuronas de cada uno de los mapas de características comparten estos parámetros. De esta forma, estas neuronas se especializan en la detección de una determinada característica en distintas zonas de la imagen. Al mismo tiempo se reduce de forma muy notable el número de parámetros a establecer durante el proceso de aprendizaje de la red.
- Capa de *pooling*. Este tipo de capas reciben como entrada cada uno de los mapas de características y obtienen un nuevo mapa de características simplificado. Por ejemplo, en las capas de tipo *max-pooling*, cada neurona de esta capa obtiene como salida el valor máximo de activación de una pequeña región de un determinado mapa de características.

En los últimos años se han desarrollado múltiples modelos de redes convolucionales. Para el sistema de clasificación de ciruelas desarrollado en este trabajo, hemos utilizado la red *Alexnet* [5]. Esta red convolucional se desarrolló para la clasificación de imágenes de alta resolución del conjunto de datos IMAGENET². En la Figura 3, podemos ver un esquema resumido de su arquitectura. Para una descripción más detallada de la red es posible encontrar el código y los distintos parámetros de la red aquí: <http://code.google.com/p/cuda-convnet/>.

La red Alexnet se compone de 5 capas de tipo convolucional y 3 capas totalmente conectadas. A diferencia de las capas convolucionales, las neuronas de las capas totalmente conectadas tienen conexiones con todas las neuronas de entrada. Además, se utilizan capas de normalización de la respuesta después de las dos primeras capas convolucionales. El objetivo de estas capas de normalización es implementar lo que se conoce como inhibición lateral. Mediante este proceso, una neurona excitada domina o suaviza a las neuronas vecinas y se crean contrastes más altos [5]. Las capas de *pooling* se sitúan después de estas capas de normalización y después de la quinta capa convolucional.

² <http://www.image-net.org/>

Title Suppressed Due to Excessive Length




Figura 3. Arquitectura de la red Alexnet.

4. Estudio Experimental

En esta sección, describimos los experimentos computacionales realizados para validar el rendimiento del sistema propuesto para el estudio y caracterización de variedades de ciruelas. Para ello, en primer lugar, presentamos los conjuntos de datos utilizados para dichos experimentos (Sección 4.1), y en segundo lugar, detallamos los resultados obtenidos en dichos experimentos (Sección 4.2).

4.1. Marco experimental

Para validar el sistema de clasificación de variedades de ciruelas, hemos creado 4 conjuntos de datos diferentes, que se caracterizan por los distintos niveles y tipos de maduración de las ciruelas. Además, cada conjunto de datos está duplicado, uno con imágenes en color y otro con imágenes en blanco y negro. Cada ciruela de los diferentes conjuntos de datos está fotografiada desde 4 ángulos distintos. A continuación se describen cada uno de estos conjuntos de datos.

- CD1: formado por 121 imágenes de ciruelas, recogidas del árbol durante la semana del 9 de Mayo. Es decir, con una maduración de 7 semanas para la variedad *Black Splendor* y 6 semanas para las variedades *OwenT* y *Angelino*.
- CD2: formado por 121 imágenes de las mismas ciruelas del conjunto de datos CD1, con una semana más de maduración fuera del árbol.
- CD3: formado por 147 imágenes de ciruelas, recogidas del árbol con 9 semanas de maduración para la variedad *Black Splendor* y 8 semanas para las variedades *OwenT* y *Angelino*.
- CD4: formado por las imágenes de los conjuntos de datos CD1 y CD2.

Para el entrenamiento de la red convolucional se utilizan el 75 % de las imágenes de cada conjunto de datos, mientras que el 25 % restante se utiliza para su validación. Para cada experimentación, se han realizado además 5 particiones distintas de entrenamiento y validación, utilizando semillas diferentes. Es importante destacar que las imágenes se presentan a la red sin ningún tipo de preprocesamiento adicional al realizado en la fase

F. J. Rodríguez et al

de segmentación, salvo la aplicación de una normalización habitual en las redes neuronales convolucionales que consiste en restar a cada píxel el valor medio de los píxeles de la imagen. Dicha normalización mejora considerablemente el resultado obtenido por este tipo de redes.

4.2. Resultados

El objetivo de esta sección es analizar los resultados obtenidos por el sistema de clasificación. Para ello, en la Tablas 1 y 2, se presentan los resultados obtenidos por la red neuronal convolucional sobre los 4 conjuntos de datos, utilizando como entrada las imágenes en color y en blanco y negro, respectivamente. Además, se han probado diversas configuraciones de dos parámetros del proceso de aprendizaje, el número de épocas (*nepochs*: 50, 100 y 300) y el ratio de aprendizaje de la red (*lr* : 0,01 y 0,001). Es importante destacar además que durante el proceso de aprendizaje el ratio de aprendizaje se va reduciendo, en este caso en particular, un 10 % cada *nepochs*/3 épocas.

<i>nepochs</i>	<i>lr</i>	Conjunto	Prec. (Test)	Desv.
300	0.01	CD1	88,80 %	4,08
300	0.001	CD1	89,60 %	4,09
300	0.01	CD2	92,40 %	1,34
300	0.001	CD2	92,00 %	2,83
300	0.01	CD3	93,80 %	1,09
300	0.001	CD3	90,80 %	3,03
300	0.01	CD4	96 %	0
300	0.001	CD4	95,20 %	1,09
100	0.01	CD1	71,40 %	8,62
100	0.001	CD1	58,80 %	9,57
100	0.01	CD2	91,40 %	4,50
100	0.001	CD2	57,20 %	5,35
100	0.01	CD3	90,20 %	1,30
100	0.001	CD3	71,20 %	1,79
100	0.01	CD4	92,40 %	1,94
100	0.001	CD4	71,00 %	1,41
50	0.01	CD1	89,20 %	2,94
50	0.001	CD1	36,60 %	5,81
50	0.01	CD2	90,80 %	2,77
50	0.001	CD2	45,80 %	11,09
50	0.01	CD3	93,40 %	3,58
50	0.001	CD3	42,00 %	0
50	0.01	CD4	82,80 %	2,28
50	0.001	CD4	51,20 %	3,11

Tabla 1. Resultados del sistema de clasificación para imágenes en color

Analizando los resultados obtenidos, podemos destacar varios aspectos importantes:

- Los valores de acierto obtenidos para todos los conjuntos de datos son muy destacables. En particular, se alcanza un acierto máximo del 93,60 % para el conjunto CD1, utilizando imágenes en blanco y negro, entrenado la red durante 300 épocas y con un ratio de aprendizaje de 0,01. En cuanto al conjunto CD2, el mejor valor

Title Suppressed Due to Excessive Length

<i>nepochs</i>	<i>lr</i>	Conjunto	Prec. (Test)	Desv.
300	0.01	CD1	93,60 %	5,13
300	0.001	CD1	77,60 %	1,34
300	0.01	CD2	85,20 %	4,60
300	0.001	CD2	66,20 %	4,38
300	0.01	CD3	93,40 %	3,29
300	0.001	CD3	82,00 %	2,74
300	0.01	CD4	93,80 %	1,09
300	0.001	CD4	94,60 %	0,89
100	0.01	CD1	79,80 %	13,95
100	0.001	CD1	42,80 %	5,26
100	0.01	CD2	67,00 %	6,73
100	0.001	CD2	43,00 %	11,68
100	0.01	CD3	88,00 %	1,41
100	0.001	CD3	63,20 %	5,93
100	0.01	CD4	94,20 %	2,16
100	0.001	CD4	58,60 %	4,50
50	0.01	CD1	78,00 %	0
50	0.001	CD1	34,00 %	0
50	0.01	CD2	69,40 %	1,95
50	0.001	CD2	37,20 %	2,68
50	0.01	CD3	79 %	1,87
50	0.001	CD3	42,00 %	0
50	0.01	CD4	86,80 %	7,60
50	0.001	CD4	38 %	0,02

Tabla 2. Resultados del sistema de clasificación para imágenes en blanco y negro

de acierto es de un 92,40 %, en este caso con imágenes en color. Finalmente, para el conjunto de datos CD3, el porcentaje de acierto máximo es de un 93,80 % y para el conjunto CD4 de un 96 %, en ambos casos con imágenes en color

- El mejor valor de acierto obtenido es de un 96 %, en el conjunto CD4, que es bastante superior al obtenido en otros conjuntos de datos. Es importante destacar que esta mejora puede estar influenciada por una mejora del enfoque en las imágenes de dicho conjunto, lo que nos ha permitido obtener imágenes de mayor nitidez.
- En cuanto a la diferencia de rendimiento entre la utilización de imágenes en color e imágenes en blanco y negro, destacar que los resultados son en la mayoría de los casos mejores para imágenes en color. En este aspecto, es interesante destacar que para imágenes en color se pueden obtener resultados ya muy competitivos con solo 50 épocas (excepto para el conjunto CD4), a diferencia de lo que ocurre con imágenes en blanco y negro con el mismo número de épocas. Esto nos puede indicar que el proceso de aprendizaje es generalmente más rápido utilizando la información de color, aunque aumentando el número de épocas se pueden obtener resultados similares con las imágenes en blanco y negro e imágenes en color.

5. Conclusiones

En este trabajo hemos presentado un sistema completo para el análisis y caracterización de tres tipos de variedades de ciruelas en estados tempranos de maduración: *Black Splendor*, *Owent* y *Angelino*. Este sistema se compone de un proceso de toma

F. J. Rodríguez et al

y segmentación de imágenes y utiliza una red neuronal convolucional que es capaz de obtener tasas de acierto de hasta un 96 % en la identificación de dichas variedades de ciruelas. Esta tasa de acierto resulta notable teniendo en cuenta la dificultad que presenta esta tarea en etapas tempranas del proceso de maduración, incluso para un experto humano.

Los prometedores resultados alcanzados por el sistema desarrollado en este trabajo, hacen que nos planteemos diversas líneas de mejora para dicho sistema. Por una parte, la utilización de imágenes hiperespectrales para mejorar la precisión. En segundo lugar, la ampliación de los objetivos del sistema para incluir la identificación de otros aspectos como puede ser el nivel de maduración de las ciruelas.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el Gobierno de Extremadura y el Fondo Europeo de Desarrollo Regional (FEDER) bajo los proyectos con código IB13113 y Acción VII-14. Los autores también agradecen el acceso a los recursos de cómputo, experiencia técnica y asistencia proporcionada por el centro COMPUTEX / CeniTS de la Junta de Extremadura.

Referencias

1. Cubero, S., Aleixos, N., Moltó, E., Gómez-Sanchis, J., Blasco, J.: Advances in machine vision applications for automatic inspection and quality evaluation of fruits and vegetables. *Food and Bioprocess Technology* 4(4), 487–504 (2011)
2. Deng, L., Yu, D.: Deep learning: Methods and applications. *Foundations and Trends in Signal Processing* 7(3-4), 197–387 (2014)
3. Jiménez, A., Jain, A., Ceres, R., Pons, J.: Automatic fruit recognition: a survey and new results using range/attenuation images. *Pattern Recognition* 32(10), 1719 – 1736 (1999)
4. K., Kavukcuoglu, K., Ranzato, M., LeCun, Y.: What is the best multi-stage architecture for object recognition? In: 2009 IEEE 12th International Conference on Computer Vision. pp. 2146–2153 (2009)
5. Krizhevsky, A., Sutskever, I., Hinton, G.E.: 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)
6. LeCun, Y., Huang, F.J., Bottou, L.: Learning methods for generic object recognition with invariance to pose and lighting. In: *Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on*. vol. 2, pp. 97–104 (2004)
7. Nielsen, M.A.: *Neural Networks and Deep Learning*. Determination Press (2015)
8. Patel, H., Jain, R., Joshi, M.: Automatic segmentation and yield measurement of fruit using shape analysis. *International Journal of Computer Applications in Technology* 45(7), 19–24 (2012)
9. Pathare, P.B., Opara, U.L., Al-Said, F.A.J.: Colour measurement and analysis in fresh and processed foods: A review. *Food and Bioprocess Technology* 6(1), 36 – 60 (2013)
10. Wu, D., Sun, D.W.: Colour measurements by computer vision for food quality control: A review. *Trends in Food Science and Technology* 29(1), 5 – 20 (2013)