




UNIVERSITAT
POLITÀCNICA
DE VALÈNCIA



***Desarrollo de técnicas de visión
hiperespectral y tridimensional
para el sector agroalimentario.***



TESIS DOCTORAL PRESENTADA POR:

Eugenio Ivorra Martínez

DIRIGIDA POR

Antonio José Sánchez Salmerón

Valencia, Enero 2015

Agradecimientos

Tengo tantas personas a las que agradecer su ayuda que no sé por dónde empezar. Supongo que lo mejor es empezar por dar las gracias a mis compañeros de trabajo que han estado conmigo a lo largo de estos años con los cuales he compartido laboratorio, experiencias, problemas, partidos de frontón y grandes momentos. Algunos ya no trabajan conmigo, otros se incorporaron a mitad del camino, pero igualmente, gracias a todos.

Recuerdo como empezó mi “vida investigadora” cuando contactó conmigo el director de mis tesis el profesor Antonio José Sánchez Salmerón después de que me descartara para una beca de colaboración que había solicitado por no cumplir los requisitos. Después del primer reto que fue encontrar su despacho en la CPI, me encomendó la arriesgada tarea de abrir una nueva línea de investigación en el instituto basada en imágenes hiperespectrales. Creo que hemos trabajado y aprendido ambos mucho durante todos estos años pero, sin ninguna duda, el investigador que soy a día de hoy se lo debo a él. Además, tengo la suerte de poder afirmar que no solo me ha formado como investigador, sino que también ha contribuido a formarme como persona. Por todo ello, mi más sincero agradecimiento.

El trabajar en proyectos multidisciplinarios siempre es complicado, por eso creo que la gran labor realizada conjuntamente con Joel, Samuel y el profesor Raúl Grau Meló del Departamento de Tecnología de Alimentos se puede clasificar de éxito rotundo. Gracias, sin vuestros conocimientos y ayuda, esta tesis sería bien distinta.

Mi familia siempre ha sido mi gran apoyo, dándome cariño, comprensión y la estabilidad necesaria para recorrer este camino. De los cuales, me gustaría destacar a mis padres por su amor incondicional y a mi hermano que ha sido siempre mi ejemplo a seguir. Muchísimas gracias, sin vosotros no habría llegado nunca a este punto.

Agradecimientos

Mis amigos son mi válvula de escape en los malos momentos y mis compañeros de celebración en los buenos. Muchas gracias a todos pero mención especial a Victor con el cual hice el viaje más increíble de mi vida y a Javier que me lleva brindando su amistad desde el colegio. Gracias de nuevo y... no tengáis dudas, ¡esta tesis se celebrará como se merece!

Finalmente, pero no por ello menos importante, le dedico esta tesis a mi novia María. Gracias por estar a mi lado, por ayudarme en todo lo que has podido y disculparme los inconvenientes que ha supuesto la realización de esta tesis. Sin duda alguna, eres el mayor hallazgo de mi vida. Te quiero.

Agradecimientos

- *Un hombre es sabio mientras busque la sabiduría; si llega a creer que la ha encontrado, se convierte en idiota. Proverbio árabe.*
- *Si tu intención es describir la verdad, hazlo con sencillez y la elegancia déjasela al sastre. Albert Einstein*
- *Lo que con mucho trabajo se adquiere, más se ama. Aristóteles*

Resumen

En la industria alimentaria, como en cualquier otra industria, la mejora de sus procesos productivos es un factor clave para mantener su competitividad e incrementar sus beneficios. Para cumplir este objetivo es necesario incorporar nuevos métodos que mejoren la calidad y eficiencia de estos procesos. Además, en los alimentos actuales cada vez hay una mayor distancia entre el lugar de producción del alimento y el lugar donde se consume aumentando las posibilidades de que se contamine o exista una incertidumbre acerca de su estado. Esto exige sistemas de calidad que puedan inspeccionar el 100% de los alimentos de una forma económica y no destructiva. En esta tesis se propone utilizar para ello técnicas hiperespectrales y tridimensionales.

Se ha hecho una revisión del estado del arte de las diferentes técnicas de obtención de información tridimensional así como de sus usos en la industria alimentaria. En base a ello, se han seleccionado las técnicas basadas en luz estructurada (SL), estéreo-visión y tiempo de vuelo (TOF) como las técnicas más apropiadas. Se ha realizado una comparativa entre SL y TOF para la medida en línea de producción de 3 alimentos de origen animal y 3 de origen vegetal. De este estudio se concluye que ambas técnicas son válidas teniendo unos R^2CV medios de 0.85 el TOF y de 0.94 el SL para estimar el volumen de las muestras. Se profundizó en el estudio de SL mediante la resolución del problema de segmentación de raíces en tubérculos. Se trata de un problema difícil de resolver por técnicas clásicas de visión por computador en 2D debido a que las raíces tienen un color muy parecido a los tubérculos. Este problema se resolvió utilizando un modelo Adaboost que clasificó los puntos tridimensionales en raíces o puntos de superficie basándose en un vector de descriptores 3D. En este estudio, se llegó a alcanzar un porcentaje de acierto del 94%. Otro problema resuelto fue la determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión. Se trata de un componente de calidad complicado de estimar debido al problema de subjetividad ya que actualmente se realiza de forma manual por un panel de expertos siguiendo el descriptor de la OIV N°204. El método semi-automático desarrollado utiliza nuevos descriptores 3D y un

modelo SVM, obteniendo un R^2 en predicción de 0.8 para 100 racimos de 10 variedades diferentes.

Por otro lado, se ha desarrollado una metodología para la obtención de resultados a partir de imágenes hiperespectrales. Esta metodología se ha aplicado en 3 casos prácticos de diferentes alimentos para medir su frescura, entendiendo frescura como el grado de deterioro de los alimentos respecto a la calidad inicial de los mismos. La frescura actualmente se estima de forma analítica como una combinación de una serie de análisis físico-químicos destructivos. Mediante la captura de imágenes hiperespectrales en el rango SW-NIR se estimó la frescura de los siguientes alimentos en sus envases comerciales con distintos tipos de procesado: pechugas de pollo fileteadas, pavo cocido, jamón cocido y salmón ahumado. Se empezó con la aplicación básica de la metodología desarrollada en el pavo y el jamón cocidos donde se consiguieron unos resultados medios de validación cruzada de R^2 0.93 y de 0.9 respectivamente utilizando dos modelos PLSDA para correlar el tiempo con los espectros adquiridos. El siguiente caso práctico se realizó en pechugas de pollo, donde se amplió la metodología básica efectuando una selección de longitudes de onda mediante el algoritmo IPLSDA que redujo de 54 a 13 las variables al mismo tiempo que mejoró los resultados de los modelos PLSDA para estimar la frescura de R^2CV 0.77 a 0.85. También se estudió la influencia del film en cuanto al análisis de frescura con técnicas hiperespectrales, donde se concluyó que éste únicamente atenúa el espectro sin afectar a los resultados. En el último caso práctico se determinó si el salmón ahumado estaba caducado mediante imágenes hiperespectrales. Este caso se enfocó en la fase de segmentación espacial donde se obtuvo los espectros del tejido magro y del tejido graso por separado. Para ello se transformó la imagen hiperespectral a una imagen 2D en RGB empleando un modelo calculado del sistema hiperespectral. Una vez transformadas a imágenes 2D, se segmentó la imagen mediante un algoritmo basado en segmentación por color. Se obtuvo un resultado de $R^2CV=0.83$ con la segmentación espacial propuesta. En este estudio se demostró la necesidad de realizar una buena segmentación espacial en los casos en que las muestras no son homogéneas como es el caso de los diferentes tejidos del salmón.

Resumen

La principal aportación de la tesis es la metodología desarrollada para la combinación de técnicas 3D e hiperespectrales en el sector alimentario. La gran ventaja que se consigue con estos nuevos procedimientos es disponer de una resolución espacial elevada mediante las técnicas 3D y una muy buena resolución espectral con las técnicas hiperespectrales. En esta tesis se presentan dos de las muchas posibilidades de unir ambas técnicas. En la primera de ellas se analizó la información tridimensional del proceso de fermentación de masas de harina. Esta información tridimensional se empleó para distinguir entre harinas supuestamente iguales (según los análisis realizados en la industria) que se comportaron de forma distinta durante la fermentación. Mediante la metodología desarrollada que emplea ambas técnicas, se consiguió predecir a partir de la información hiperespectrales el comportamiento dinámico que tuvo la muestra durante la fermentación. El conocimiento de este comportamiento es de gran interés puesto que por ejemplo permite ahorrar dinero agrupando muestras con tiempos similares de fermentación o seleccionando mejor la materia prima. El segundo caso donde se investigó y desarrolló esta conjunción de técnicas se basó en aprovechar la gran resolución espacial obtenida de las técnicas 3D. Concretamente, se utilizó en la fase de segmentación espacial al procesar imágenes hiperespectrales de dorada. El objetivo de la segmentación en base a la información tridimensional fue obtener la información espectral de zonas específicas del pescado como los ojos donde se puede estimar mejor la frescura. Los resultados de R^2 CV fueron de 0.844 al correlacionar los espectros obtenidos de los ojos con el tiempo mediante un PLSDA.

El desarrollo de estas técnicas tendrá un gran impacto en la industria agroalimentaria en un futuro próximo, ya que supone una clara innovación tecnológica respecto a realizar análisis físico-químicos destructivos en un subconjunto de las muestras. Estas técnicas permiten realizar el control de calidad y de seguridad de todas las muestras de forma no destructiva mejorando por tanto la calidad, rapidez, seguridad, fiabilidad y coste de los diferentes procesos de la industria alimentaria.

Resum

En la indústria alimentària, com en qualsevol altra indústria, la millora dels seus processos productius es un factor clau per a mantindre la seua competitivitat i incrementar els seus beneficis. Per a complir este objectiu és necessari incorporar nous mètodes que milloren la qualitat i eficiència d'aquestos processos. A més, en els aliments actuals cada vegada hi ha una major distància entre el lloc de producció de l'aliment i el lloc on es consumix, augmentant les possibilitats de que es contamine o existisca una incertesa sobre el seu estat. Açò exigix sistemes de qualitat que puguen inspeccionar el 100% dels aliments d'una forma econòmica i no destructiva. En aquesta tesi es proposa utilitzar tècniques hiperespectrals i tridimensionals.

S'ha fet una revisió de l'estat de l'art de les diferents tècniques d'obtenció d'informació tridimensional, així com dels seus usos en la indústria alimentària. Basant-se en això, s'han seleccionat les tècniques basades en llum estructurada (SL), estèreo-visió i temps de vol (TOF) com les tècniques més apropiades. S'ha realitzat una comparativa entre SL i TOF per a la mesura en línia de producció de 3 aliments d'origen animal i 3 d'origen vegetal. D'aquest estudi es conclou que ambdós tècniques son vàlides tenint uns R2CV mitjans de 0.85 el TOF i de 0.94 el SL per a estimar el volum de les mostres. Es va aprofundir en l'estudi de SL mitjançant la resolució del problema de segmentació d'arrels en tubèrculs. Es tracta d'un problema difícil de resoldre per tècniques clàssiques de visió per computador en 2D degut a que les arrels tenen un color molt paregut als tubèrculs. Aquest problema es va resoldre utilitzant un model Adaboost que va classificar els punts tridimensionals en arrels o punts de superfície basant-se en un vector de descriptors 3D. En aquest estudi, s'arribà a alcançar un percentatge d'encert del 94%. Altre problema resolt va ser la determinació de la compacitat de xanglots de raïm basant-se en descriptors 3D utilitzant tècniques d'estèreo visió. Es tracta d'un component de qualitat complicat d'estimar degut al problema de subjectivitat ja que actualment es realitza de forma manual per un grup d'experts seguint el descriptor de la OIV N^o204. El mètode semi-automàtic

desenvolupat utilitza nous descriptors 3D i un model SVM, obtenint un R2 en predicció de 0.8 per a 100 xanglots de 10 varietats diferents.

Per altre costat, s'ha desenvolupat una metodologia per a l'obtenció de resultats a partir d'imatges hiperespectrals. Aquesta metodologia s'ha aplicat en 3 casos pràctics de diferents aliments per a mesurar el seu frescor, entenent frescor com el grau de deteriorament dels aliments respecte a la qualitat inicial dels mateixos. El frescor actualment s'estima de manera analítica com una combinació d'una sèrie d'anàlisi físic-químics destructius. Mitjançant la captura d'imatges hiperespectrals en el rang SW-NIR es va estimar el frescor dels següents aliments en els seus envasos comercials amb distints tipus de processat: pits de pollastre filetejats, titot cuit, pernil cuit i salmó fumat. Es va començar amb l'aplicació bàsica de la metodologia desenvolupada en el titot i el pernil cuits on es conseguiren uns resultats mitjans de validació creuada de R2 0.93 i de 0.9 respectivament utilitzant dos models PLSDA per a correlar el temps amb els espectres adquirits. El següent cas pràctic es va realitzar en pits de pollastre, on es va ampliar la metodologia bàsica efectuant una selecció de longituds d'onda mitjançant l'algoritme IPLSDA que va reduir de 54 a 13 les variables al mateix temps que va millorar els resultats dels models PLSDA per a estimar el frescor de R2CV 0.77 a 0.85. També es va estudiar l'influència del film en quant a l'anàlisi de frescor amb tècniques hiperespectrals, on es va concloure que aquest únicament atenua l'espectre sense afectar als resultats. En l'últim cas pràctic es va determinar si el salmó fumat estava caducat mitjançant imatges hiperespectrals. Aquest cas es va enfocar en la fase de segmentació espacial on es van obtenir els espectres del teixit magre i del teixit gras per separat. Per a això es va transformar l'imatge hiperespectral a una imatge 2D en RGB empleant un model calculat del sistema hiperespectral. Una vegada transformades a imatges 2D, es va segmentar l'imatge mitjançant un algoritme basat en segmentació per color. Es va obtenir un resultat de R2CV=0.83 amb la segmentació espacial proposada. En aquest estudi es va demostrar la necessitat de realitzar una bona segmentació espacial en els casos en que les mostres no són homogènies com es el cas dels diferents teixits del salmó.

La principal aportació de la tesi es la metodologia desenvolupada per a la combinació de tècniques 3D i hiperespectrals en el sector alimentari. El gran avantatge que s'aconsegueix amb aquestos nous procediments es disposar d'una resolució espacial elevada mitjançant les tècniques 3D i una molt bona resolució espectral amb les tècniques hiperespectrals. En aquesta tesi es presenten dos de les moltes possibilitats d'unir ambdós tècniques. En la primera d'elles es va analitzar la informació tridimensional del procés de fermentació de masses de farina. Aquesta informació tridimensional es va emprar per a distingir entre farines suposadament iguals (segons els anàlisi realitzats en la indústria) que es van comportar de forma distinta durant la fermentació. Mitjançant la metodologia desenvolupada que empra ambdós tècniques, es va aconseguir predir a partir de l'informació hiperespectral el comportament dinàmic que va tindre la mostra durant la fermentació. El coneixement d'aquest comportament és de gran interès ja que per exemple permet estalviar diners agrupant mostres amb temps similars de fermentació o seleccionant millor la matèria prima. El segon cas on es va investigar i desenrotllar aquesta conjunció de tècniques es va basar en aprofitar la gran resolució espacial obtinguda de les tècniques 3D. Concretament, es va utilitzar en la fase de segmentació espacial al processar imatges hiperespectrals de daurada. L'objectiu de la segmentació en base a l'informació tridimensional va ser obtindre l'informació espectral de zones específiques del peix com els ulls on es pot estimar millor el frescor. Els resultats de R^2 CV van ser de 0.844 al correlacionar els espectres obtinguts dels ulls amb el temps mitjançant un PLSDA.

El desenvolupament d'aquestes tècniques tindrà un gran impacte en la indústria agroalimentària en un futur pròxim, ja que suposa una clara innovació tecnològica respecte a realitzar anàlisis físic-químics destructius en un subconjunt de les mostres. Aquestes tècniques permeten realitzar el control de qualitat i de seguretat de totes les mostres de forma no destructiva millorant per tant la qualitat, rapidesa, seguretat, fiabilitat i cost dels diferents processos de la indústria alimentària.

Abstract

Enhancements of the productive processes in the food industry, as any other industry, are a key factor to keep the competitiveness and increase profits. In order to achieve this objective it is needed to use new methods that improve the quality and efficiency of these processes. Moreover, nowadays there is a farther distance between the place of production of the current foods and the place where they are eaten. This requires quality systems that can inspect the 100% of the food samples in a cheap and non-destructive way. Hyperspectral and 3D techniques are proposed in this thesis as a solution.

A review of the current state of art has been done for the different techniques to obtain three dimensions' information as well as their uses in the food industry. Structured light (SL), stereo vision and time of flight (TOF) have been chosen as the best suitable. A comparison between SL and TOF for the in-line measurement of three animal foods and three vegetable foods has been done. The conclusion of this study is that both techniques are suitable to use having a mean R^2CV of 0.85 for TOF and 0.95 for SL for the volume estimation of the samples. SL techniques have been studied deeper solving the segmentation problem of detecting roots on potatoes. This is a difficult problem to solve using classic computer vision techniques due to the similar colors between the roots and the potatoes. This problem was solved doing an Adaboost model that classifies the 3D points of the cloud into roots or surface points using a 3D features vector for each point. The results achieved values of 94% in accuracy. Another problem solved was the assessment of grape cluster yield components based on 3D descriptors using stereo vision. Compactness is especially difficult to assess due its subjectivity. Currently, this quality component is evaluated by a group of experts following the method described in OIV volume 204. A semi-automatic method was developed to solve this problem using new 3D descriptors and a SVM model. A prediction value of $R^2=0.8$ was achieved for hundred bunches of ten different varieties.

Abstract

With regard of hyperspectral techniques, a new methodology has been developed in order to get results from hyperspectral images. This methodology has been applied for solving three different problems. These problems were freshness assessment of different foods, understanding freshness as the level of degradation of the aliments since its initial quality. Currently, freshness assessment is done by a combination of destructive physic-chemical analyses. Freshness evaluation was performed using hyperspectral images in the range of SW-NIR to the following food: sliced chicken breast, cooked ham, cooked turkey and smoked salmon. The starting point was the basic use of the developed methodology to cooked ham and cooked turkey where a cross-validation results of R^2 0.93 and 0.9 respectively were achieved. Time and spectra acquired were correlated using two PLS-DA models. The following practical case was conducted in chicken breasts freshness estimation, where the basic methodology was extended making a selection of the most important wavelengths using the algorithm IPLSDA. They were reduced from 54 to 13 variables which made an improvement in the cross validation results from 0.77 to 0.85. It was also studied the possible influence of the film in the freshness estimation using hyperspectral analyses. It was found that the film only attenuates the intensity signal of the spectrum but it does not affect in the results. In the last case, it was determined when the smoked salmon was expired by hyperspectral imaging. This case was focused on the spatial segmentation phase where the spectra of lean tissue and fat tissue were obtained separately. This hyperspectral image is transformed into a 2D image in RGB using a calculated model of the hyperspectral system. Once transformed to 2D images, image segmentation was performed using a color based segmentation algorithm. A result of $R^2_{CV} = 0.83$ was obtained with the proposed spatial segmentation. In this study, the requirement of a good spatial segmentation in the cases where samples are not homogeneous (like the salmon) was proven.

The main contribution of this thesis is the methodology developed for combining 3D and hyperspectral techniques for the food industry. The most important advantages using this new procedure are that the 3D techniques provide a high spatial resolution while the hyperspectral techniques offer a very good spectral resolution. In this work it is explained two of the many possibilities of using the developed methodology developed. In the first one, the fermentation

Abstract

process of flour mass was analyzed using 3D techniques. This 3D information was used to discriminate between supposedly equal flour (equals for the analysis performed in the industry) that behaved differently during fermentation. It was possible to predict this behavior from the hyperspectral information applying the methodology developed. The knowledge of this behavior is of great interest because it can be used to save money by grouping samples with similar fermentation times or selecting the best raw materials. The second case where the combination of techniques was researched and tested was based on taking advantage of the high spatial resolution obtained from the 3D techniques. Specifically, it was used in the segmentation stage when hyperspectral images of gilt-head were processed. The goal of segmentation based on the three-dimensional information was to obtain spectral information just from the fish eyes. Spectral information acquired from this area improved the estimation of freshness. It was obtained a cross-validation result of 0.844, correlating only the eyes spectra with time using a PLSDA model.

The development of these techniques may have a major impact on the food industry in the near future, as it represents a clear technological innovation in comparison with conducting destructive physical and chemical analyses on a subset of samples. These techniques allow the quality control and security of all the samples in a non-destructive way, thereby improving the quality, speed, safety, reliability and cost of numerous processes in the food industry.

Índice

Agradecimientos	i
Resumen	iv
Resum	vii
Abstract.....	x
Índice.....	xiii
Capítulo 1: Introducción, justificación, objetivos y organización de la tesis	1
1.1.- Introducción.....	1
1.2.- Justificación.....	3
1.3- Objetivos.....	5
1.4- Organización de la tesis	6
Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperspectrales en la industria alimentaria.....	8
1.1.- Estado del arte de sensores tridimensionales (3D).....	8
1.1.1.- Técnicas de obtención de información tridimensional	8
1.1.1.1.- Técnicas basadas en luz estructurada	9
1.1.1.2.- Técnicas basadas en tiempo de vuelo	11
1.1.1.3.- Técnicas basadas en interferometría	13
1.1.1.4.- Técnicas basadas en rayo x.....	14
1.1.1.5.- Técnicas basadas en campos magnéticos	14
1.1.1.6.- Técnicas basadas en estéreo visión.....	15
1.1.1.7.- Técnicas basadas en cámaras en movimiento	17
1.1.1.8.- Técnicas basadas en acomodación de enfoque	17

Índice

1.1.1.9.- Técnicas basadas en conocimiento de la escena	18
1.1.1.10.- Técnicas basadas en estéreo fotométrico	18
1.1.1.11.- Técnicas basadas en el análisis de textura	19
1.1.2.- Revisión del estado del arte de las técnicas 3D en la industria alimentaria	19
1.2.- Técnicas hiperespectrales de visión por computador	23
1.2.1.- Fundamentos de la técnica hiperespectral	23
1.2.1.1.- Radiación electromagnética	23
1.2.1.2.- Radiación NIR.....	25
1.2.1.3.- Origen	27
1.2.2.- Contexto actual.....	27
1.2.3.- Diferencias entre espectroscopia, análisis de imagen en visible e hiperespectral	29
1.2.4.- Ventajas y desventajas de las técnicas hiperespectrales	31
Capítulo 3: Aportaciones de las técnicas 3D.....	33
1.- Introducción.....	33
2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal.....	33
2.1.- Descripción del estudio	33
2.2.- Sistema tridimensional por tiempo de vuelo (TOF)	34
2.3.- Sistema tridimensional por luz estructurada (SL).....	36
2.4.- Resultados.....	40
2.5.- Conclusiones.....	45
2.6.- Aportaciones del estudio.....	46
3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada.....	46

Índice

3.1.- Descripción del estudio	46
3.2.- Sistema tridimensional por luz estructurada	47
3.3.- Procesamiento de la información tridimensional	48
3.4.- Resultados.....	53
3.5.- Conclusiones.....	56
3.6.- Aportaciones del estudio.....	57
4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión.....	58
4.1.- Descripción del estudio	58
4.2.- Sistema tridimensional por visión estéreo	59
4.3.- Reconstrucción 3D de los racimos de uva usando visión estereoscópica.....	60
4.3.1.- Aproximación automática	62
4.3.2.- Refinamiento manual	64
4.4.- Descriptores 3D y modelos.....	66
4.5.- Resultados.....	71
4.5.1.- Resultados de los componentes de calidad del racimo	73
4.5.2.- Resultados de otros componentes de productividad del racimo	77
4.6.- Conclusiones.....	78
4.7.- Aportaciones del estudio.....	79
Capítulo 4: Aportaciones técnicas hiperespectrales.....	80
1.- Introducción.....	80
1.1.- Definición de frescura.....	80
1.2.- Degradación de alimentos.....	81
2.- Análisis de frescura de productos alimentarios	83

Índice

2.1.- Configuración y calibrado del equipo	84
2.2.- Segmentación espacial	88
2.3.- Preprocesado	89
2. 4.- Análisis estadístico multivariante	90
2. 5.- Selección de longitudes de onda	90
2. 6.- Validación de resultados.....	91
3.- Caso práctico: evaluación de tres sistemas de iluminación	92
4.- Caso práctico: estudio de frescura en jamón de pavo y jamón cocido.....	95
4.1.- Descripción del estudio	95
4.2.- Análisis destructivos	95
4.3.- Equipo hiperespectral utilizado y condiciones de adquisición.....	96
4.4.- Análisis estadístico realizado	98
4.5.- Resultados imágenes hiperespectrales	98
4.6.- Conclusiones	102
4.7.- Aportaciones del estudio.....	103
5.- Caso práctico: estudio de frescura en pechuga de pollo.....	104
5.1.- Descripción del estudio	104
5.2.- Análisis destructivos	104
5.3.- Equipo hiperespectral utilizado y condiciones de adquisición.....	105
5.4. – Modelos estadísticos empleados.....	106
5.5.- Resultados de las imágenes hiperespectrales	106
5.6.- Correlación entre los análisis destructivos y los no destructivos.....	111
5.7.- Conclusiones.....	111
5.8.- Aportaciones del estudio.....	112

Índice


6.- Caso práctico: detección de caducidad en salmón ahumado	113
6.1.- Descripción del estudio	113
6.2.- Análisis destructivo	114
6.3.- Equipo hiperespectral utilizado y condiciones de adquisición.....	115
6.4.- Segmentación espacial	116
6.4.1.- Modelo de color.....	116
6.4.2.- Segmentación basada en RGB	118
6.5.- Resultados imagen hiperespectral	119
6.6.- Conclusiones	124
6.7.- Aportaciones del estudio	125
Capítulo 5: Aportaciones de la combinación de técnicas 3D e hiperespectrales.....	126
1.- Introducción.....	126
2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales	127
2.1.-Descripción del estudio	127
2.2.- Preparación de la masa y del proceso de fermentación	128
2.3.- Análisis reológicos.....	129
2.4.- Sistema de adquisición hiperespectral.....	129
2.5.- Sistema de adquisición tridimensional.....	131
2.6.- Resultados.....	133
2.6.1.- Resultados del sistema tridimensional.....	133
2.6.2.- Resultados imagen hiperespectral	135
2.7.- Conclusiones	139

Índice

2.8.- Aportaciones del estudio	140
3.- Caso práctico: estudio de frescura en sparus aurata usando técnicas hiperespectrales y segmentación 3D	141
3.1.-Descripción del estudio	141
3.2.- Análisis destructivos	141
3.3.- Equipo utilizado	141
3.3.1.- Sistema de adquisición hiperespectral	142
3.3.2.- Sistema de adquisición tridimensional.....	143
3.4.- Segmentación espacial mediante 3D	144
3.5.- Resultados imagen hiperespectral	146
3.6.- Conclusiones.....	148
3.7.- Aportaciones del estudio.....	149
Capítulo 6: Conclusiones y trabajos futuros	150
1.- Conclusiones	150
2.- Trabajos futuros.....	153
3.- Publicaciones	154
Apéndice A: Modelos estadísticos para el análisis de imagen multivariante.....	158
1.- PCA.....	158
1.1.-Fundamento	158
1.2.-Matemáticas del PCA.....	159
1.2.1.- Método basado en correlaciones	160
1.2.2.- Método basado en las covarianzas	161
1.1.3. Limitaciones	162
1.1.4.- Parámetros estadísticos	162

Índice

2.- PLS.....	164
2.1. - NIPALS.....	164
2.2.- SIMPLS	166
3.- Métodos de clasificación	167
3.1.- K-means	169
3.2.- SIMCA.....	171
3.3.- PLSDA	172
3.4.- Adaboost.....	172
3.4.1- Algoritmo Minimalist Real Adaboost (Barnes et al., 2010b).....	174
3.5. SVM	175
3.5.1 ϵ -SVR	176
4.- Selección de variables.....	177
4.1. Algoritmos genéticos	178
4.2. Intervalos de PLS.....	180
Bibliografía	181



Capítulo 1: Introducción, justificación, objetivos y organización de la tesis

1.1.- Introducción

Uno de los principales objetivos de las empresas en el sector industrial es mejorar la eficiencia de sus procesos y garantizar unos estándares de calidad en sus productos para seguir siendo competitivas. Para conseguir esta mejora en sus procesos es necesario disponer información precisa de sus materias primas, de la transformación y del producto final resultante. Esta información se puede obtener de muchos tipos de análisis y métodos pero uno de los más extendidos por sus muchas ventajas es la visión por computador.

La visión por computador tradicional es una disciplina que data de 1960 y que ha tenido un gran desarrollo tanto en teoría como en aplicaciones. Actualmente, se aplica de forma exitosa en numerosos campos como por ejemplo en la medicina, la industria del automóvil, en tareas de vigilancia o la industria alimentaria.

La visión por computador se basa en el principio de que cualquier tarea realizada por la supervisión de ojos humanos puede ser reemplazada o incluso mejorada por un equipo de visión artificial. Es por ello que normalmente las cámaras son sensibles a los colores primarios (rojo, verde y azul) imitando a los ojos humanos.

Entre las numerosas ventajas de la visión por computador, destacan las siguientes: es rápida, económica, fiable y adaptable a casi cualquier escenario. Su velocidad y precisión han ido mejorando con el transcurso de los años siendo capaces de satisfacer el constante

incremento en la producción de alimentos y en la calidad exigida en ellos ayudando a desarrollar procesos totalmente automáticos.

En la industria alimentaria, la visión por computador tradicional se emplea principalmente para clasificar productos por variedades o calidades (Brosnan & Sun, 2002) o para medir atributos externos de calidad (B. Zhang et al., 2014). Con la evolución de la tecnología, se han desarrollado nuevas técnicas de visión por computador como por ejemplo los sensores 3D y los sensores hiperspectrales. Estas nuevas tecnologías permiten estimar características internas de productos agroalimentarios que requieren de análisis físico-químicos destructivos o medir características externas como la morfología y el volumen de forma cuantificable y muy precisa.

Una de las áreas priorizadas dentro del programa “Horizon 2020” de la Unión Europea es el topic conocido como “Sustainable Food Security” (SFS-13-2015), donde se engloban aquellos proyectos cuyo objetivo es el desarrollo de nuevos métodos o tecnologías que faciliten el control de los productos y procesos de producción de la industria agroalimentaria. El hecho de que esta área sea una de las principales prioridades dentro del panorama científico europeo refleja el interés que despierta para la industria alimentaria la posibilidad de disponer de métodos analíticos rápidos y económicos. La disponibilidad de dichos métodos permitiría no solo el adecuado control de la producción a nivel industrial, sino también el control de la calidad del producto elaborado durante el periodo completo de comercialización.

Siguiendo las pautas marcadas por la Unión Europea, en esta tesis se va a desarrollar una serie de metodologías basadas en técnicas hiperspectrales (SW-NIR) y tridimensionales enfocadas a la caracterización de los alimentos y, por tanto, a garantizar la seguridad en su consumo. Concretamente, tal como se ve en la figura 1-1 se van a desarrollar procedimientos para las dos técnicas anteriores y una nueva metodología para su uso conjunto.

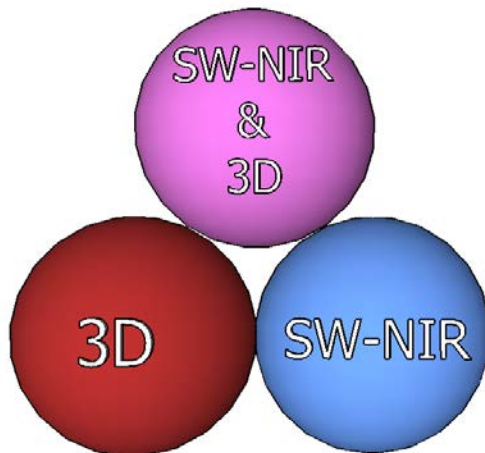


Figura 1-1 Esquema de las técnicas de las cuales se han desarrollado metodologías en esta tesis.

1.2.- Justificación

En este proyecto de Tesis se pretende obtener nuevos conocimientos para el desarrollo de técnicas no destructivas de control de calidad utilizando imágenes hiperespectrales y tridimensionales. Como caso práctico se va a trabajar con imágenes hiperespectrales en el rango del NIR para el análisis de cualidades de productos alimenticios. Debido a la gran cantidad de información contenida en una imagen hiperespectral es necesario el desarrollo de técnicas de compresión de datos y procesado de imágenes capaces de extraer y obtener las características relevantes. Para ello se han empleado métodos de proyección sobre estructuras latentes mediante el análisis de imagen. Existen muchos tipos de técnicas para sacar información tridimensional pero esta tesis se centrará en luz estructurada, visión estereoscópica y por tiempo de vuelo. La utilización de técnicas tridimensionales en el sector alimenticio presenta un gran interés debido a la gran cantidad de información que proporcionan acerca de la geometría, morfología y localización de los productos. Tanto los sensores hiperespectrales como tridimensionales han ido evolucionando y mejorando con los años ofreciendo actualmente un buen funcionamiento a menores precios. Esta mejora

tecnológica da como consecuencia un mayor interés en su utilización en las industrias y por tanto, en el desarrollo de metodologías eficientes para su uso.

La principal aportación de esta tesis es la novedosa metodología desarrollada que utiliza técnicas hiperespectrales y tridimensionales en el sector alimentario. La gran cantidad de información que aportan ambas técnicas exige una metodología basada en la reducción y extracción de la información relevante para cada aplicación. Esta metodología se ha desarrollado apoyándose en el conocimiento adquirido de cada una de estas técnicas por separado. Empleando los procedimientos desarrollados para la combinación de estas técnicas se obtiene una gran resolución espacial (con las técnicas 3D) y una gran resolución espectral (con las técnicas hiperespectrales) que permite resolver problemas no resueltos hasta ahora, o mejorar las soluciones actuales.

El avance científico conseguido en esta tesis tendrá un gran impacto en la industria agroalimentaria en un futuro próximo, ya que supone una clara innovación tecnológica respecto a realizar análisis físico-químicos destructivos en un subconjunto de las muestras. La utilización de las metodologías desarrolladas permitirá realizar el control de calidad y de seguridad de todas las muestras de forma no destructiva. Además, estas metodologías se han probado sobre alimentos en diferentes estados de procesados desde materias primas como la harina hasta productos procesados y envasados comercialmente como el salmón ahumado. Por ejemplo estas técnicas se podrían adaptar y utilizar en línea en la industria alimentaria inspeccionando el 100% de los productos y obteniendo información acerca de las mismas revisando por tanto el procesado realizado o como paso previo al mismo para optimizar los parámetros del proceso. Cabe recalcar que las metodologías desarrolladas se han evaluado sobre equipos de bajo coste con lo cual su utilización en la industria se amortizaría en poco tiempo. En base a ello se puede concluir que los nuevos procedimientos desarrollados mejorarían la calidad, rapidez, seguridad, fiabilidad y coste de los diferentes productos y procesos de la industria alimentaria.

1.3- *Objetivos*

En la realización de esta tesis se estableció como objetivo general el desarrollo de técnicas no destructivas de control de calidad de productos agroalimentarios basadas en imágenes hiperespectrales y tridimensionales con sistemas de bajo coste. Para ello, se proponen los siguientes objetivos específicos:

- Realizar una revisión constante del estado del arte de técnicas de control de calidad de productos agroalimentarios basados en visión por computador prestando especial atención a los basados en sensores hiperespectrales y tridimensionales.
- Seleccionar las tecnologías óptimas de visión 3D para diferentes procesos y productos alimentarios.
- Desarrollar y analizar metodologías para las tecnologías 3D seleccionadas para la caracterización de productos y el control de procesos en productos agroalimentarios.
- Formular nuevos descriptores para analizar y extraer información tridimensional útil de nubes de puntos con diferentes resoluciones.
- Desarrollar y valorar procedimientos para el control de calidad en diferentes productos agroalimentarios a partir de imágenes hiperespectrales en el rango del espectro visible hasta el infrarrojo cercano (SW-NIR).
- Determinar si es posible obtener conjuntos reducidos de longitudes de onda para determinar algunas propiedades/calidad en diferentes materias primas o alimentos.
- Desarrollar y evaluar procedimientos para la utilización simultánea de técnicas tridimensionales y de espectroscopia para una mejor caracterización de los alimentos o de los procesados de los mismos.

1.4- Organización de la tesis

La tesis se organiza en 6 capítulos de la siguiente forma:

Capítulo 2

Se hace una revisión del estado del arte actual en la temática de la visión por computador aplicada al sector alimenticio. Este capítulo se subdivide en dos apartados: técnicas tridimensionales y técnicas hiperspectrales. En cada uno de los apartados, además de la revisión del estado del arte, se definen cada una de las técnicas así como las más adecuadas para su uso en la industria alimentaria.

Capítulo 3

Se presentan las aportaciones de la tesis en el estudio de diferentes productos alimentarios usando diferentes técnicas tridimensionales: luz estructurada (SL), estereoscópica y por tiempo de vuelo (TOF). Este capítulo se subdivide en una comparativa entre TOF y SL, un caso de estudio basado en SL aplicado a tubérculos donde se profundiza en la segmentación y utilización de características 3D más relevantes y un caso de estudio utilizando visión estereoscópica para la caracterización semi-automática de los principales componentes de productividad en racimos de uvas.

Capítulo 4


Se establecen las aportaciones de la tesis en el estudio de diferentes productos alimentarios usando técnicas hiperspectrales. Este capítulo se subdivide en dos apartados: la explicación de la técnica hiperspectral y su metodología para la medida de frescura en alimentos y otro apartado donde se detallan los casos de estudio realizados siguiendo la metodología desarrollada en la que se explica desde el caso más básico a los más completos.

Capítulo 5

Se explica la metodología desarrollada para la utilización simultánea de técnicas hiperespectrales junto a tridimensionales así como los beneficios obtenidos de ella. Esto se aborda desde dos aproximaciones diferentes. En la primera se describe un caso de estudio en la que la información tridimensional se utiliza para caracterizar el proceso y la técnica hiperespectral para predecir su comportamiento. Este primer caso de estudio se realiza en harinas de trigo con diferentes procesos de fermentación. La segunda aproximación consiste en aprovechar la gran resolución espacial obtenida de las técnicas 3D para segmentar muestras de pescado y obtener solo la información espectral de los ojos en los cuales se puede medir mejor la frescura.

Capítulo 6

Se discuten las conclusiones extraídas del presente proyecto de tesis además del trabajo futuro que se deriva del mismo. Además se enumeran las publicaciones en revistas internacionales revisadas por expertos en la temática que sustentan la investigación realizada en esta tesis.



Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperspectrales en la industria alimentaria

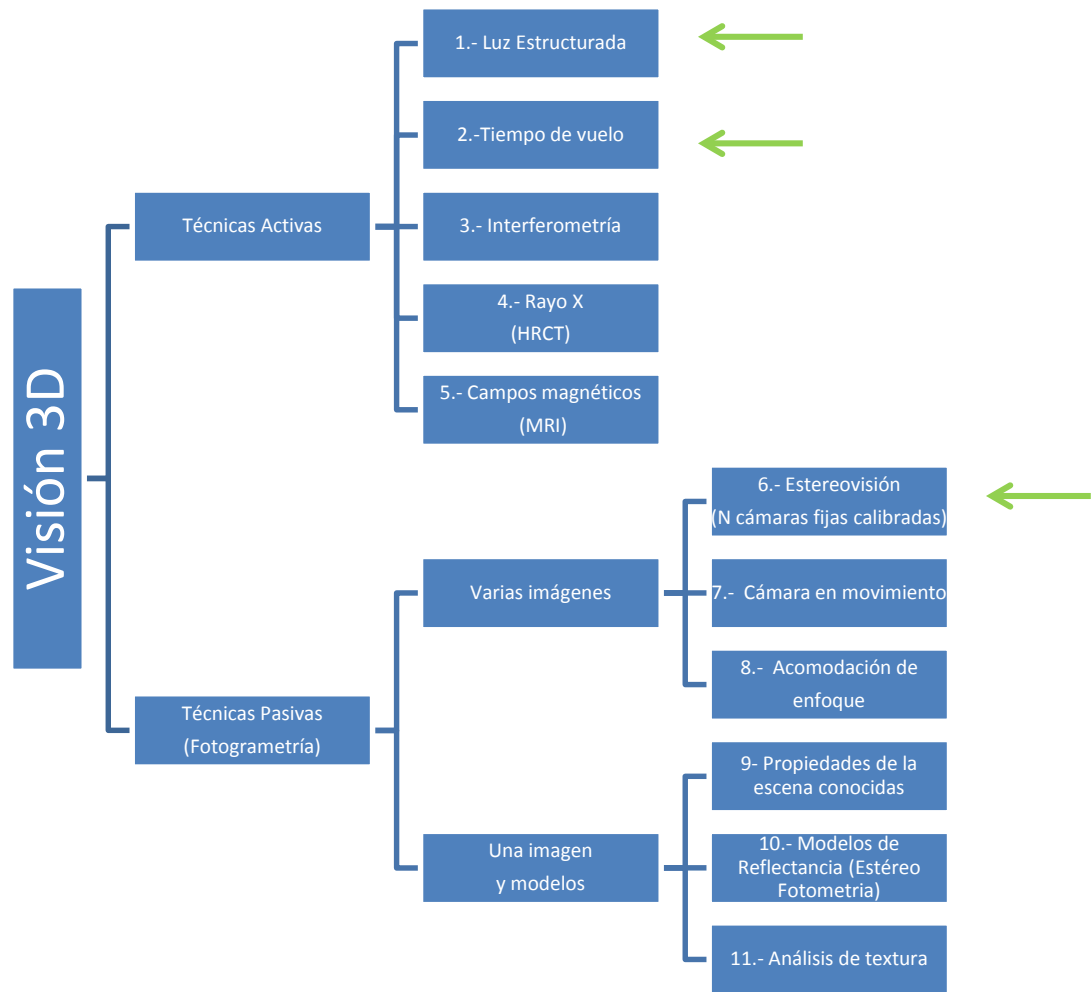
1.1.- Estado del arte de sensores tridimensionales (3D)

1.1.1.- Técnicas de obtención de información tridimensional

Existen muchas clasificaciones de las diferentes técnicas que actualmente se usan para obtener información tridimensional atendiendo por ejemplo al tipo de información que se obtiene (si directamente se obtiene la distancia hasta los objetos o solo se obtienen los vectores normales de la superficie del mismo), de la forma en que se extrae la información (por triangularización conociendo la física de las señales, midiendo el tiempo de retorno de las señales o simplemente usando una cámara de visión monocular e información de la escena) o dependiendo de si la información 3D se obtiene directamente del sensor (directa) o se infiere a partir de imágenes 2D y el conocimiento a priori de la escena y de las muestras (indirecta). En esta tesis se ha decidido agruparlas dependiendo de la interacción que tiene el sensor 3D con la muestra siendo activa si necesita emitir señales y pasiva si solo adquiere información y las pasivas a su vez dependiendo de si necesitan una o más imágenes.

Las principales técnicas 3D están clasificadas atendiendo a los anteriores criterios en el esquema 2-1.

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria



Esquema 2-1: Clasificación de las diferentes técnicas 3D. Las flechas verdes indican las técnicas empleadas en esta tesis.

1.1.1.1.- Técnicas basadas en luz estructurada

Los sensores basados en luz estructurada constan fundamentalmente de tres elementos: un patrón de luz, un sistema de detección o cámara CCD y un sistema de procesado de datos. La fuente de luz es la encargada de emitir un patrón de luz sobre el objeto a medir que provocará una deformación en el patrón que será medido por una cámara CCD. La información 3D se obtiene de la deformación de este patrón basándose en trigonometría (Peiravi & Taabbodi, 2010). Existen muchos tipos de patrones desde el más sencillo que es un punto láser a otros

1.1.- Estado del arte de sensores tridimensionales (3D)

más complejos como emitir múltiples patrones simultáneos de franjas de frecuencias sinodales (S. Zhang, 2010). En la fig. 2-1 se muestra un ejemplo de un patrón basado en la proyección de una línea láser. La posición 3D en este caso se puede obtener conociendo la distancia entre el láser y la cámara (llamado línea base) y el ángulo entre dicha línea y el rayo del láser. Las coordenadas 3D (x,y,z) de un punto del objeto sobre el que proyecta el láser se pueden calcular conociendo el píxel (x',y') sobre el que proyecta usando la siguiente ecuación 2.1:

$$\begin{bmatrix} x \\ y \\ z \end{bmatrix} = \frac{1}{f \cot \alpha - x'} * \begin{bmatrix} bx' \\ by' \\ bf \end{bmatrix} \quad (2.1)$$

Donde f es la distancia focal, b es la línea base y α es el ángulo entre el plano del rayo láser y el eje x .

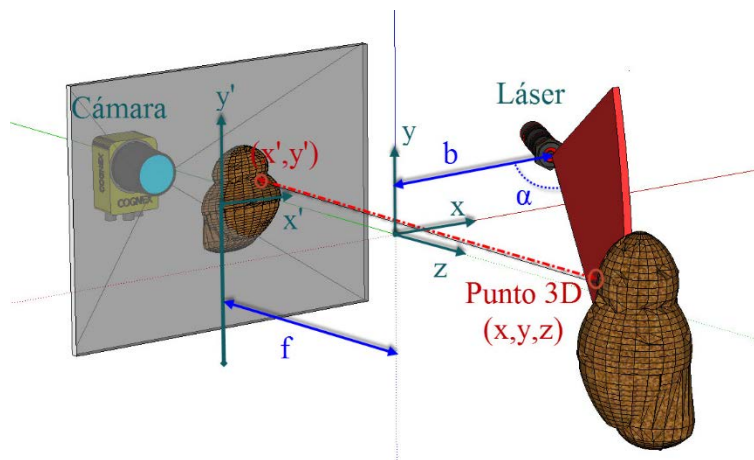


Figura 2-1: Esquema de un sistema de captura 3D basado en luz estructurada

Las principales ventajas de este método son que resultan muy precisos, robustos a las condiciones de iluminación ambientales, no requieren textura en la superficie, son rápidos en el cálculo y se pueden desarrollar sistemas de bajo coste. Por el contrario, son poco flexibles, teniendo que ajustarse para trabajar en un rango y precisión determinados, tienen problemas de oclusión dependiendo de la configuración del sistema, pueden requerir un movimiento

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

mecánico para escanear todo el objeto y, en determinados objetos de colores parecidos al color del patrón de luz emitido, puede ser muy difícil la tarea de detectar el patrón. Están especialmente indicados para tareas específicas en entornos controlados lo que ha hecho que se apliquen en la industria.

1.1.1.2.- Técnicas basadas en tiempo de vuelo

Este tipo de técnicas consisten en calcular el tiempo que tarda una onda electromagnética en reflejarse en un objeto y volver a un receptor atravesando un medio conocido. Conociendo la velocidad de la onda en dicho medio, se puede calcular la distancia en función del tiempo. Estos sensores están compuestos por un emisor que emite un tipo de onda y un receptor que captura la cantidad de onda que vuelve y el tiempo que ha tardado. Existen principalmente 3 tipos de sensores:

- Basados en emisores de luz que emiten con frecuencias determinadas: Consisten en emitir ondas electromagnéticas a ciertas longitudes de onda de forma que la distancia se calcula midiendo el desfase de dichas ondas respecto a las emitidas. Suelen emitir en el rango del infrarrojo para que les afecte poco la iluminación del entorno (figura 2-2a).
- Basados en obturadores automáticos: Se trata de sensores que emiten ondas a una cierta frecuencia y que disponen de obturadores que se cierran a la misma frecuencia. La distancia en este caso se calcula con la cantidad de luz que se bloquea con el obturador, con la que se recibe en el sensor y conociendo el rango de alcance (figura 2-2b).

1.1.- Estado del arte de sensores tridimensionales (3D)

- Basados en pulsos directos: Consisten en emitir pulsos y medir la cantidad y tiempo que tardan en volver al sensor. Los más utilizados son láseres o ultrasonidos para emitir los pulsos (figura 2-2c).




Figura 2-2: Cámaras TOF. a) CamCube, PDM systems b) Zcam, 3DVSystems c) Lidar Láser, SICK

Existen muchas formas de medir el tiempo que tardan las ondas en volver al sensor, pero generalmente se basan en el cálculo de la demodulación de fase utilizando por ejemplo la técnica de los “cuatro cubos”. Esta técnica se basa en que cada pixel del sensor mide la cantidad de luz reflejada por la escena cuatro veces a intervalos regulares de tiempo (m_0 , m_1 , m_2 y m_3) de forma que el cálculo de fase se realiza mediante la ecuación 2.2.

$$\varphi = \arctan\left(\frac{m_3 - m_1}{m_0 - m_2}\right) \quad (2.2)$$

La intensidad se calcula con la ecuación 2.3 mientras que la amplitud de la onda con la 2.4. La amplitud es un indicador de la calidad de la medida.

$$B = \frac{m_0 + m_1 + m_2 + m_3}{4} \quad (2.3)$$

$$A = \frac{\sqrt{[m_3 - m_1]^2 + [m_0 - m_2]^2}}{2} \quad (2.4)$$

El rango del sensor se calcula utilizando la frecuencia de modulación del emisor de luz f_m y la constante de la velocidad de la luz en el vacío c en la siguiente ecuación:

$$L = \frac{c}{2f_m} \quad (2.5)$$

Y por último se puede obtener fácilmente la distancia al objeto como:

$$D = L * \frac{\varphi}{2\pi} \quad (2.6)$$

Las principales ventajas de estos métodos son que tienen un tiempo de adquisición de imágenes muy rápido, que obtienen directamente la información 3D sin casi procesado de la información y que no dependen de la textura de los objetos. Sin embargo, son sistemas con una resolución muy baja (por ejemplo, 64×64 CanestaVision, 176×144 de la Swissranger SR3000 o de 204×204 de la cámara PMD CamCube), tienen dificultades para escanear objetos con un fuerte coeficiente especular si el ángulo de la luz no es exactamente perpendicular y en la actualidad son sistemas de un coste elevado (Foix, Alenya, & Torras, 2011).

1.1.1.3.- Técnicas basadas en interferometría

Los sensores interferómetros funcionan emitiendo señales electromagnéticas de una o más longitudes de onda sobre una superficie y lo comparan con un patrón de referencia extrayendo la información 3D de las diferencias respecto a éste. Normalmente utilizan más de un tipo de longitud de onda y usan una combinación de todas ellas para obtener mejor resolución. El principal uso es medir las variaciones en superficies para un control preciso de calidad de superficies o para obtener imágenes con mucha resolución en astronomía. Los mayores inconvenientes que tiene es que solo sirven para medir superficies prácticamente planas, que

1.1.- Estado del arte de sensores tridimensionales (3D)

son caros y que no se suelen utilizar en el rango del espectro visible debido a la mayor complejidad mecánica que implica trabajar con longitudes de onda cortas.

1.1.1.4.- Técnicas basadas en rayo x

Se trata de técnicas usadas principalmente en medicina pero que pueden ser adaptadas para su uso en la industria. Consisten en la emisión de un tipo de radiación (generalmente rayos X) sobre los objetos de forma que se obtiene información 3D de una sección del objeto en función de la absorción de radiación del material del objeto. Si se desplaza el objeto, éste se puede reconstruir entero juntando los diferentes planos.

Las principales ventajas de estos métodos son que permiten obtener información tridimensional tanto interna como externa de los objetos y con una gran precisión. Sin embargo, las principales limitaciones son que resultan muy caros, no pueden escanear objetos grandes y que la radiación puede suponer un riesgo para los seres humanos e implica fuertes medidas de protección y seguridad.

1.1.1.5.- Técnicas basadas en campos magnéticos

Al igual que las técnicas basadas en radiación, los sensores que utilizan campos magnéticos se han desarrollado para ser usados principalmente en medicina pero también pueden ser adaptados para su uso en la industria. La más empleada es la imagen por resonancia magnética nuclear que se basa en el estudio de la perturbación de los núcleos atómicos de los objetos a escanear. Estos objetos primero son alineados con un campo magnético constante que posteriormente es perturbado con el uso de un campo magnético alterno, de orientación ortogonal. La resultante de esta perturbación es la que aporta información 3D de un plano del objeto.

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

Las principales ventajas de estas técnicas son que permiten conocer información tridimensional de la estructura interna de los objetos y que son técnicas muy precisas. Sin embargo, las principales limitaciones son que resultan muy caros, son lentos en adquisición de imágenes y que debido a los fuertes campos magnéticos que se producen no puede haber objetos metálicos en los alrededores del sensor.

1.1.1.6.- Técnicas basadas en estéreo visión

Este tipo de técnicas consisten en capturar imágenes de una escena desde dos o más puntos de vista diferentes. Los sensores pueden consistir o bien de varias cámaras sincronizadas desplazadas entre sí o bien de una sola cámara que captura la escena desde diferentes posiciones. En la figura 2-3 hay 3 ejemplos de sensores comerciales basados en esta tecnología. Una vez capturadas las imágenes, se trata de encontrar los pares de características que se corresponden de una imagen respecto a la otra, este paso se conoce con el nombre de problema de correspondencia. Para encontrar estas características es necesario medir cuanto se parecen entre ellos mediante una función de coste. Las funciones de coste más populares son la diferencia de intensidades absolutas, la raíz cuadrada de la diferencia de intensidades y la correlación cruzada normalizada (Lazaros, Sirakoulis, & Gasteratos, 2008). Para más detalles acerca de las funciones de coste y una comparativa entre ellas consultar (Hirschmuller & Scharstein, 2007). Una vez encontrados los pares de características, se calcula su diferencia de coordenadas también llamada disparidad siendo la distancia 3D de estos puntos inversamente proporcional a la disparidad. Un esquema básico del procedimiento que se sigue para el cálculo del 3D es el siguiente:

1. Captura de la escena desde diferentes puntos de vista. Se deben conocer las localizaciones de estos puntos de vista o en caso contrario se tienen que calcular en función de las imágenes.

1.1.- Estado del arte de sensores tridimensionales (3D)

2. Corrección de la imagen para eliminar posibles distorsiones debido a la lente (de barril, de cojín o de mostacho). Con esto se consigue que las imágenes sean resultado de proyecciones puras.
3. Rectificación de las imágenes que aunque no es imprescindible se suele realizar. Por ejemplo, en el caso de una configuración horizontal de cámaras en paralelo esto haría que una característica en una imagen se pueda encontrar en la misma fila en la otra imagen.
4. Se resuelve el problema de correspondencia.
5. Una vez se tienen los pares de características se calcula el mapa de disparidad como la diferencia entre sus coordenadas.
6. Conociendo los parámetros intrínsecos y extrínsecos de las cámaras se puede extraer la información 3D utilizando el mapa de disparidad.

Las principales ventajas de utilizar técnicas de estereovisión es que no necesitan iluminación específica, son totalmente pasivos al no emitir ningún tipo de señal, son baratos puesto que solo necesitan cámaras y pueden tener unas resoluciones y velocidades altas dependiendo de las cámaras. El mayor problema que tienen es resolver el conocido problema de correspondencias que en el caso de objetos con poca textura resulta muy complicado. Existen métodos que combinan estéreo con luz estructurada para resolver este problema pero esto implica perder parte de las ventajas de un sistema estéreo puro (Jang, Je, Seo, & Lee, 2013).




Figura 2-3: Cámaras de estéreo visión. a) Bumblebee 2, Point Grey b) NC353L, Elphen c) Ensenso N10, iDS Imaging & Camera System

1.1.1.7.- Técnicas basadas en cámaras en movimiento

Se trata de una técnica similar a la estéreo visión con la diferencia de que las imágenes se capturan con una sola cámara desde diferentes puntos de vista. Requiere una buena calibración de la cámara y que el objeto a escanear permanezca inmóvil. Las localizaciones desde donde son capturadas las imágenes deben ser conocidas o bien usando sensores externos o bien calculándolas usando puntos conocidos en las imágenes. Una vez conocido esto se pueden aplicar los mismos pasos que para las técnicas de estereovisión.

Las principales ventajas son que resultan baratos puesto que solo requieren una cámara, no requieren una iluminación específica y pueden escanear objetos de cualquier tamaño.

1.1.1.8.- Técnicas basadas en acomodación de enfoque

Se trata de métodos que utilizan la propiedad de profundidad de campo de una cámara para calcular la información 3D de la imagen. Esto se consigue porque el objeto fotografiado sufre un desenfoque proporcional a la distancia entre los puntos del objeto y los puntos del objeto enfocado (Nayar, Watanabe, & Noguchi, 1996). Existen dos variantes: pasiva y activa. La pasiva se basa en medir la distorsión en la textura de los objetos mientras que la activa se basa en medir la distorsión sobre un patrón de luz que se emite sobre el objeto. Estas técnicas se utilizan especialmente en microscopía.

Las principales ventajas de las técnicas basadas en este método son que es económico y sencillo de utilizar. Por otro lado, sus desventajas son que tienen una resolución espacial no uniforme (la profundidad tiene mucha menor resolución), requiere de un sistema mecánico complejo si se quiere escanear escenas con profundidades muy diferentes, requiere una calibración precisa de la cámara y en caso de que sea pasivo le puede afectar la luz ambiental.

1.1.1.9.- Técnicas basadas en conocimiento de la escena

Estas técnicas consisten en extraer información 3D a partir de una sola imagen 2D capturada en una escena donde aparece un objeto conocido. Conociendo las dimensiones del objeto y teniendo una buena calibración de la cámara es posible extraer información 3D, siendo especialmente precisa en las dimensiones x e y (siendo z el eje de distancia a la cámara). Se suele emplear en conjunción con otras técnicas como luz estructurada (Rönholm, Honkavaara, Litkey, Hyyppä, & Hyyppä, 2007).

Las ventajas que presentan estas técnicas son que son baratas, sencillas de aplicar y se consiguen buenos resultados en objetos bien definidos. Las desventajas son que tiene que haber siempre en la imagen un patrón conocido y que puede ser exigente computacionalmente dependiendo del modelo.

1.1.1.10.- Técnicas basadas en estéreo fotométrico

La idea del estéreo fotométrico consiste en variar la dirección de la luz incidente en una escena entre distintas imágenes, manteniendo el punto de vista constante (Woodham, 1980). La intensidad de las imágenes obtenidas se utiliza para calcular matemáticamente el proceso inverso de generación de las imágenes. Para resolver el sistema de ecuaciones de este proceso es necesario conocer las propiedades de reflexión de la escena y la geometría del sistema de iluminación utilizado (mapa de reflectancia). Resolviendo estos sistemas de ecuaciones se extrae la información $2D\frac{1}{2}$ (la orientación de la superficie) y el color real (también llamado albedo). Actualmente, se ha mejorado la técnica utilizando varios puntos de vista que permiten capturar la escena sin conocer a priori la posición de las luces y que al mismo tiempo mejoran la precisión (Hernandez, Vogiatzis, & Cipolla, 2008).

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

Las ventajas de este método es que es rápido y económico sin embargo no tiene mucha resolución, es necesario tener controlada la iluminación y adquiere solo información 2D½.

1.1.1.11.- Técnicas basadas en el análisis de textura

Estas técnicas consisten en la extracción de información 3D a partir de imágenes 2D de objetos con texturas irregulares. Por ejemplo un círculo en una superficie con inclinación se mostraría en la imagen 2D como una elipse y dependiendo de los parámetros de esta elipse se podría estimar la inclinación de esta superficie. Son métodos económicos y sencillos de utilizar pero los resultados no son precisos y necesitan que la escena contenga mucha textura.

1.1.2.- Revisión del estado del arte de las técnicas 3D en la industria alimentaria

Desarrollar nuevos productos y procesos son objetivos prioritarios de la industria alimentaria para mejorar su competitividad y sus beneficios. Para alcanzar estos objetivos es necesario incorporar nuevas formas de mejorar la calidad, seguridad y eficiencia de los procesos tradicionales (Datta & Halder, 2008). La visión por computador es una de las formas de abordar estos objetivos debido a su naturaleza no destructiva y a los buenos resultados que ha dado en otros tipos de industria en el control de calidad. Dentro de la visión por computador cabe destacar los sistemas 3D basados en imágenes que no solo complementan los sistemas tradicionales de 2D (Poussart & Laurendeau, 1988) sino que resuelven problemas muy difíciles de estos últimos (Mufti & Mahony, 2011). El resultado es que el interés en este tipo de visión por computador 3D está aumentando y se está adaptando para su uso en la industria alimentaria.

1.1.- Estado del arte de sensores tridimensionales (3D)

Conocer el modelo 3D de un alimento puede ser muy interesante para modelar las transformaciones que sufre el mismo y tener un mayor control de los procesos. Por ejemplo Fabbri, Cevoli, Romani, & Rosa (2011) usaron modelos 3D para describir modelos numéricos de la propagación de calor y de la transferencia de masa durante el tostado de café. Trujillo & Pham (2006) también hicieron uso de información 3D, en este caso de ternera para el control de temperatura y humedad en el proceso de refrigeración.

Las técnicas 3D más empleadas en la industria alimentaria son las basadas en luz estructurada, en estéreo visión y en menor medida las de tiempo de vuelo como veremos a continuación.

La estéreo visión se emplea principalmente en el campo de la acuicultura debido a la dificultad de emplear otros sistemas bajo el agua. Existen numerosos estudios que abordan la problemática de obtener las correspondencias entre imágenes (visibilidad del agua, corrientes, contaminación en el agua, etc...), y por tanto la información 3D, en un medio acuático. Algunos ejemplos son (Ruff, Marchant, & Frost, 1995; Harvey et al., 2003; Martínez-de Dios, Serna, & Ollero, 2003; Quevedo & Aguilera, 2010). Una variante de la estéreo visión es la utilización de un vídeo usando una sola cámara en movimiento, que también se emplea para este tipo de aplicaciones como por ejemplo para medir la velocidad de los peces (Petrell, Shi, Ward, Naiberg, & Savage, 1997) o para estudiar la biodiversidad en las costas (Mallet & Pelletier, 2014) sin embargo, (Harvey, Shortis, Stadler, & Cappelletti, 2002) demuestra en su estudio que las técnicas de estéreo visión son más precisas y robustas para medidas en el medio acuático. Otras aplicaciones en las que se ha usado con éxito la estéreo visión ordenadas de menor a mayor tamaño de medición son: para calcular el tamaño de los granos de trigo (Sun, Berman, Coward, & Osborne, 2007), para medir volumen de frutas como por ejemplo el mango (Chalidabhongse, Yimyam, & Sirisomboon, 2006) o el tomate (Xiang, Jiang, & Ying, 2014), estudiar el florecimiento de árboles frutales (Nielsen, Slaughter, & Gliever, 2012) o para la navegación de vehículos agrícolas (Rovira-Más, Zhang, & Reid, 2008).

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

Por lo que respecta a los sensores basados en luz estructurada, también hay un gran número de aplicaciones desarrolladas para alimentos como por ejemplo la predicción de la densidad de alimentos midiendo el volumen y el peso (Kelkar, Stella, Boushey, & Okos, 2011), la reconstrucción 3D de tomates (Hatou, Morimoto, De Jager, & Hashimoto, 1996), el análisis preciso del crecimiento de plantas de trigo (Paulus, Schumann, Kuhlmann, & Léon, 2014) o las estimaciones de área y volumen de diversas frutas como las manzanas, las peras, las bananas y las fresas (Uyar & Erdoğdu, 2009). Sin embargo, estas aplicaciones se realizaron con escáneres 3D y procesamientos de la información optando por la precisión en las mediciones y los cálculos sin tener en cuenta el tiempo. No obstante, además de la precisión de los métodos que utilizan luz estructurada, la gran ventaja de estos sensores es su rapidez en el cálculo del 3D lo cual hace que sean especialmente indicados para la industria. Por ejemplo, los siguientes estudios se basan en esta cualidad para el cálculo rápido de parámetros de alimentos como el peso de pescados (Mathiassen, Misimi, Toldnes, Bondø, & Østvik, 2011), el rigor mortis de pescados (Misimi, Erikson, Digre, Skavhaug, & Mathiassen, 2008) o la monitorización de la fermentación de diferentes harinas (Eugenio Ivorra, Amat, Sánchez, Barat, & Grau, 2014), de hecho en el estudio (Verdú et al., 2013a) se compara la luz estructurada con los sensores de tiempo de vuelo para su aplicación en línea saliendo vencedora la luz estructurada. También han proliferado las aplicaciones basadas en la cámara Kinect Microsoft© que proyecta un matriz de luz infrarroja y calcula la profundidad dependiendo de la deformación de la misma. Ha tenido éxito la Kinect debido principalmente a su bajo coste. Algunos ejemplos de aplicaciones de la Kinect para alimentos incluye la medición del volumen de comida en un plato y su identificación (M.-Y. Chen et al., 2012), la estimación de tamaño de cebollas (Wang & Li, 2014), el control de carne en mataderos (Larsen, Hviid, Jørgensen, Larsen, & Dahl, 2014) o para el estudio del fenotipo de plantas (Chéné et al., 2012).

A pesar de que los sensores de tiempo de vuelo se usan principalmente en la navegación de robots móviles, existen aplicaciones de esta tecnología en el sector alimenticio. Algunos ejemplos de estas aplicaciones son el modelado de plantas (Klose, Penlington, &

1.1.- Estado del arte de sensores tridimensionales (3D)

Ruckelshausen, 2009; Kazmi, Foix, Alenyà, & Andersen, 2014) o la monitorización de la fermentación del alcohol (Hoche, Hussein, Hussein, & Becker, 2011). Dentro de los diferentes tipos de sensores de tiempo de vuelo destacan los ultrasonidos en número de aplicaciones para el control de calidad de alimentación como se puede comprobar en la revisión del estado del arte realizada por (Awad, Moharram, Shaltout, Asker, & Youssef, 2012).

Existen también estudios con sensores basados en rayos X que demuestran que estos pueden ser usados exitosamente para estimar el volumen de frutas así como sus componentes internos (Barcelon, Tojo, & Watanabe, 1999; Veliyulin, Misimi, Bondø, Vebenstad, & Østvik, 2011; Salmanizadeh, Nassiri, Jafari, & Bagheri, 2014). Al igual que con los rayos X, también se han adaptado recientemente los sensores basados en campos magnéticos utilizados en medicina para ser usados en el sector de la alimentación. Algunos ejemplos del uso de resonancia magnética en este sector son la monitorización del crecimiento de los “ojos” de los quesos (Musse, Challos, Huc, Quellec, & Mariette, 2014), detección de defectos internos en manzanas Fuji (Gonzalez et al., 2001), medición de la densidad de alimentos (Kelkar et al., 2011) o en la cuantificación de los diversos tipos de tejidos (grasa-músculo) en cerdos (Monziols et al., 2006). Para más información se puede consultar la siguiente revisión del estado del arte de la resonancia magnética aplicada a alimentos (Patel, Khan, & Kar, 2013). Con el avance tecnológico, estos tipos de sensores han evolucionado mucho y han reducido un poco su coste pero aun así sigue siendo muy alto y unido a las desventajas ya mencionadas en los apartados anteriores **1.1.1.4 y 1.1.1.5** (peligrosidad, velocidad de adquisición lenta, limitación en tamaño de escaneado) explica el limitado número de aplicaciones en el sector.

1.2.- Técnicas hiperespectrales de visión por computador

1.2.1.- Fundamentos de la técnica hiperespectral

1.2.1.1.- Radiación electromagnética

La radiación electromagnética es una combinación de campos eléctricos y magnéticos oscilantes perpendiculares entre sí, que se propagan a través del espacio transportando energía de un lugar a otro. El espectro electromagnético se extiende desde la radiación de menor longitud de onda, como los rayos gamma y los rayos X, pasando por la luz ultravioleta, la luz visible y los rayos infrarrojos, hasta las ondas electromagnéticas de mayor longitud de onda, como son las ondas de radio. Se cree que el límite para la longitud de onda más pequeña posible es la longitud de Planck mientras que el límite máximo sería el tamaño del Universo aunque formalmente el espectro electromagnético es infinito y continuo.

El espectro electromagnético, como se muestra en la figura 2.2, está formado por las siguientes regiones que son los rayos gamma, los rayos X, la radiación ultravioleta (UV), la luz visible (VIS), la radiación infrarroja (IR) divide a su vez en el infrarrojo cercano (NIR), infrarrojo medio (MIR) e infrarrojo lejano (FIR), las regiones de microondas y las ondas de radio (FM y AM). Cada región corresponde a un determinado tipo de transiciones atómicas o moleculares correspondiente a las diferentes energías.

1.2.- Técnicas hiperespectrales de visión por computador




Figura 2.2: Espectro electromagnético

El espectro visible es la región de frecuencias entre 400 y 700 nm que pueden ver los seres humanos y que denominamos luz. Las ondas lumínicas son electromagnéticas y, por tanto consisten en un campo eléctrico oscilante perpendicular y en fase con un campo magnético oscilante.

En general, una onda electromagnética se compone de valles y crestas sucesivas, y a la distancia entre dos crestas o valles adyacentes se la conoce como la longitud de onda. Las ondas electromagnéticas del espectro varían mucho en tamaño, desde las ondas de radio tan grandes como el tamaño de un edificio, a los rayos gamma cuyo tamaño es inferior al del núcleo de un átomo. La frecuencia (f) es inversamente proporcional a la longitud de onda (λ), de acuerdo con la ecuación de la velocidad de la onda (v) que es igual a c en el vacío (aprox. 3×10^8 m/s):

$$v = \lambda * f \quad (2.7)$$

Cabe resaltar de esta ecuación que la frecuencia es inversa a la longitud de onda para mantener constante la velocidad de la onda.

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

1.2.1.2.- Radiación NIR

La región del infrarrojo comprende el intervalo espectral entre 780 nm y 1000 μm . Según el fenómeno espectroscópico que provoca la absorción de energía por parte de la materia, podemos dividir esta región en tres zonas (U. -E ISO, 2007):

- Infrarrojo cercano 780:3000 nm (NIR).
- Infrarrojo medio 3000:50 μm (MIR).
- Infrarrojo lejano 50:1000 μm (FIR).

El infrarrojo lejano (FIR) se debe a las rotaciones moleculares, mientras que el medio (MIR) proviene de las vibraciones moleculares fundamentales. El origen del infrarrojo cercano (NIR) se debe a los sobretonos y combinaciones de las bandas fundamentales del infrarrojo medio como a continuación se va a explicar.

Una molécula absorbe radiación infrarroja cuando experimenta un cambio neto en el momento dipolar como consecuencia de su movimiento de vibración o de rotación. Si esto ocurre, el campo eléctrico asociado a la radiación puede interactuar con el campo eléctrico originado por la fluctuación del momento dipolar de la molécula. Si la frecuencia de la radiación iguala exactamente a la frecuencia de vibración natural de la molécula, ocurre una transferencia neta de energía que da lugar a un cambio en la amplitud de la vibración molecular y como consecuencia se absorbe la radiación. Sin embargo, la energía no se transfiere continuamente, sino en paquetes discretos llamados quantum. En consecuencia, las moléculas sólo pueden ocupar niveles discretos de energía definidos por números enteros 0, 1, 2... y el cambio de energía necesaria para una transición entre dos niveles está directamente relacionado con la frecuencia de la energía multiplicada por h (la constante de Planck).

Para el movimiento armónico simple, la absorción o emisión de energía sólo puede tener lugar si coincide con una transición entre cualquier par de niveles de energía adyacentes. La primera

1.2.- Técnicas hiperespectrales de visión por computador

transición para la mayoría de moléculas es del nivel de energía 0 a 1 y se llama transición o banda fundamental. El modelo armónico simple no describe adecuadamente el movimiento de vibración de los enlaces químicos porque por un lado los átomos se repelen entre sí cuanto más se acercan y por el otro lado se disminuye la energía potencial cuando se acercan a la distancia de rotura de enlace. Es por eso que el modelo anarmónico es más realista. En este modelo los niveles energéticos no están igualmente espaciados: a niveles de energía más altos, la energía entre niveles consecutivos es menor. Las transiciones energéticas no se producen únicamente para la banda fundamental ($n = \pm 1$), sino que también se observan transiciones $n = \pm 2, \pm 3...$ cuyas bandas se denominan sobretonos. Los sobretonos se detectan en las longitudes de onda de la región NIR.

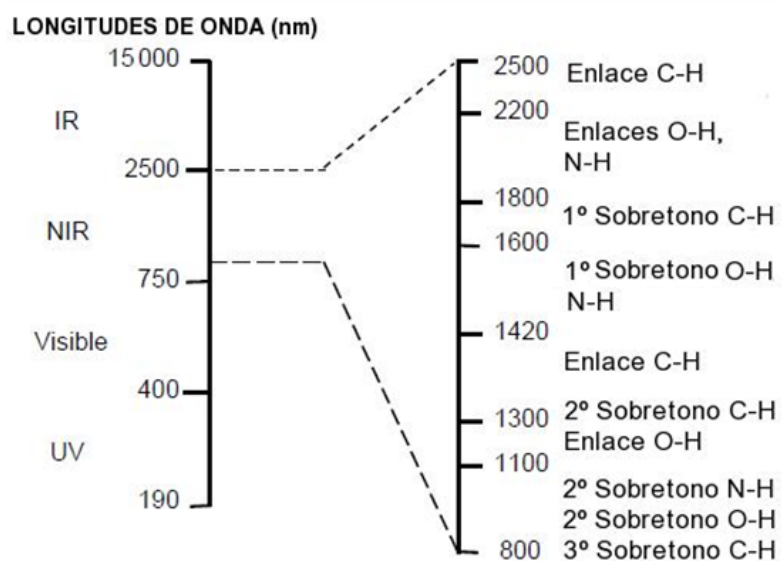


Figura 2.3: Principales bandas de absorción en el NIR y su localización

El primer sobretono ($n = 2$) es el de mayor intensidad. Además de los sobretonos, en la región NIR también pueden observarse otro tipo de bandas de absorción, llamadas bandas de combinación, debidas a la interacción entre las diferentes frecuencias fundamentales de vibración de moléculas poliatómicas (sumas o restas de múltiplos de cada una de las frecuencias de los diferentes átomos que interaccionan).

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

1.2.1.3.- Origen

La espectroscopia en el rango del infrarrojo se lleva utilizando desde hace mucho tiempo, el comienzo de toda esta línea de investigación se remonta a 1800 cuando el astrónomo W. Herschel demostró la existencia de la radiación infrarroja (Herschel, 1800). Después, en la década de 1880, W. Abney y ER. Festing empezaron a aplicar radiación infrarroja en componentes químicos consiguiendo correlacionar bandas de absorción a determinadas longitudes de onda con componentes químicos (Abney & Festing, 1886). A partir de este punto se han llevado a cabo muchos estudios enfocados a la identificación de elementos y a la creación de bases de datos con los espectros inequívocos de ellos. Sin embargo, todos estos estudios se realizaron en el rango del infrarrojo medio y lejano (1500nm -1 mm) y no es hasta 1963 con Hart et al que no se empieza a trabajar en el rango del infrarrojo cercano con su trabajo acerca de la calidad de semillas (Hart & Norris, 1963). Durante las últimas tres décadas el desarrollo de nuevos métodos analíticos ha ido en paralelo al desarrollo de la tecnología informática y de espectrómetros con mayor sensibilidad.

1.2.2.- Contexto actual

Uno de los objetivos de la Unión Europea es garantizar la seguridad de los alimentos que son consumidos. Para cumplir este objetivo la Unión Europea incentiva mediante una serie de programas el desarrollo y la implantación de nuevas tecnologías en la industria agroalimentaria. En este sentido, diferentes investigaciones se han dirigido a la obtención de técnicas no destructivas para la evaluación de factores de calidad internos y externos de los alimentos. Una de ellas es el análisis de imagen, de entre las que se incluyen el análisis de resonancia magnética nuclear (NMR) (Kim, Chen, McCarthy, & Zion, 1999), resonancia magnética (MRI) (Gonzalez et al., 2001) y rayos X (Barcelon et al., 1999), como técnicas para caracterizar la

1.2.- Técnicas hiperespectrales de visión por computador

composición química, fenómenos de transferencia de agua en carne o la calidad de las frutas. La principal ventaja del uso de las técnicas NMR, MRI y rayos X es la posibilidad de adquirir imágenes del interior del producto, sin embargo su elevado coste, la dificultad técnica para el trabajo en línea y, en algunos casos, los riesgos asociados a su empleo (p.e. en el caso de las imágenes por rayos X) hacen que la aplicación de estas tecnologías sea complicada (P. Chen & Sun, 1991).

Esto ha provocado que los métodos de espectroscopia hayan ganado mucha importancia en la evaluación de factores de calidad de los alimentos durante las últimas décadas ya que no presentan las anteriores desventajas. El hecho de que el espectro NIR refleje diversos parámetros del material lo hace apropiado para evaluar complejos factores de calidad (Williams & Norris, 2001). Concretamente, el infrarrojo cercano de longitud de onda corta (SW-NIR) parece especialmente prometedor para la determinación rápida y no destructiva de atributos en muestras biológicas (Wu, He, & Feng, 2008; Wu, He, Feng, & Sun, 2008). Esto se debe a que en el rango SW-NIR la energía penetra más en la muestra con mucha menos aportación calórica a la misma que en el rango del NIR. Además, el SW-NIR puede ser medido con iluminantes (halógenos de tungsteno) y detectores (silicon diode array) muy baratos (Mayes & Callis, 1989), lo que supone una gran diferencia de coste respecto a otros métodos.

En la actualidad, la espectroscopia está dando paso a la espectroscopia óptica con imágenes hiperespectrales, en las cuales se tiene tanto información espectral como espacial. Las técnicas hiperespectrales tienen un amplio abanico de posibles aplicaciones, como el control de calidad en química / farmacia, análisis en biología / bioquímica, diagnosis en ciencias biomédicas, control de calidad en alimentación y temas forenses o toxicología, entre otras. En el sector médico, este campo de investigación es de gran utilidad como por ejemplo para la detección de células cancerígenas (Kam, O'Connell, Wisdom, & Dai, 2005), permitiendo a los médicos distinguir mejor melanomas y otras afecciones cutáneas. En el sector de la construcción, uno de sus usos es el análisis de las propiedades químicas de cementos (Gastaldi, Canonico, Irico, Pellerej, & Paganini, 2010). Además, sus aplicaciones se expanden a todo tipo de industrias

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

como la del reciclaje (Farcomeni, Serranti, & Bonifazi, 2008) o la farmacéutica (Fortunato de Carvalho Rocha, Sabin, Março, & Poppi, 2011).

En el sector de la alimentación las técnicas hiperespectrales son de especial interés porque permiten el análisis de alimentos de forma individual o colectiva, reducen desechos al no ser destructivas y permiten un estudio temporal sobre la misma muestra. Debido a estos motivos, entre otros, el volumen de aplicaciones y estudios de estas técnicas en el sector alimenticio ha aumentado mucho. El estado del arte más actual se puede consultar en los siguientes trabajos: enfocado en frutas (Nicolai et al., 2007; Magwaza et al., 2012) o más general para todo tipo de alimentos que cubre más de 260 trabajos y aplicaciones durante los últimos años (Alander, Bochko, Martinkauppi, Saranwong, & Mantere, 2013; Qu et al., 2014).

Con el fin de obtener nuevos conocimientos y procedimientos para la caracterización de diversas muestras tanto de origen animal como vegetal, en esta tesis se ha aprovechado el avance tecnológico que permite obtener imágenes hiperespectrales con mayor resolución espectral y espacial que los equipos utilizados tradicionalmente.

1.2.3.- Diferencias entre espectroscopia, análisis de imagen en visible e hiperespectral

El análisis clásico de imágenes en visible tiene algunos inconvenientes que lo hacen inadecuado para determinadas aplicaciones industriales. Es ineficiente en el caso de objetos con colores RGB similares, en el caso de clasificaciones complejas, es incapaz de predecir atributos de calidad (composición bioquímica) y no puede detectar la presencia de defectos invisibles a la vista.

1.2.- Técnicas hiperespectrales de visión por computador

Actualmente, se han desarrollado muchas técnicas ópticas mediante espectroscopia de infrarrojo (IR) como un medio para la detección no destructiva de calidad de los alimentos. IR es rápida, no destructiva y relativamente fácil de implementar en aplicaciones “on-line” y “off-line”. Además, tiene la posibilidad de medir simultáneamente varios atributos de calidad. En estas técnicas espectroscópicas, es posible obtener información sobre características cualitativas de la muestra basada en la absorción de la luz, sin embargo no resulta sencillo conocer la ubicación de esta información. Es decir, la espectroscopia nos proporciona una muy buena resolución espectral pero una mala resolución espacial, al contrario que la visión por computador tradicional que nos da una muy buena resolución espacial pero una mala resolución espectral.

La unión de la visión por computador clásica y la espectroscopia da lugar a la técnica hiperespectral, que junta los puntos fuertes de ambas. Una imagen corriente de visión por computador contiene la información espacial de la muestra en una matriz de 2D (X,Y) mientras que la imagen hiperespectral se diferencia en que añade una dimensión más, de forma que se consigue un cubo en 3D (X,Y,Z), como podemos ver esquemáticamente en la Figura 2.4.

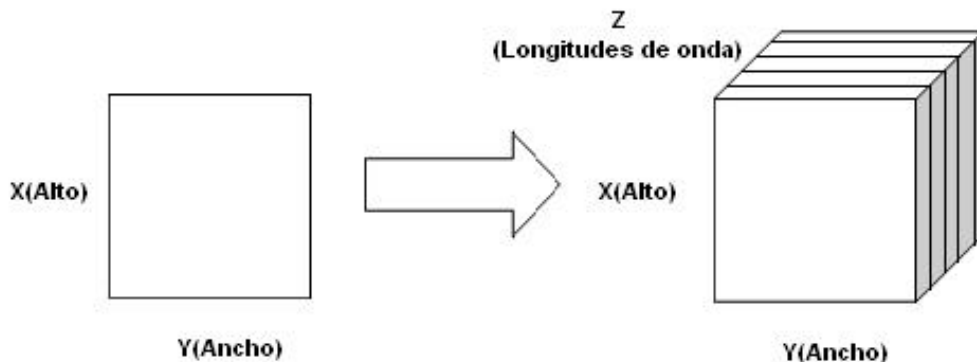


Figura 2.4: Imagen tradicional vs hiperespectral

En resumen, las principales diferencias y ventajas de las imágenes hiperespectrales sobre los métodos convencionales y técnicas espectroscópicas se exponen en la Tabla 2.1.

Capítulo 2: Estado del arte de las técnicas tridimensionales e hiperespectrales en la industria alimentaria

Tabla 2.1: Principales diferencias imagen clásica, espectroscopia e hiperespectral

Características	Imagen 2D clásica	Espectroscopia	Hiperespectral
Información espacial	Sí	No	Sí
Información espectral	No/RGB	Sí	Sí
Composición química	No	Sí	Sí
Robustez	Sí	No	Sí

1.2.4.- Ventajas y desventajas de las técnicas hiperespectrales

A continuación se exponen las principales ventajas de la utilización de la imagen hiperespectral en alimentación, sector en el que se centra la presente tesis:

- No requiere preparación de las muestras.
- Es un análisis no-destructivo y no-invasivo, con lo que no altera las muestras.
- Una vez realizada la calibración y validación del modelo, resulta muy rápido y sencillo de utilizar.
- La inversión en el sistema se recupera rápidamente al no tener que comprar reactivos ni ningún material fungible para realizar los análisis en las muestras.
- Al tener resolución espacial se pueden analizar varias muestras de forma simultánea.
- Es más robusto que la técnica de espectrografía al no depender la medida de un solo punto y tener información redundante.
- Es rápida, ya que no requiere repetir la captura en diferentes puntos.
- Puede identificar distintos componentes químicos en una muestra.
- Es capaz de seleccionar regiones de interés en una muestra.
- Se puede implementar en una línea de producción.

Por el contrario, también presenta desventajas como:

1.2.- Técnicas hiperespectrales de visión por computador

- Proporciona mucha información redundante que conlleva un mayor coste computacional para su procesamiento.
- Es necesario un equipo con una buena capacidad de procesamiento para su utilización.
- Es un método indirecto, puesto que requiere la utilización de un modelo y su validación.
- Es necesario realizar un filtrado para su uso en línea.
- En caso de muestras líquidas u homogéneas puede resultar más económico la espectrografía.

Como se puede observar el número y la importancia de las ventajas supera en mucho el de las desventajas como evidencia la proliferación de artículos de investigación actuales en esta línea (Gowen, O'Donnell, Cullen, Downey, & Frias, 2007).

Capítulo 3: Aportaciones de las técnicas 3D

1.- Introducción

Existen muchas técnicas tridimensionales que se pueden utilizar en el sector alimentario tal y como se explica en el capítulo 2. En esta tesis se ha optado por emplear y estudiar tres tipos diferentes de sensores: de tiempo de vuelo (TOF), de luz estructurada (SL) y de visión estéreo. Se han realizado tres casos prácticos uno para cada técnica excepto el de luz estructurada que se empleó en dos de ellos. En el primero de los casos prácticos se realizó una comparativa de los métodos de TOF y SL aplicados a muestras de origen animal y vegetal, así como de los problemas que surgieron en su utilización y sus correspondientes soluciones. En el segundo, se profundizó en la técnica SL y se realizó un procesamiento más avanzado de la información tridimensional que aporta este método. En el último de los casos prácticos se utilizó un sistema de visión estéreo en condiciones de adquisición similares a campo (que complican el problema) donde se soluciona el difícil problema de correspondencias en uvas. Además, en este último caso se definieron parámetros de caracterización de racimos de uva que únicamente pueden ser calculados obteniendo el modelo tridimensional de las muestras.

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal

2.1.- Descripción del estudio

El estudio se llevó a cabo en diferentes tipos de alimentos con composiciones, estructuras y dimensiones diferentes. Los alimentos fueron de dos tipos de tejido animal (músculo *longissimus dorsi* de cerdo y grasa ventral) y de tres tipos de tejido vegetal (patata, manzana y aguacate). Para calibrar el sistema se utilizaron bloques sólidos, con forma regular y sin brillos.

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal

Para cada tipo de alimento, se cortaron 5 muestras ($n=25$) en forma cúbica con tamaños aleatorios (desde $3.6 \text{ m}^3 \cdot 10^{-6}$ a $70.2 \text{ m}^3 \cdot 10^{-6}$). Debido a la dificultad de cortar las muestras de tejido animal con formas regulares, el volumen se calculó empleando la siguiente ecuación:

$$V = M/\delta \quad (3.1)$$

Donde M es la masa y δ es la densidad de la muestra (medida con un picnómetro). Para calcular el volumen en los productos vegetales, debido a que tuvieron formas más regulares, se utilizó la conocida fórmula para el cálculo de volúmenes de paralelepípedos:

$$V = LWH \quad (3.2)$$

Donde L es la longitud, W el ancho y H el alto de la muestra.

2.2.- Sistema tridimensional por tiempo de vuelo (TOF)

El método de tiempo de vuelo está basado en el cálculo del tiempo que requiere una onda electromagnética en ir y volver a través de un medio conocido. En este caso, el dispositivo de adquisición es una PMD[Vision] 19k camera (PMDTechnologies GmbH, Siegen, Alemania) (Figura 3.1) que proporciona imagen e información de profundidad de la escena. El sensor de la cámara está basado en tecnología CMOS formado por 19200 PMD (Photonic Mixer Devices) píxeles organizados en una matriz de 160 por 120.

El tiempo de vuelo (t_d) es proporcional a la distancia $d = \frac{c}{2} t_d$ de la superficie y al desfase $\phi_d = \frac{4\pi f}{c} d$ de la señal óptica recibida en cada píxel PMD. Esta señal es correlada con la señal de referencia generada justo después de que el fotodiodo emita con la misma frecuencia, pero

cambiada por los ángulos $\alpha_n = \frac{2\pi n}{N}$, $n = 0 \dots N - 1$. Conociendo la velocidad de la luz en el aire $c = 3 \cdot 10^8 \frac{m}{s}$, la frecuencia de modulación del equipo $f = 20 \text{ MHz}$ y $N = 4$ (para este caso) se puede saber la distancia. El rango máximo de medida corresponde al ángulo $\phi_d = 2\pi$: $d_{\max} = \frac{c}{4\pi f} \phi_d = \frac{c}{2f} = 7500 \text{ mm}$. Para más detalles acerca del cálculo del desfase consultar (Luan, 2001; Plaue, 2006).

La adquisición de imagen se realizó utilizando tres puntos de vista diferentes para cada una de las muestras. Esto se realizó rotando las muestras de forma que todos los lados (X, Y y Z) se encontraran en posición vertical. La rotación de las muestras se realizó para estudiar la posible influencia entre la superficie expuesta y la altura de las muestras. Para cada una de las posiciones se adquirieron 50 imágenes usando un tiempo de integración de $5 \cdot 10^{-3} \text{ s}$ y capturando 1.5 imágenes por segundo. La adquisición de imagen se llevó a cabo en un ambiente controlado sin luz ambiental, utilizando únicamente la luz infrarroja emitida por el dispositivo para evitar posibles ruidos de otras fuentes de luz.

Se utilizó un fondo negro plano situado a una distancia de 0.4m de la luz infrarroja y a 0.368 m de la óptica de la cámara. Se capturó una imagen sin muestras que luego se utilizó para restar a las imágenes de las muestras para obtener las alturas de las muestras en valores positivos.

Para cada posición de la muestra, se realizó un filtro temporal utilizando la mediana de las 50 imágenes de profundidad y a esta imagen resultante se le aplicó a continuación un filtro espacial de mediana con una ventana de 9×9 píxeles. Una vez la imagen 3D estaba filtrada, se segmentó la imagen y se calcularon las dimensiones y el volumen de las muestras. La cámara se calibró para transformar la información adquirida al sistema internacional (SI) y rectificar la imagen.

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal




Figura 3.1 Configuración del sistema tridimensional de tiempo de vuelo

2.3.- Sistema tridimensional por luz estructurada (SL)

El sistema tridimensional por luz estructurada se basa en la proyección de un patrón de luz sobre la muestras y en el cálculo de sus dimensiones 3D a partir de la deformación de este patrón usando una cámara. En este caso, el patrón es una línea proyectada por un láser rojo lineal (Lasiris SNF 410, Coherent Inc. Santa Clara, California, Estados Unidos) a una distancia de 0.02 m. La cámara utilizada (AD-080CL, JAI Company, Yokohama, Kangawa, Japón), trabajó a 15 imágenes por segundo y se colocó a 0.04 m sobre una cinta transportadora. Además, la cámara y el láser se colocaron de forma que la línea del láser proyectara en una única fila de la imagen. Tanto la cámara como el láser estuvieron fijos durante todo el estudio.

Las muestras se reconstruyeron enteras mediante el movimiento constante de la cinta transportadora a $15 \cdot 10^{-4}$ m/s. La resolución del sistema para la configuración establecida fue

de $3 \cdot 10^{-5}$ m, $1 \cdot 10^{-4}$ m y $103 \cdot 10^{-6}$ m en los ejes X, Y y Z respectivamente (Figura 3.2). La resolución en X depende de la resolución en píxeles de la cámara, la óptica utilizada y la distancia a la muestra; la resolución en Y depende de la velocidad de la cinta transportadora y de las imágenes por segundo que captura la cámara por lo que se podría mejorar fácilmente; y la resolución en Z que depende del ángulo entre la cámara y el láser. Se utilizó un ángulo β (Figura 3.2) de 38.675 grados, escogido como una medida de compromiso entre la resolución Z y un rango de trabajo válido para las muestras a analizar.




Figura 3.2. Esquema del sistema tridimensional por luz estructurada

Las muestras se colocaron en la cinta transportadora, una detrás de otra para ser escaneadas por el haz del láser. Para aumentar la información capturada y reducir el área de oclusión, las muestras fueron escaneadas por duplicado, girándolas 90 grados respecto al eje Z.

La calibración del sistema de visión 3D por luz estructurada se realizó en tres fases:

- El cálculo de los parámetros intrínsecos de la cámara.
- Hallar la correspondencia entre el plano de proyección de la línea láser en la cinta transportadora y el plano de proyección de la imagen en la cámara.
- Sincronización de la cámara y la cinta transportadora.

El proceso de calibración de parámetros intrínsecos se realizó utilizando el método de calibración flexible de Zhang (Z. Zhang, 2000) usando la librería *OpenCV*. Este método calcula la

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal

distancia focal, el punto principal, el coeficiente de oblicuidad y las distorsiones radial y tangencial hasta de orden cinco de la óptica. Para realizar este proceso se utilizó una plantilla con un patrón de cuadrados de ajedrez (10 filas por 15 columnas) de 10 milímetros de lado, alternados en color blanco y negro y 10 imágenes diferentes (aunque teóricamente solo hacen falta 4 se utilizaron 10 para una mayor precisión).

La correspondencia entre el plano de proyección de la línea láser en la cinta transportadora, y el plano de proyección de la imagen en la cámara se realizó tomando 10 puntos distribuidos regularmente en la escena 3D en el plano de proyección del láser (Trobina, 1995). Usando estos puntos con coordenadas 3D conocidas y sus correspondientes puntos en la imagen se calculó la transformación de homografía. Una homografía se define matemáticamente como una matriz de dimensiones 3×3 , H que cumple las siguientes ecuaciones:

$$\begin{bmatrix} x_2 \\ y_2 \\ z_2 \end{bmatrix} = \begin{bmatrix} H_{11} & H_{12} & H_{13} \\ H_{21} & H_{22} & H_{23} \\ H_{31} & H_{32} & H_{33} \end{bmatrix} \begin{bmatrix} x_1 \\ y_1 \\ z_1 \end{bmatrix} \leftrightarrow x_2 = Hx_1 \quad (3.3)$$

Utilizando las siguientes condiciones:

$$x'_2 = x_2/z_2, \quad y'_2 = y_2/z_2, \quad z_1 = 1 \quad (3.4)$$

Se obtiene:

$$\left. \begin{array}{l} a_x^T h = 0 \\ a_y^T h = 0 \end{array} \right\} \leftrightarrow Ah = 0 \quad (3.5)$$

Donde:

$$h = (H_{11}, H_{12}, H_{13}, H_{21}, H_{22}, H_{23}, H_{31}, H_{32}, H_{33})^T \quad (3.6)$$

$$\left. \begin{array}{l} a_x = (-x_1, -y_2, -1, 0, 0, 0, x'_2 x_1, x'_2 y_1, x'_2)^T \\ a_y = (0, 0, 0, -x_1, -y_1, -1, y'_2 x_1, y'_2 y_1, y'_2)^T \end{array} \right\} \leftrightarrow A = \begin{bmatrix} a_{x1}^T \\ a_{y1}^T \\ \vdots \\ a_{xn}^T \\ a_{yn}^T \end{bmatrix} \quad (3.7)$$

La matriz H se puede calcular resolviendo el sistema de ecuaciones (3.5) mediante la descomposición por valores singulares de la matriz A y escogiendo el valor más pequeño que es el que mejor se ajusta a los puntos.

Tras el cálculo de la homografía se aplica una matriz de rotación de β grados sobre el eje X a los puntos 3D obtenidos para que coincida el eje Z con el vector normal a la superficie de la cinta transportadora.

La última fase de la calibración del equipo es sincronizar la cámara con la cinta transportadora conectando el disparador de la cámara con un codificador absoluto encargado de medir la velocidad de la cinta transportadora y configurada para tener una resolución constante de $1 \cdot 10^{-4}$ m en el eje y .

Un elemento fundamental del cálculo de la información 3D es determinar la zona de la imagen en la que se encuentra la proyección de la línea láser. La detección robusta y precisa de la línea láser en la imagen es de gran importancia debido a que va a condicionar la calidad de la información 3D obtenida y por tanto del volumen calculado. La extracción de las coordenadas de imagen en las que proyecta el láser se realizó siguiendo estos pasos: primero, se segmentó la imagen utilizando el umbral global de Otsu (Nobuyuki Otsu, 1979), a continuación se filtró la imagen eliminando los píxeles de láser no conectados con áreas menores a 100 píxeles y finalmente, las coordenadas por filas se calcularon empleando la técnica de centro de masas (Haug & Pritschow, 1998). Esta técnica consiste en usar una media ponderada a lo largo de cada columna pesando las coordenadas de acuerdo a su valor de intensidad. Con este método se obtuvo precisión subpíxel.

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal

2.4.- Resultados

Los volúmenes de las muestras medidos por métodos físico-químicos y por los métodos 3D empleados en este estudio se muestran en la figura 3.3. Con la técnica de TOF, se generaron 3 grupos de datos por muestra en respuesta a las 3 posiciones en las que se capturó cada muestra, mientras que utilizando la técnica de SL se generaron 2 grupos de datos.




Figura 3.3. Volúmenes medidos por análisis físico-químico y mediante los sistemas 3D propuestos

La figura 3.4 muestra el modelo 3D de una muestra de tejido magro reconstruida por SL y por TOF.




Figura 3.4. (A) Muestra de magro, (B) imagen 3D usando SL y (C) técnicas TOF.

Capítulo 3: Aportaciones de las técnicas 3D

Para cuantificar y comparar los resultados obtenidos de las técnicas 3D respecto a los obtenidos por métodos físico-químicos, se realizó un análisis estadístico usando el método Bland-Altman (Martin Bland & Altman, 1986). Este procedimiento es usado para comparar dos métodos diferentes de medida y determinar si un nuevo método puede reemplazar a un método aceptado como estándar (Hill, Tofts, & Baldock, 2010). Para proporcionar información adicional a la comparativa también se realizó un análisis PLS.

La tabla 3.1 muestra los resultados del estudio Bland-Altman para las dos técnicas usadas. Los datos presentados son los umbrales que incluían hasta el 95% de las diferencias entre las medias de las muestras. Como es posible observar, los resultados estadísticos demostraron que la técnica SL ofreció mejores resultados que TOF (menor diferencia entre los umbrales para cada tipo de muestra) excepto para las patatas ($\Delta_{SL}=13.27$; $\Delta_{TOF}=8.07$). Las muestras de calibración presentaron resultados similares para ambas técnicas.

Tabla 3.1. Estudio Bland-Altman para la información obtenida de las técnicas 3D comparadas con los análisis físico-químicos. Los resultados son los umbrales superiores e inferiores que incluyen el 95% de las diferencias de las medias para cada muestra.

	TOF			SL		
	Inferior	Superior	Δ	Inferior	Superior	Δ
Madera	-2.64	3.42	6.06	-2.51	3.33	5.84
Magro	-10.77	5.17	15.94	-8.18	2.54	10.72
Grasa	-3.63	6.44	10.07	-5.86	1.73	7.16
Aguacate	-5.02	10.36	15.38	-0.54	7.07	12.61
Manzana	-7.76	12.67	20.43	-4.7	6.25	10.95
Patata	-6.25	1.83	8.07	-6.24	7.03	13.27
Todas	-8.24	8.89	17.13	-6.82	5.2	12.02

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal

No se encontraron relaciones estadísticas significativas al contrastar los resultados obtenidos de Bland-Altman con los principales componentes de las muestras (grasa, carbohidratos o agua) obtenidos de la bibliografía (USDA Nutrient Data Laboratory, 2012) o con el tipo de estructura (vegetal o animal). Debido a esto, se analizaron todas las muestras de forma conjunta. Los resultados usando todas las muestras demostraron que la técnica SL es mejor que la técnica TOF con menor dispersión (figura 3.5).

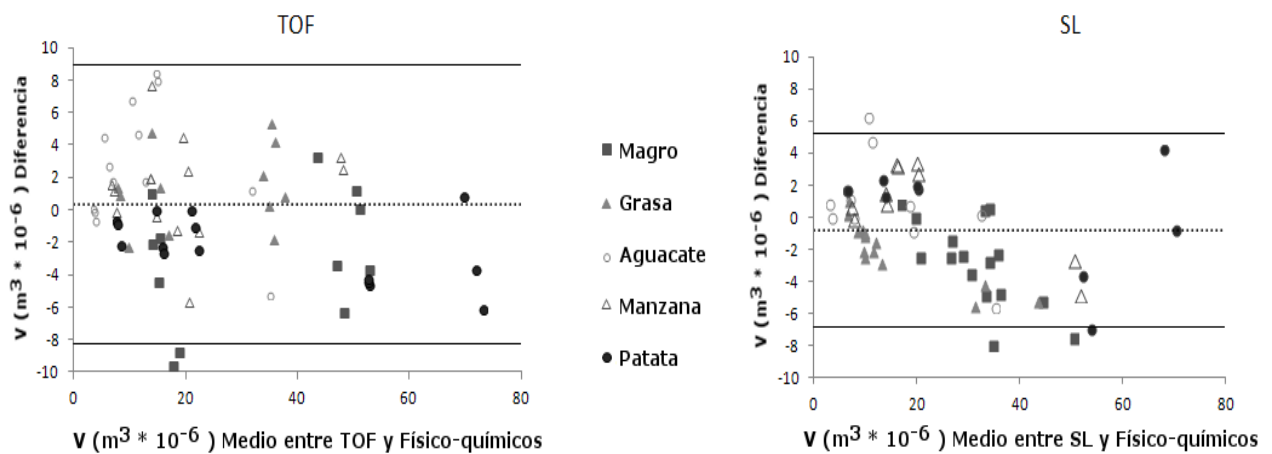


Figura 3.5 Gráfico de los resultados Bland-Altman para las dos técnicas 3D empleadas

El análisis estadístico usando PLS confirmó que la técnica SL es mejor que la TOF en cuanto a resultados, obteniendo valores superiores de R^2CV y de $RMSE$ (tabla 3.2). Se encontró una relación estadística al incorporar la información del tipo de muestra usando la técnica SL. El peor resultado obtenido fue en el aguacate y en la grasa y el mejor en la manzana y en la patata. El contenido en grasa de las muestras puede ser la razón de este comportamiento. De hecho, la grasa en la superficie de algunas muestras provocó una pequeña dispersión (figura 3.6) en la proyección del láser que redujo la precisión.

Capítulo 3: Aportaciones de las técnicas 3D

Table 3.2 Resultados estadísticos PLS para la información obtenida de los dos métodos 3D comparándola con la información obtenida por análisis físico-químicos.

	TOF				SL			
	RMSEC	RMSECV	R ² Cal	R ² CV	RMSEC	RMSECV	R ² Cal	R ² CV
Madera	0.030	0.139	0.99	0.99	0.027	0.040	0.99	0.99
Magro	0.088	0.100	0.95	0.94	0.047	0.050	0.94	0.94
Grasa	0.077	0.091	0.96	0.94	0.034	0.064	0.97	0.92
Aguacate	0.097	0.123	0.87	0.81	0.066	0.088	0.94	0.91
Manzana	0.111	0.122	0.88	0.86	0.035	0.044	0.98	0.98
Patata	0.024	0.028	0.98	0.98	0.043	0.056	0.98	0.98
Todas	0.139	0.141	0.85	0.85	0.066	0.070	0.94	0.94




Figura 3.6 Imagen capturada con el sistema 3D de luz estructurada de una muestra de grasa

Hubo una gran dispersión en los datos cuando se utilizó la técnica TOF tal y como se puede ver en ambos métodos estadísticos. Esto pudo ser debido a factores no controlados que produjeron interacciones con la señal reflejada, modificando el tiempo de vuelo de las ondas de

2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal

vuelta a la cámara. De hecho, el error se incrementó cuando aumentó el ratio de S/V (superficie de la muestra expuesta a la cámara dividida por el volumen de la muestra) como se puede ver en la figura 3.7. Esto pudo ser debido a las irregularidades en la superficie y a los coeficientes de reflexión de la luz infrarroja de las muestras, que pudieron causar que no volvieran las ondas de luz y retrasos en las fases no debidas a las distancias (Mufti & Mahony, 2011).

No se encontraron influencias estadísticamente relevantes al estudiar las áreas de sombra que pueden aparecer debido al ángulo del láser en la técnica de luz estructurada. Los modelos 3D generados y los volúmenes obtenidos de los mismos tuvieron valores similares independientemente de la dirección de escaneado (figura 3.7).




Figura 3.7 Relación entre el ratio S/V y el error entre el volumen obtenido del TOF (VTOF) y de los análisis físico-químicos (VPhCh)

El tiempo requerido para determinar el volumen se puede dividir en el tiempo de adquisición y en el tiempo de procesado. Para el sistema TOF, el tiempo de adquisición se vio limitado por la baja frecuencia de adquisición de este tipo de dispositivo a lo que hay añadir el gran número de imágenes necesario para realizar la media temporal y reducir el ruido. Por otro

lado, el sistema SL tiene una mayor frecuencia de adquisición y solo depende de la velocidad de la cinta y de la resolución requerida. Por lo tanto, el tiempo de adquisición en SL fue menor. Para el tiempo de procesado, SL requirió un mayor tiempo que el sistema TOF para obtener la información 3D y calcular el volumen a partir de la misma. Se puede concluir que ambas técnicas tienen un coste temporal parecido y aceptable para ser usadas en entornos industriales.

2.5.- Conclusiones

Para aplicaciones en línea, SL demostró ser una mejor técnica que TOF para determinar el volumen de alimentos con diferentes composiciones, estructuras y dimensiones. Los alimentos fueron 2 de tejido animal (magro y grasa) y 3 de tejido vegetal (patata, manzana y aguacate). La técnica TOF se vio afectada por factores que aumentaron la dispersión en los resultados y que eran proporcionales al ratio de superficie expuesta a la cámara dividido por su volumen. SL fue afectado ligeramente por la composición de la muestra. El contenido de grasa de algunos alimentos pudo ser la razón de la reflexión del láser sobre la superficie de la muestra que redujo la precisión del sistema. Aun así, los valores de R^2 y RMSE de validación cruzada, para los peores casos, demostraron que SL es una técnica válida para determinar el volumen en alimentos. Se necesitan estudios posteriores para evaluar muestras con formas irregulares, más tipos diferentes de tejidos y estudios de tiempo para adaptar el sistema a una aplicación en línea de producción. Una posible solución para evaluar muestras irregulares sería la utilización de varios láseres.

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada

2.6.- Aportaciones del estudio

En este estudio se comparó un sistema tridimensional por luz estructura y un sistema por tiempo de vuelo para el cálculo del volumen de alimentos. De los resultados obtenidos, se concluye que el sistema por SL es mejor que el sistema TOF para este cometido. Cabe destacar el error proporcional al ratio de superficie expuesta a la cámara dividida por el volumen encontrado al usar el sistema TOF y cuyo motivo se atribuye a irregularidades en la superficie. Además, al utilizar el sistema SL en algunos alimentos cuyos componentes principales son los lípidos se produjo una dispersión del láser, empeorando la precisión del sistema. Este problema se redujo debido a la robusta técnica de segmentación del láser utilizada en la imagen basada en el centro de masas y en un umbral dinámico. La posibilidad de disponer de una técnica capaz de proporcionar información 3D de alimentos resulta de gran interés para la industria alimentaria. En este estudio se demostró que la luz estructurada es una muy buena opción para ello.

Como resultado de este estudio se ha publicado el siguiente artículo en revista indexada (Verdú et al., 2013b).

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada

3.1.- Descripción del estudio

El estudio se realizó sobre patatas enteras (*Solanum tuberosum*) con diferentes tiempos de recogida y, por lo tanto, en diferentes estados. Las muestras también eran diferentes en formas y tamaños (desde 100 a 250 cm³) tal y como se puede observar en la figura 3.8. Las muestras

fueron escaneadas 3 veces cada una. El objetivo del estudio fue detectar y cuantificar las raíces de las patatas.



Figura 3.8 Muestras de patatas sobre las que se realizó el estudio.

3.2.- Sistema tridimensional por luz estructurada

Para este estudio se utilizó una cámara Cognex 3D Laser Profiler DS1000 (Cognex, Natick, EEUU) montada sobre un plataforma móvil. El láser de la cámara DS 1000 es de la clase 3R por lo que se necesitaron gafas de protección para los operarios cercanos al láser. Las muestras se escanearon a una distancia de 34.5 cm con una resolución de 4000x3000 píxeles. La geometría 3D completa se consiguió con el movimiento lineal de la plataforma sobre la que se encontraba la muestra tal y como se puede ver en la figura 3.9. La plataforma y la cámara estaban sincronizadas para obtener una resolución uniforme en el eje de movimiento de la plataforma.

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada

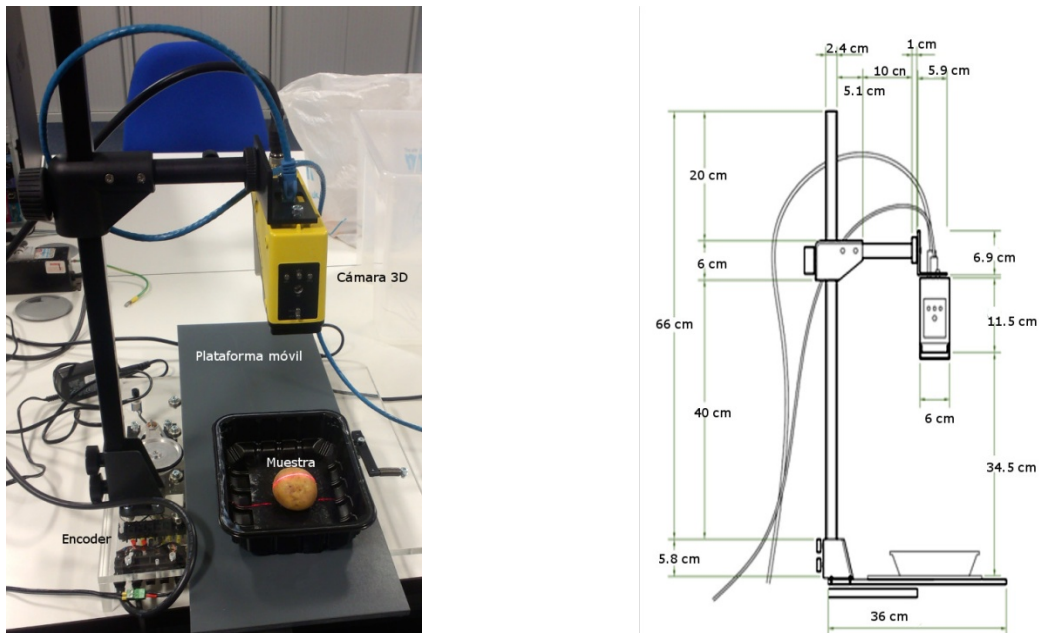



Figura 3.9 Sistema tridimensional por luz estructurada empleado.

El ordenador utilizado fue un ordenador con procesador de 4 núcleos QuadCore Q6600 de Intel a 2.4Ghz y una tarjeta gráfica Nvidia 8600GT.

3.3.- Procesamiento de la información tridimensional

El procesamiento de la información tridimensional adquirida por el sistema se realizó conforme pone en el esquema 3.1.



Esquema 3.1 Esquema del procesamiento de la información tridimensional

El sistema tridimensional por luz estructurada devuelve una nube de puntos con mucha resolución (más de 2 millones de punto por nube). La resolución de las nubes de puntos se calculó sumando la distancia de cada punto a su punto más cercano y dividiendo entre el número de puntos para así saber la distancia media entre puntos. Se decidió trabajar en dos resoluciones distintas y comparar sus resultados. Cada nube se redujo a una resolución alta de 12 (entre 15000 y 20000 puntos) y a una resolución baja de 30 (entre 1.000 y 3.000 puntos). Para la reducción de puntos se empleó el método basado en “voxel grids” que consiste en dividir el espacio 3D en cubos y quedarse los centroides de cada cubo.

El filtrado se realizó utilizando tres técnicas diferentes en el siguiente orden:

- Filtrado por distancia: Se calculó el centroide de la nube y se eliminaron todos los puntos cuya distancia al centroide fuera superior al doble de la distancia media al centroide. Este proceso se realizó 3 veces de forma iterativa para quitar los puntos alejados de la nube y no eliminar puntos de la muestra.
- Filtrado estadístico: Se calculó la distancia media de cada punto a sus puntos cercanos y utilizando una distribución gaussiana con una desviación estándar se eliminaron los puntos que se encontraban fuera del intervalo.
- Filtrado esférico: Consistió en eliminar los puntos que no tenían al menos 5 puntos dentro de una esfera de radio la distancia media y centro el punto a analizar.

La figura 3.10b es un ejemplo de los resultados obtenidos al reducir el número de puntos y al realizar el proceso de filtrado partiendo de la nube de puntos adquirida por el sistema (figura 3.10a).

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada




Figura 3.10 a) Nube de puntos adquirida por la cámara DS1000 para una muestra de patata b) Nube de puntos con reducción de puntos y filtrada

Tras la reducción de puntos y el filtrado, se realizó una segmentación manual de las raíces en las nubes de puntos para las patatas. Esto se realizó por dos motivos, para entrenar el modelo de clasificación y para poder cuantificar los resultados del mismo.

La base de datos de puntos tridimensionales fue de 158472 puntos para las nubes de alta resolución y de 19750 puntos para las nubes de baja resolución. De estos puntos, 1713 y 233 fueron etiquetados como puntos de raíz en las nubes de alta y de baja resolución respectivamente.

Una vez se hubieron etiquetado los puntos como superficie o raíz, se calcularon las características tridimensionales de cada punto. Para cada punto se calculó un vector de características de 102 valores que estaba compuesto por los siguientes parámetros:

- 3 histogramas FPFH a 3 radios diferentes con 33 valores cada uno dando un total de 99 datos geométricos.
- La curvatura de la superficie.
- La distancia Euclídea y de Mahalanobis del punto al centroide de la nube.

El FPFH es una mejora en el rendimiento de la PFH reduciendo la complejidad a $O(n \cdot k)$ donde n es el número de puntos y k el número de puntos vecinos a cambio de reducir poder descriptivo en zonas con un alto nivel de detalle (R.B. Rusu, Blodow, & Beetz, 2009). El radio utilizado para el cálculo de este descriptor fue múltiplo de la resolución de la nube. Concretamente, para las nubes de alta resolución se utilizaran los múltiplos [3 8 12] y para las nubes de baja resolución [2 4 6]. Estos valores se obtuvieron de forma empírica probando diferentes combinaciones y estudiando los vectores de características.

La característica de superficie de curvatura local se estimó utilizando los valores propios de la matriz de covarianza de los k puntos vecinos cercanos al punto analizado siguiendo la ecuación 3.8.

$$\sigma = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2} \quad (3.8)$$

Se utilizaron también la distancia Euclídea al cuadrado y la distancia de Mahalanobis al centroide de la nube. La distancia euclídea es el cuadrado de la distancia que separa dos puntos x e y . El factor al cuadrado incrementa el peso de los objetos más alejados. La ecuación que se utilizó fue:

$$\|\vec{x}\vec{y}\|_2 = \sum_{i=1}^n (x_i - y_i)^2 \quad (3.9)$$

La distancia de Mahalanobis se puede definir como la medida de la desigualdad entre dos vectores \vec{x} e \vec{y} basándose en su matriz de covarianza S . La ecuación que se utilizó para calcularla es:

$$m(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T S^{-1} (\vec{x} - \vec{y})} \quad (3.10)$$

Para la clasificación se va a utilizar el algoritmo Adaboost debido al gran número de características empleadas y al elevado número de puntos a clasificar. AdaBoost crea un clasificador fuerte mediante la unión de clasificadores débiles. Estos clasificadores débiles se

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada

crean en cascada, priorizando la clasificación de las muestras que han sido clasificadas erróneamente antes y encontrando las mejores características que incrementan el número de muestras clasificadas correctamente. En este estudio se utilizó la versión de (Barnes, Duckett, Cielniak, Stroud, & Harper, 2010a) que está basado en el algoritmo Real Adaboost propuesto por (Schapire & Singer, 1999). Sus principales ventajas son su bajo coste computacional y la selección de características que realiza.

Para tener la mayor base de datos posible, y debido a la gran diversidad morfológica que presentan las muestras, se utilizaron un 80% de puntos para el entrenamiento y un 20% para la predicción. Esto se repitió 5 veces seleccionando cada vez un 20% distinto para la predicción. El resultado final se calculó como la media de estas 5 iteraciones.

Los resultados que podía dar el modelo AdaBoost para cada punto eran 3: punto clasificado como raíz, punto clasificado como superficie y punto no clasificado. Cuando un punto no se clasificaba significaba que ninguno de los clasificadores fuertes dio un valor de certeza lo suficientemente alto para que fuera clasificado como raíz o superficie.

Los resultados del modelo AdaBoost se refinaron mediante un post-procesado. Este post-procesado se basó en que los puntos no clasificados por el algoritmo se clasificaran con la clase del punto clasificado más cercano a ellos, además también se filtraron los puntos aislados que salen rodeados de puntos con otra clasificación evitando que existieran puntos clasificados como superficie en clústeres de puntos de raíz. Esto se realizó para cada punto calculando los 9 puntos más cercanos y cuando el 60% de puntos era diferente al punto analizado, éste cambiaba de clase.

El procesamiento se realizó usando el entorno de programación Microsoft Visual Studio 2010 en el lenguaje de programación C++ utilizando las librerías 3D PointCloud (Radu Bogdan Rusu & Cousins, 2011). El modelo AdaBoost usado fue el implementado por (Barnes et al.,

2010a) que hace uso del procesamiento en paralelo de la tarjeta gráfica mediante la librería CUDA de Nvidia.

3.4.- Resultados

Los resultados se dividieron en 4 apartados:

- Clasificación de nubes de alta resolución utilizando de base de datos nubes de alta resolución.
- Clasificación de nubes de baja resolución utilizando de base de datos nubes de baja resolución.
- Clasificación de nubes de baja resolución utilizando de base de datos nubes de alta resolución.
- Clasificación con nubes de alta resolución y con post-procesado.

Para la clasificación de los puntos se fueron aumentando progresivamente los valores del clasificador:

- L: Número de iteraciones del clasificador para calcular los clasificadores débiles.
- M: Número de características utilizadas para calcular cada clasificador débil.
- N: Profundidad del árbol de decisión de cada clasificador débil.

Estos valores se aumentaron progresivamente para estudiar su efecto en los resultados y en el tiempo de clasificado de cada patata con el objetivo de llegar a un compromiso entre tiempo y eficacia. El tiempo de clasificado aumentó de forma directamente proporcional con el aumento de los valores del clasificador. De forma similar, el % de puntos no clasificados decreció con el aumento del tiempo y, por tanto, con la complejidad del modelo de clasificación como se puede ver en la gráfica de la figura 3.11.

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada




Figura 3.11 Número de puntos medio no clasificados de nubes de alta resolución para diferentes valores del clasificador.

Los resultados que se obtuvieron se resumen en la tabla 3.3. Los resultados se calcularon como la media de los valores de porcentaje de acierto (puntos de raíz y puntos de superficie bien clasificados divididos por el número total de puntos) obtenidos de las 5 iteraciones del modelo.

Se probaron valores de $L=[5,10,15,20,30]$, $M=[2,4,8,16]$, $N=[4,8,16,32]$ y todas sus combinaciones para los modelos Adaboost. Los resultados indicaron que los valores intermedios ($L=10$, $M=4$, $N=8$) son los adecuados como una medida de compromiso entre tiempo y resultados pero, que en caso de no ser importante el tiempo, es posible mejorar los resultados incrementando los valores de los parámetros ($L=30$, $M=16$, $N=32$).

Tabla 3.3 Resultados de los diferentes modelos Adaboost realizados para las nubes de puntos de patatas

Datos para entrenar	Datos para clasificar	L	M	N	% aciertos	tiempo medio (s)
Alta resolución	Alta resolución	5	2	4	81,67	3,165
		10	4	8	88,54	14,090
		30	16	32	94,11	266,168

Capítulo 3: Aportaciones de las técnicas 3D

Baja resolución	Baja resolución	5	2	4	59,32	0,401
		10	4	8	76,75	1,713
		30	16	32	86,56	30,445
Alta resolución	Baja resolución	5	2	4	47,58	0,494
		10	4	8	56,24	1,812
		30	16	32	56,21	32,965
Alta resolución	Alta resolución con post-procesado	5	2	4	88,14	5,0733
		10	4	8	90,51	15,971
		30	16	32	93,49	267,677

Los resultados al trabajar con nubes de baja resolución disminuyeron de forma significativa, especialmente para algunas de sus muestras. Esto se debe a que existían casos de puntos etiquetados como raíces (en las nubes de alta resolución) que desaparecieron en las nubes de baja resolución debido al pequeño tamaño de las raíces.

Los resultados bajaron mucho al utilizar modelos construidos a partir de nubes de alta resolución y al usar nubes de baja resolución para testarlos. De esto se puede concluir que es importante utilizar muestras con la misma resolución debido a que las características 3D utilizadas no son invariantes a cambios de resolución.

Los resultados cualitativos se puede observar en la figura 3.12b al compararlo con la imagen real de la figura 3.12a. La figura mostrada corresponde a la muestra 2 con nube de puntos de alta resolución y valores bajos del clasificador (por eso hay tantos puntos sin clasificar). Cuando se realizó el post-procesado (figura 3.12c) los resultados mejoraron notablemente. Concretamente, los resultados mejoraron en el caso de utilizar valores mínimos un 7% y en el caso intermedio un 2%. Gracias al post-procesado se obtuvo un clasificador más eficaz para los modelos con parámetros bajos e intermedios. Cabe recalcar que utilizando los valores mínimos y utilizando el post-procesado se consiguieron resultados parecidos al modelo con valores intermedios sin post-procesado con la ventaja de ser mucho más rápido (5s contra 14s).

3.- Caso práctico: Detección de raíces en tubérculos mediante una técnica tridimensional por luz estructurada

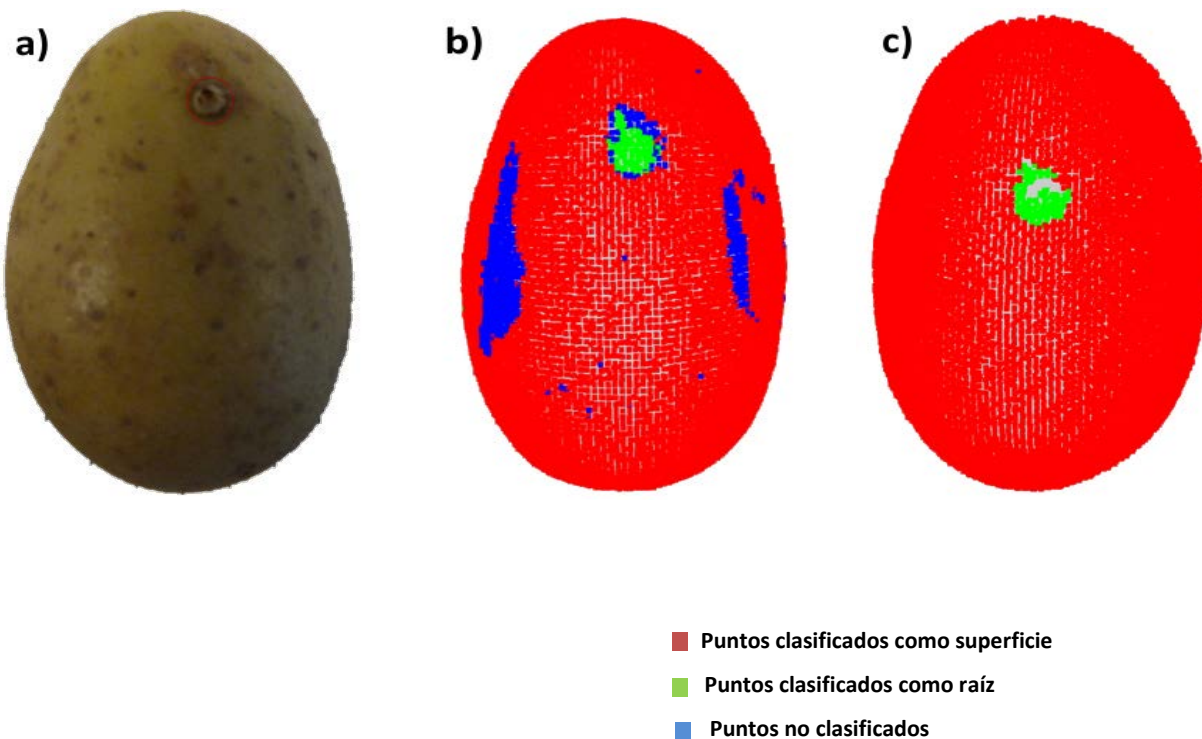


Figura 3.12 a) Fotografía patata con la raíz señalada con un círculo rojo, b) resultado clasificación nube alta resolución valores bajos del clasificador, c) resultado clasificación nube alta resolución valores bajos del clasificador con post-procesado.

3.5.- Conclusiones

Se demostró que la técnica tridimensional por SL es capaz de detectar raíces de una forma rápida y precisa. Se utilizaron características 3D basadas en FPFH, distancias al centroide y la curvatura de la superficie para caracterizar los puntos que fueron clasificados por modelos Adaboost. El post-proceso diseñado aplicado a los resultados del clasificador permite modelos Adaboost más simples con resultados equivalentes a modelos más complejos. Las pruebas realizadas con diferentes resoluciones demostraron que es necesario utilizar nubes de puntos de resoluciones parecidas para entrenar el modelo y para usarlo posteriormente. La configuración idónea para la aplicación basada en los resultados fue un modelo Adaboost con parámetros (L=5, M=2, N=4) y post-procesado usando datos de alta resolución. Con esta

configuración se consiguió un porcentaje medio de acierto de 88.14% con 5 segundos de procesamiento. Aunque los resultados fueron muy prometedores a nivel de laboratorio, se necesitan realizar optimizaciones para su utilización en líneas de producción. Dos posibles soluciones para reducir el tiempo de forma notablemente serían: calcular únicamente las características 3D empleadas por el modelo y realizar el cálculo de estas características 3D en paralelo en la tarjeta gráfica.

3.6.- Aportaciones del estudio

En este estudio se utilizó un sistema tridimensional por luz estructurada comercial para la segmentación de raíces de patatas. Las raíces son complicadas de segmentar por visión de computador 2D debido a que tienen colores similares a los de la patata por lo que el uso del 3D facilita mucho la tarea. Basándose en los resultados obtenidos, se concluye que el sistema por SL es muy prometedor para esta aplicación debido a los buenos resultados obtenidos. Cabe destacar que se trató de un estudio inicial realizado sin control de iluminación que requirió un filtrado más exigente de los datos. El algoritmo desarrollado clasifica los puntos tridimensionales con gran eficacia llegando los resultados a ser de hasta el 94% de acierto. Además, se demostró el buen funcionamiento que se obtiene con la utilización del clasificador Adaboost con características 3D. Este estudio supone otro claro ejemplo del gran potencial que tienen las técnicas 3D, especialmente las de SL, para la solución de problemas difíciles de resolver por otros medios en el sector alimentario.

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

4.1.- Descripción del estudio

El estudio se realizó en 100 racimos de uva de diferentes morfologías. Las muestras fueron de 10 variedades de uva de vino (*Vitis vinífera L.*): Miguel de Arco, Monastrell, Bobal, Cabernet Franc, Planta Mula, Ruby_Seedless, Mouraton, Naparo ,Moravia Agria and Moscatel Morisco. Solo se utilizaron racimos principales de acuerdo al descriptor OIV N°206 (OIV, 2007). Cada muestra se capturó 4 veces por la cámara de estéreo visión rotando el racimo $\pi/2$ radianes usando como eje su pedúnculo. Todas las muestras fueron recolectadas por expertos el mismo día de un viñedo de Logroño (España).

Los componentes de calidad y productividad fueron medidos destructivamente a mano por expertos de Logroño. La compacidad fue medida usando el descriptor de la OIV N°204 (OIV, 2007) por un panel formado por 14 expertos con el objetivo de minimizar el problema de la subjetividad. Este descriptor clasifica los racimos en 5 grupos, numerados 1, 3, 5, 7 y 9 donde 1 indica bayas agrupadas con muchos pedúnculos visibles y 9 indica bayas deformadas por la presión.

Independientemente de la compacidad, cada racimo fue descrito morfológicamente usando descriptores cuantitativos y objetivos. Concretamente, el peso de cada racimo se midió con una balanza (Blauscal, AC-5000), y el volumen fue medido mediante la técnica de desplazamiento de agua por inmersión en un recipiente lleno de agua. Se contó el número de bayas desgranando los racimos a mano. Se escogieron 15 bayas aleatoriamente para medir su tamaño usando calibres digitales (Mitutoyo, CD-15DCX). El tamaño medio se calculó realizando la media de las 15 bayas.

4.2.- Sistema tridimensional por visión estéreo

Las imágenes se adquirieron usando la cámara estéreo Bumblebee2 (Point Grey Research Inc, Richmond, BC, Canadá) modelo BB2-08S2C-25 configurada en modo automático (balance de blancos, ganancia y tiempo de integración). Las imágenes están sincronizadas y tienen una resolución de 1024x768 píxeles a color con valores de 0 a 255 por canal.

La adquisición fue realizada en condiciones de laboratorio pero la configuración realizada se diseñó para simular las condiciones de campo. La muestra se fijó por su pedúnculo, como si estuviera colgando de la viña (Figura 3.13).




Figure 3.13 Configuración de adquisición del sistema tridimensional de visión estéreo

Los sistemas de iluminación empleados fueron cuatro pares de tubos fluorescentes (Osram L 18W/965 BIOLUX) con un color de temperatura de 6500k. Estos estaban distribuidos y orientados a diferentes ángulos, lo que produjo reflejos en las muestras (Figura 3.14). La distancia entre las luces y las muestras fue de alrededor de 0,35m. Se decidió no variar la intensidad de luz porque afectaría menos que el cambio ya existente entre los colores de las diferentes muestras. La cámara se podía poner entre 0,10 y 0,25 m de la muestra. En esta configuración se decidió usar la máxima distancia para trabajar con la mínima resolución de la

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

proyección de la muestra (alrededor de 170 x 250 píxeles). Como resultado, se trabajó en unas condiciones difíciles para el posterior procesamiento de imagen. Se necesitó un fondo controlado para el cálculo de uno de los descriptores 3D propuesto para medir la compacidad.




Figura 3.14 Imágenes capturadas a baja resolución y con reflejos (muestra 6 de variedad Bobal)

La adquisición de imagen se realizó con el programa PGR FlyCapture v.122 (Point Grey Research Inc, Richmond, BC, Canadá).

4.3.- Reconstrucción 3D de los racimos de uva usando visión estereoscópica

La aproximación propuesta está pensada para ser usada con un sistema de inspección formado por dos cámaras puestas en configuración paralela. El sistema proporciona dos imágenes del racimo de uva, una de cada cámara. Estas imágenes, junto a la calibración conocida de las cámaras, son entonces usadas de forma automática para obtener una

reconstrucción parcial en 3D del racimo de uva, que puede ser completada y refinada manualmente por un usuario.

Desafortunadamente, esta aproximación tiene algunas dificultades inherentes. Primero, algunas de las bayas de las capas internas del racimo están total o parcialmente escondidas detrás de otras bayas. Este hecho impide la reconstrucción de aquellas bayas que están completamente ocultas. Sin embargo, los descriptores 3D propuestos aún pueden ser extraídos de las bayas reconstruidas. Esto también significa que las bayas parcialmente ocultas serán más difíciles de generar debido a la falta de información. Además, para que sea factible la resolución del problema, las bayas de uva fueron modeladas matemáticamente como esferas perfectas. Existen casos en que éstas pueden estar muy deformadas, siendo más ovoides que esféricas, lo que añade una dificultad añadida en estos casos extremos.

Para resolver estas dificultades se han usado diferentes técnicas de visión por computador. Estas incluyen: i) la implementación 3D de la transformada de Hough (Woodford, Pham, Maki, Perbet, & Stenger, 2014), ii) la detección de características y iii) la correspondencia entre características. Además, la aproximación presentada aquí incluye la constante utilización de la proyección directa e inversa usando el modelo de cámara “pin-hole” en varias etapas del proceso automático.

Se ha desarrollado una nueva herramienta 3D en C++ en el entorno de Microsoft Visual Studio 2010 Professional con interfaz Qt 4.8.0. El procesamiento de imagen se realizó usando la librería openCV 2.3.1. Esta herramienta 3D de reconstrucción tiene un claro flujo de control que incorpora el procesamiento automático y un refinamiento manual. En la parte automática, la herramienta genera tantas bayas correctas como es posible sin la supervisión del usuario. La efectividad de este método depende mucho del caso, ya que algunas variedades resultan más sencillas de reconstruir que otras, dependiendo principalmente de cómo de grandes son las dificultades descritas anteriormente.

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

4.3.1.- Aproximación automática

Esta aproximación genera automáticamente un modelo 3D parcial del racimo de uvas sin ayuda del usuario. Para realizar esta tarea, se resolvieron los siguientes problemas.

Primero, las imágenes originales se rectificaron para cumplir con la configuración paralela de la cámara, donde la línea base ($b= 0.1197$ m) se alineó con los ejes X y por lo tanto las restricciones de la geometría epipolar se pudieron aplicar fácilmente para resolver el problema de correspondencias. En este caso, solo se utilizaron características verticales ya que los ejes horizontales pertenecen a la misma línea epipolar y esto incrementa el riesgo de obtener correspondencias erróneas.

Las características basadas en bordes son muy adecuadas para escenarios con un alto grado de variabilidad de color o iluminación. En este caso, los bordes verticales se extrajeron de las imágenes rectificadas y para cada borde vertical se estimó un vector de descriptores. Este vector consistió en el módulo del gradiente (m_i), los senos (s_i) y los cosenos (c_i) de la orientación del gradiente. El rango de distancias entre la cámara y la muestra permitió alcanzar una precisión en la reconstrucción menor a 1 mm en los bordes ocultos. Por lo tanto, los bordes ocultos de las bayas pudieron ser usados para el problema de reconstrucción del racimo obteniendo errores pequeños.

Para medir la similitud entre características de las imágenes izquierdas y de las imágenes derechas se utilizó la distancia Euclídea entre los vectores normalizados de los descriptores [m_i , s_i , c_i]. La correspondencia entre características es un problema de optimización donde las características en una fila de la imagen izquierda tienen que coincidir con las características en la misma fila de la imagen derecha. Este problema de correspondencia se resolvió usando programación dinámica, donde se explora un árbol de posibles soluciones. Cada nodo de este árbol contiene dos índices de columnas (uno por cada imagen), una lista de parejas que encajan

y el coste de correspondencia. Los dos índices apuntan a las características que el algoritmo intenta corresponder en este nodo (Figura 3.15).

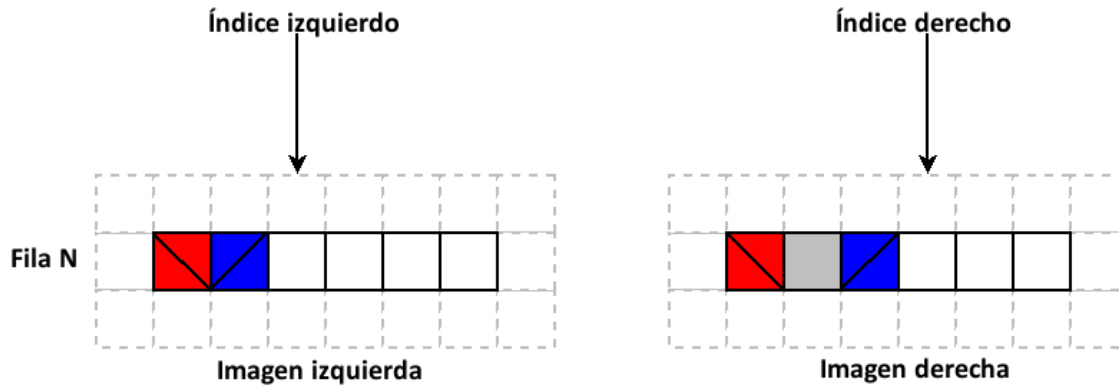


Figura 3.15. Ejemplo de un nodo, donde las características que coinciden son del mismo color. El color gris representa una característica oculta.

Cada nodo genera 3 nuevas ramas. La primera rama considera el caso de que la característica de la imagen izquierda estuviera oculta y por lo tanto no correspondiera con ninguna de la imagen derecha. En este caso, el nodo hijo incrementa su índice izquierdo y añade una constante al coste de correspondencia. La segunda rama considera el caso de que la característica en la imagen izquierda encaja con la de la de la imagen derecha. En este caso el nodo incrementa los dos índices (izquierda y derecha), añade la pareja de índices que encajan y añade el coste de correspondencia. Y finalmente, la tercera rama considera el caso de que la característica de la imagen derecha esté oculta y no encaje con ninguna de la imagen izquierda. En este último caso, el nodo incrementa su índice derecho y añade una constante al coste de correspondencia.

El algoritmo expande el árbol y encuentra la solución óptima, que es el nodo hoja con el mínimo coste que contiene la lista de pares de características que han encajado. Para cada par de bordes verticales que han encajado se reconstruye un punto 3D por triangularización. Además, se pudieron reconstruir otras características distintas a los bordes verticales. Por

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

ejemplo, los puntos entre las bayas tienen unos colores oscuros en ambas imágenes. Se realizó una transformada de Hough adaptada para detectar esferas en un espacio de dimensiones de 4 parámetros (x_c, y_c, z_c, r) . Se utilizaron los puntos 3D reconstruidos usando los bordes verticales como entrada para la transformada de Hough. Tras la fase de acumulación, se estableció un mínimo número de votos para detectar las esferas. Se realizó un paso de refinamiento para detectar y eliminar algunas esferas erróneas, tales como esferas que colisionan entre sí o esferas que engloban puntos 3D de los reconstruidos como puntos entre bayas. Cabe recalcar que la transformada de Hough es una técnica robusta ante ruidos tales como los reflejos.

4.3.2.- Refinamiento manual

En la fase de refinamiento manual, el usuario podía reconstruir bayas adicionales usando una herramienta de reconstrucción 3D implementada. Esto se podía realizar por dos métodos. El primero requería que el usuario introdujese las coordenadas 3D y el radio de la baya. Mientras que este método es directo y funcional, es poco intuitivo y lento. Por ese motivo, se diseñó y desarrolló un método alternativo más visual. En este caso, para reconstruir una baya el usuario solo necesita especificar 5 puntos en el borde de una baya en una de las imágenes originales y el centro en la otra imagen. Con esta información, la herramienta genera la baya 3D automáticamente, sin necesidad de ninguna otra interacción con el usuario. Esto permite a un usuario reconstruir bayas de una forma sencilla introduciendo solo 6 puntos de una forma totalmente visual, intuitiva y rápida. Además, la herramienta ayuda al usuario en este proceso mediante ayudas visuales en forma de previsualizaciones del resultado final en las imágenes originales así como con restricciones en los ejes cuando era posible. Usando este método un usuario no tiene que ser un experto en la herramienta debido a lo sencillo, fácil y directo que es el método.

Capítulo 3: Aportaciones de las técnicas 3D

Uno de los objetivos de este trabajo fue desarrollar una herramienta de reconstrucción 3D tan intuitiva como fuera posible. Por lo tanto, esta herramienta tiene una interfaz gráfica que permite al usuario visualizar el modelo e interactuar con él. Esta interfaz se puede ver en la figura 3.16 dividida en dos partes principales: la parte 2D (recuadro rojo) y la parte 3D (recuadro azul).

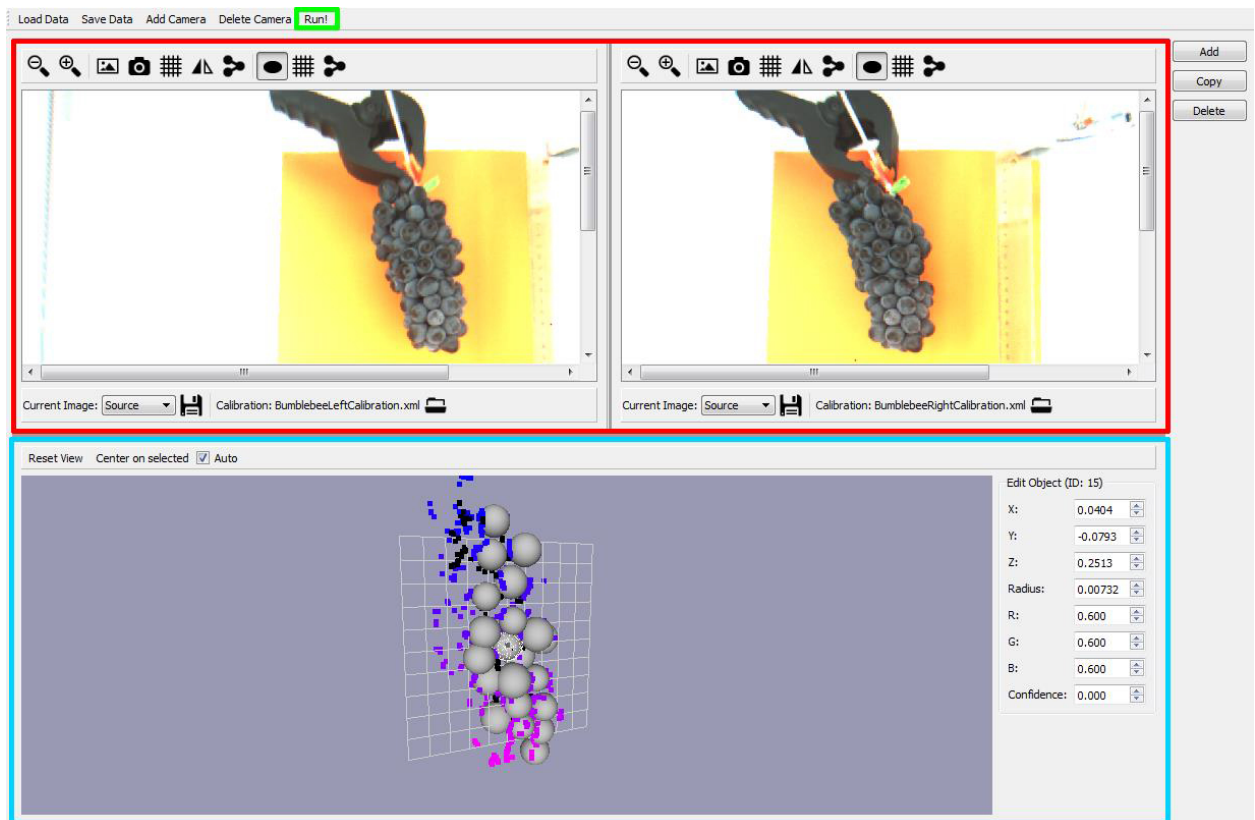


Figura 3.16 Interfaz de la herramienta de reconstrucción 3D. La parte 2D se encuentra marcada en rojo y la parte 3D en azul.

Por un lado, está la parte 2D, donde se encuentra toda la información relacionada con el espacio 2D tal como las imágenes originales de la uva. Como se ha mencionado previamente, el proceso de reconstrucción requiere dos imágenes por lo cual existen dos recuadros con las imágenes originales, uno para cada cámara. Estos recuadros pueden ser usados en la herramienta de introducir 6 puntos en la fase manual para reconstruir bayas.

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

Las imágenes 2D mostradas aportan información muy útil como la proyección del modelo 3D sobre estas imágenes. De esta forma, el usuario puede comprobar fácilmente si el modelo encaja de forma correcta sobre las imágenes originales y corregirlo en caso necesario.

Por otro lado, la parte 3D muestra el modelo tridimensional del racimo de uva. El usuario puede seleccionar en este modelo bayas individuales y editar sus parámetros además de poder navegar libremente en el espacio 3D para poder visionar el modelo desde cualquier punto de vista. El modelo 3D se actualiza inmediatamente con la información añadida para reflejar el estado actual del modelo. Esto quiere decir que cuando el usuario realiza un cambio de cualquiera de las formas explicadas, el modelo se actualiza en consecuencia. Lo mismo ocurre cuando se ejecuta la fase automática, en el momento en que acaba la ejecución, el modelo se actualiza con los resultados.

Finalmente, el modelo reconstruido puede salvarse en un formato abierto y legible, de forma que los modelos puedan ser usados fácilmente por otras aplicaciones para ser mostrados o para modificarlos.

4.4.- Descriptores 3D y modelos

Existen muchos descriptores morfológicos para la caracterización de racimos de uva que pueden ser medidos manualmente. Sin embargo, con el modelo 3D del racimo, se pueden calcular descriptores 3D automáticamente (tabla 3.4). En este trabajo, 6 descriptores 3D se calcularon a partir de los modelos 3D: volumen del racimo, tamaño de la baya, número de bayas, medida de la concavidad, intersección entre bayas y número de bayas por área. Los últimos descriptores 3D son nuevos descriptores propuestos en este trabajo para establecer una medida de compacidad que no puede ser medida a mano.

Capítulo 3: Aportaciones de las técnicas 3D

Para calcular la medida de la concavidad (agujeros entre bayas) se realizó una segmentación de imagen. Esta segmentación consta de dos pasos: primero se establece un área de interés (ROI) y segundo, una clasificación de los píxeles en tres clases: fondo, agujero y baya.

Tabla 3.4 Descriptores morfológicos y 3D

Descriptores	Morfológicos (Medidos a mano)	3D (Medidas automáticas)	Unidades
Longitud del racimo	No destructivo	No destructivo	$m \cdot 10^{-2}$
Ancho del racimo	No destructivo	No destructivo	$m \cdot 10^{-2}$
Volumen del racimo	No destructivo	No destructivo	$m^3 \cdot 10^{-3}$
Peso del racimo	No destructivo	Estimado	$kg \cdot 10^{-3}$
Tamaño del grano	No destructivo	No destructivo	$m^3 \cdot 10^{-6}$
Número de bayas	Destructivo	Estimado	
Semillas por grano	Destructivo	Oculto	
Longitud pedúnculo	Destructivo	Oculto	$m \cdot 10^{-2}$
Peso del raquis	Destructivo	Oculto	$kg \cdot 10^{-3}$
Longitudes de las ramificaciones del raquis (1 a 7)	Destructivo	Oculto	$m \cdot 10^{-2}$
Ramificaciones del raquis	Destructivo	Oculto	
Medida de la concavidad	Imposible	No destructivo	
Intersección entre bayas	Imposible	No destructivo	$m^3 \cdot 10^{-6}$
Número de bayas por área	Imposible	No destructivo	

El primer paso consistió en definir un área de interés. Esto se calculó como la diferencia entre el área convexa que engloba el racimo y las bayas del modelo 3D. Esta diferencia estima las concavidades potenciales que puede tener el racimo. Estas posibles concavidades se calcularon usando las imágenes 2D resultantes de la proyección del modelo 3D. Concretamente, para calcular el área convexa del racimo, se utilizó una triangularización de Delanuy usando los centros proyectados en las imágenes 2D de las esferas del modelo. A partir de los triángulos formados se definió un área convexa que los incluyera. Sin embargo,

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

hubo que eliminar algunos triángulos de esta área convexa para asegurar un mejor ajuste a la forma del racimo. Se eliminaron principalmente triángulos que incluyeran concavidades muy grandes. Estos triángulos eliminados tenían al menos un vértice dentro del área convexa y su lado más largo era por lo menos el triple de largo que su altura. Los píxeles dentro de esta área convexa refinada se utilizaron como primera región. La segunda región fue el resultado de unir las elipses resultantes de la proyección del modelo 3D. Finalmente, el área de interés quedó definida como la diferencia entre la primera y la segunda región.

La figura 3.17 muestra un ejemplo de este paso en la muestra Bobal 1. Las bayas proyectadas están mostradas en verde, la triangularización de Delanuy en azul, el área convexa en rojo y los triángulos eliminados en violeta. En la figura 3.18, los píxeles incluidos en el área de interés están coloreados en rojo.




Figura 3.17 Área convexa creada a partir de la triangularización de Delanuy



Figura 3.18 Región de interés definida para la clasificación de píxeles

El segundo paso fue la clasificación de los píxeles dentro del ROI en tres clases dependiendo de su color. Esta clasificación se realizó mediante un reconocimiento de patrones de k-vecinos-cercanos (Sánchez, Albarracín, Grau, Ricolfe, & Barat, 2008a). Se seleccionaron automáticamente 5 colores de baya diferentes para cada par de imágenes usando una agrupación k-means de los píxeles dentro de las elipses proyectadas a partir del modelo 3D. Se entrenaron también 5 colores del fondo. Luego, para cada píxel dentro de la región de interés se calculó la diferencia a estos colores. Si la mínima diferencia fue con un color de grano y esta diferencia era positiva (el color del píxel era más intenso que el del modelo) entonces el píxel se clasificaba como píxel de grano. En caso de que fuera negativa, el píxel se clasificaba como agujero y la diferencia se utilizaba como una medida aproximada de la profundidad del agujero.

Se acumuló el valor de profundidad de todos los píxeles clasificados como agujero, además se sumó 255 por cada píxel de fondo. La media de las dos imágenes fue calculada para cada muestra. Este valor se llamó medida de concavidad y es el único descriptor 3D que requiere de un fondo controlado.

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

La intersección entre esferas se aproximó usando la ecuación 3.11 donde c es el centro de la esfera, r es su radio y n es el número total de bayas en el modelo 3D.

$$d = \begin{cases} \|\|c_1 - c_2\| - r_1 - r_2\|, & \text{if } \|\|c_1 - c_2\| - r_1 - r_2\| < 0 \\ 0, & \text{if } \|\|c_1 - c_2\| - r_1 - r_2\| \geq 0 \end{cases}$$
$$I = d * d * \min(r_1, r_2) \quad (3.11)$$

$$Im = \frac{1}{n} * \sum_{i=1}^n I_i$$

El número de bayas por área se aproximó como el área de ROI dividido por el número de bayas. Este valor se calculó como la media de los valores de las dos imágenes.

El volumen del racimo se calculó usando la información del modelo 3D mediante la ecuación 3.12.

$$V = \sum_{i=1}^n \frac{4 * \pi * r_i^3}{3} \quad (3.12)$$

Otro valor calculado a partir del modelo 3D fue el tamaño de baya. Para ello se utilizó la ecuación 3.13 que calcula el volumen medio de todas las bayas del modelo.

$$V_m = \frac{1}{n} * V \quad (3.13)$$

El número de bayas fue el número de bayas reconstruidas en el modelo 3D para cada muestra.

Los cálculos de los descriptores 3D se realizaron usando código propio desarrollado en Matlab R2008a (The Mathworks, Natick, Massachusetts, USA).

4.5.- Resultados

La eficiencia de la herramienta de reconstrucción 3D se probó generando el modelo 3D de 100 racimos de uva de diferentes variedades. Todos los modelos se generaron satisfactoriamente usando una combinación de la fase automática y manual (figura 3.19). El proceso de obtener un modelo casi exacto de la parte visible del racimo nunca costó más de 10 minutos, siendo este tiempo dependiente de la complejidad del racimo.




Figura 3.19 Modelo 3D de un racimo de uva refinado a mano

Aplicando solo la fase automática de la reconstrucción, el porcentaje medio de bayas reconstruidas correctamente fue del 20% (aproximadamente 10 bayas) por vista (figura 3.20). El peor porcentaje de reconstrucción automática fue en la variedad “Tempranillo” con un 10%. El resto de variedades dieron mejores resultados, siendo la mejor “Bobal” con un 27.78%.

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión




Figura 3.20 Bayas reconstruidas usando la transformada de Hough. Los puntos de color son puntos 3D calculados de los bordes verticales. Los puntos negros representan los puntos entre bayas.

Utilizando la herramienta desarrollada, se comprobó la precisión de los modelos 3D proyectándolos en las imágenes originales del racimo. Se obtuvo una precisión de menos de 5 píxeles de error en las proyecciones (figura 3.21). Teniendo en cuenta las condiciones de adquisición (figura 3.13), se calculó que un error de proyección de menos de 5 píxeles da como resultado un error de reconstrucción menor a un 1mm. Las únicas bayas visibles que no se pudieron reconstruir fueron aquellas que: a) solo eran visibles en una imagen y estaban totalmente ocultas en la otra, haciendo imposible la reconstrucción 3D de las mismas; o b) no podían identificarse correctamente debido al ruido visual. Todas las otras bayas visibles se pudieron reconstruir con un error mínimo.




Figura 3.21 Comprobación del modelo 3D proyectándolo en las imágenes originales rectificadas.

En este punto, cabe recalcar las importantes ventajas que supone tener un modelo 3D de los racimos. La más importante es el hecho de que los descriptores 3D se pueden extraer de forma automática. Otras ventajas significativas son que el modelo se puede salvar y guardar de forma indefinida. Esta ventaja implica la posibilidad de crear registros de los modelos 3D de variedades de vino de diferentes años. Además, también existe la posibilidad de calcular nuevos descriptores 3D de modelos previamente analizados que no eran necesarios anteriormente. Esto no es posible realizarlo de forma manual debido a la naturaleza perecedera de las muestras.

4.5.1.- Resultados de los componentes de calidad del racimo

Se realizó un estudio estadístico Kendall Tau-b (Kendall, 1970) para correlar los nuevos descriptores 3D (medida de la concavidad, intersección entre bayas y número de bayas por área) con la compacidad medida visualmente por los expertos. Se correló también el descriptor CI-12 que los autores (Tello & Ibáñez, 2014) afirman que puede ser usado como medida de compacidad. Como se puede observar en la tabla 3.5, el resultado de CI-12 presentó una buena

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

correlación, confirmando los resultados de sus autores. La medida de la concavidad presentó el máximo coeficiente de correlación de Pearson mientras que el número de bayas por área fue el peor.

Tabla 3.5 Resultados del estudio Kendall tau para los descriptores de compacidad (** $p < 0.01$ * $p < 0.05$)

Descriptores de compacidad	Rho
CI-12: $\text{Peso}/\text{Longitud}^2$	0.530**
Medida de concavidad	-0.710**
Intersección entre bayas	0.569**
Número de bayas por área	-0.205*

En las figuras 3.22 y 3.23 se muestran los resultados de realizar la segmentación de imagen en dos muestras de Cabernet Franc con dos clases diferentes de compacidad 3 (poco compacto) y 7 (bastante compacto). La profundidad del agujero se codificó usando el color azul siendo más intenso el color a mayor profundidad. Como se puede observar existe mucho más fondo y píxeles de agujero en la figura 3.22 que en la 3.23. Esta información se recoge en el descriptor definido como medida de compacidad. Así pues, parece lógica la alta correlación obtenida en el estudio de Kendall Tau para este descriptor.




Figura 3.22 Segmentación de imagen de la muestra Cabernet Franc (clase de compacidad 3)




Figura 3.23 Segmentación de imagen de la muestra Cabernet Franc (clase de compacidad 7)

En la tabla 3.6 se muestran los resultados obtenidos de realizar un modelo de regresión de vectores de soporte (Schölkopf, Smola, Williamson, & Bartlett, 2000) (SVM) para predecir la compacidad basándose en estos tres descriptores 3D: medida de la compacidad, intersección entre bayas y número de bayas por área. Las muestras se dividieron pseudo-aleatoriamente 2/3 para construir el modelo y 1/3 para testarlo. Se ajustaron las muestras para que todas las variedades de uvas se encontraran tanto en las muestras de calibración como en las de predicción. La inclusión de los descriptores de intersección entre bayas y el número de bayas por área incrementó los resultados alrededor de un 10% en comparación con utilizar únicamente el descriptor de medida de la concavidad. A pesar de los pobres resultados en correlación directa obtenidos con el modelo Kendall Tau, la inclusión del descriptor número de bayas por área ayudó a modelar algunos casos extremos, lo que explica la mejora en los resultados al usarlo.

Cabe recalcar que se realizó un solo modelo para 10 variedades distintas de uvas, lo que aumentó la complejidad del problema. Los resultados de predicción fueron de $R^2_{Pred}=0.80$,

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

pero tal y como puede observarse en la figura 3.24, el máximo error cometido para las muestras de test fue de ± 2 . Esto significa que en el peor de los casos se clasificó como una clase superior o inferior de compacidad.




Figura 3.24 Resultados del modelo SVM para predecir la compacidad

Se realizó otro modelo SVM para predecir el componente de calidad de tamaño de baya. Los resultados (tabla 3.6) fueron buenos, con unos errores medios de calibración y predicción menores de 0.23 cm^3 y unos R^2 superiores a 0.82. El modelo generado fue muy robusto puesto que las muestras usadas para la predicción encajaron incluso mejor que aquellas usadas en la calibración ($\text{RMSEP} < \text{RMSEC}$). Es importante resaltar, que a diferencia de para predecir el descriptor de compacidad, para este descriptor 3D solo se utilizaron los datos obtenidos con la fase automática de reconstrucción y que no requiere un fondo controlado.

4.5.2.- Resultados de otros componentes de productividad del racimo

Se generaron también 3 modelos SVM para estimar los siguientes descriptores morfológicos: volumen del racimo, peso total de las bayas y número de bayas. Estos modelos se realizaron utilizando la misma distribución de muestras de calibración y de predicción que las utilizadas en los modelos de componentes de calidad. Solo se utilizó un descriptor 3D para cada componente de productividad (el descriptor 3D que coincide en nombre con el componente de productividad a excepción del peso, que se utilizó el descriptor de volumen de racimo). Como se puede ver en la tabla 3.6, los resultados para el volumen de racimo y para el peso del racimo mostraron un coeficiente de predicción superior a 0.82. Para la estimación manual del volumen del racimo, se midió el racimo completo (incluyendo los pedúnculos y el raquis) mientras que usando el método basado en imagen, solo se utilizó la información de las bayas reconstruidas. Por ello, parece coherente que se obtuvieran mejores resultados estimando el peso de las bayas que para el volumen total del racimo. Los resultados fueron menores para el número de bayas (aproximadamente 24 bayas de error en predicción) probablemente porque muchas bayas estaban ocultas dentro del racimo (especialmente para aquellas muestras con mayor compacidad).

	Número de SV	RMSEC	RMSECV	RMSEP	R ² Cal	R ² CV	R ² Pred
Compacidad	20	0.920	1.139	0.817	0.886	0.826	0.808
Tamaño de baya	16	0.214	0.227	0.180	0.842	0.820	0.830
Volumen del racimo	36	28.204	46.945	56.798	0.944	0.845	0.822
Peso de las bayas	42	19.549	36.672	44.656	0.966	0.880	0.830
Número de bayas	23	13.307	23.821	23.791	0.947	0.826	0.714

Tabla 3.6 Resultados de los modelos SVM para estimar los componentes de las uvas

4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión

4.6.- Conclusiones

El estudio se centra en estimar componentes de productividad de la uva usando visión estéreo. Debido a la dificultad de hacer una correspondencia acertada entre el par de imágenes, se desarrolló una herramienta de reconstrucción 3D. Utilizando esta herramienta se reconstruyen los racimos con errores menores a 1 mm. Se ha demostrado que el sistema desarrollado cumple el objetivo de la reconstrucción satisfactoriamente además de cumplir con los estándares de usabilidad, velocidad y facilidad de manejo. De hecho, utilizando solo los modelos 3D obtenidos de la aproximación automática, la estimación del tamaño de baya con el modelo SVM alcanzó un R^2 superior a 0.82. Una vez que los modelos 3D fueron creados, se definieron 3 nuevos descriptores 3D para ayudar a medir la compacidad: medida de concavidades, intersección entre bayas y número de bayas por área. Estos descriptores se evaluaron y compararon con el actual índice CI-12 en 100 muestras diferentes de 10 variedades distintas. El descriptor que mide las concavidades dio una correlación de Kendall Tau de -0.71 mientras que el CI-12 dio una de 0.52 (ambos $p < 0.01$). Utilizando modelos SVM se obtuvo unos valores de predicción superiores al 0.8 para medir la compacidad, de 0.82 para el volumen del racimo, 0.83 para el peso total de las bayas y de 0.71 para el número de bayas.

Los resultados conseguidos muestran la capacidad de esta técnica para resolver el problema de tener una herramienta precisa y objetiva para medir la compacidad del racimo. Además, el hecho de que la estimación del tamaño de baya sea totalmente automática, hace que el uso de esta técnica sea posible en condiciones de campo. Esta técnica sería muy útil por ejemplo para determinar la compacidad en estudios de variedades o en estudios genéticos.

La adquisición de imagen se realizó en condiciones difíciles con el objetivo de simular el campo. El siguiente paso planeado es emplear la técnica desarrollada en el escenario real de campo.

4.7.- Aportaciones del estudio

En este estudio se utilizó de forma satisfactoria un sistema tridimensional basado en visión estéreo en el sector alimentario. Se demostró que en unas condiciones de adquisición difíciles el sistema es lo bastante robusto como para calcular automáticamente el tamaño medio de las bayas. Además, se desarrolló una herramienta informática que permite la reconstrucción 3D de racimos de uva por usuarios no expertos de una forma rápida e intuitiva.

Una de las grandes aportaciones de este estudio es la definición de 3 nuevos descriptores 3D que solo pueden ser calculados teniendo el modelo 3D del racimo. Estos descriptores sirven para clasificar los racimos de uva según su compacidad en 5 clases. Gracias a estos descriptores se consigue un método objetivo que mejora el estado del arte actual en abordar este problema (CI-12).

Aunque el problema de correspondencias puede ser complicado de solucionar por la naturaleza de los alimentos, en este caso se demuestra que se puede solucionar exitosamente mediante modelos. Este estudio es un ejemplo significativo de lo efectivo y útiles que pueden resultar los sistemas tridimensionales de visión estéreo en el sector alimentario.

Como resultado de este estudio se ha publicado el siguiente artículo en revista indexada (E Ivorra, Sánchez, Camarasa, Diago, & Tardaguila, 2014).



Capítulo 4: Aportaciones técnicas hiperespectrales

1.- Introducción

En la actualidad, hay pocas investigaciones que usen técnicas hiperespectrales o espectroscópicas enfocadas a evaluar productos alimenticios procesados y envasados, ya que en la mayoría de los estudios las muestras fueron manipuladas (picado, colocados en cajas de Petri, etc), es decir, cambiando la estructura y el formato en el que los productos son comercializados. Las técnicas hiperespectrales son capaces de medir muchos parámetros de los alimentos como la adulteración (Christy, Kasemsumran, Du, & Ozaki, 2004), la detección de defectos (Mehl, Chen, Kim, & Chan, 2004), por seguridad (Chao, Yang, Chen, Kim, & Chan, 2007) etc... En la presente tesis se decidió evaluar entre todos ellos la frescura aprovechando que la técnica permite realizar un seguimiento temporal de las mismas muestras a lo largo del tiempo. Resumiendo, uno de los objetivos perseguidos en la tesis fue evaluar la viabilidad de la adquisición de imágenes en el rango visible y del infrarrojo cercano de onda corta (SW-NIR) como un método no destructivo para evaluar la pérdida de frescura en alimentos.

1.1.- Definición de frescura

El término frescura es ambiguo cuando se refiere a carnes y pescados. La DRAE define frescura como: "Cualidad de fresco", siendo fresco: "Dicho de un alimento: No congelado". Esta definición guarda cierta relación con la de la organización de alimentos y agricultura que define el pescado fresco como aquel que no ha recibido ningún tratamiento para preservarlo o que únicamente ha sido enfriado (FAO, 2007). Sin embargo, el Diccionario Thesaurus la define como: "Propiedad de no estar deteriorado". En esta tesis se va a emplear esta última definición entendiendo frescura como el grado de deterioro de los alimentos respecto a la calidad inicial de los mismos.

Actualmente no está legislada ninguna metodología para cuantificar el grado de frescura de los alimentos de forma analítica. Algunos de los métodos más utilizados para obtener información de la frescura son: la medida de cambios postmortem asociados con medidas de sensores, crecimiento microbiano, cambios químicos como el pH o el nitrógeno volátil básico y la concentración de ATP (sobre todo en control de pescado) y sus productos degradados (Karube, Matsuoka, Suzuki, Watanabe, & Toyama, 1984; Fernandez-Segovia, Escriche, & Serra, 2008). El problema es que estos estudios trabajan sobre muestras preparadas, con lo que, aunque algunos no son destructivos de por sí, la muestra no es reutilizable. Debido a este motivo, desde un punto de vista práctico no resultan interesantes. Por esta razón, en esta tesis se va a aportar la ventaja de trabajar directamente sobre muestras con envase comercial sin alterarlas mediante el uso de tecnología NIR.

1.2.- Degradación de alimentos

Los alimentos que consumimos, principalmente los de origen vegetal, se deterioran principalmente por efecto de la respiración, la fermentación o la putrefacción. La respiración tiene particular importancia en las frutas y verduras que permanecen vivas algún tiempo después de la cosecha; produciéndose oxidación y maduración excesiva de estos alimentos. Por otro lado, la fermentación produce otro tipo de oxidación al limitar el contacto del aire con ciertos alimentos, produciendo cambios indeseables en las características del alimento. Muchas veces el hombre busca deliberadamente que se produzcan determinados procesos de fermentación y controla la forma y el curso de éstas para conseguir productos como vinos, cervezas (alcohol), yogurt (ácido láctico) o vinagres (ácido acético). Y por último, la putrefacción que afecta en especial a los alimentos de origen animal, provocando su descomposición (Vanaclocha & Requena, 2003).

Los principales causantes de la descomposición de los alimentos se clasifican en dos grupos dependiendo de si son factores biológicos o factores físico-químicos:

1. Factores biológicos:

- Microorganismos: Como los virus, hongos y bacterias del medio ambiente.
- Plagas: Insectos y parásitos presentes en los alimentos o donde se produzcan o almacenen.
- Enzimas: Compuestos presentes en los alimentos que aceleran las reacciones químicas específicas, interviniendo en la transformación de las sustancias que componen el alimento (maduración).

2. Físico-químicos:

- La Temperatura: Los microorganismos que pueden ocasionar problemas de salud en el hombre crecen de forma óptima con la misma temperatura que el cuerpo humano, es decir, 36-37 grados. A medida que las temperaturas se separan de este rango, se dificulta el desarrollo de éstos.
- La Humedad: El agua es indispensable para la vida, por lo que la humedad favorece el desarrollo de los microorganismos.
- La Luz: Los alimentos que están expuestos a la luz solar por mucho tiempo se deterioran debido a que aumenta su temperatura, favoreciendo el crecimiento de microorganismos.
- La Composición del alimento: Cuanto más nutrientes contengan los alimentos, tanto más favorecen el crecimiento de microorganismos. Hay gérmenes que prefieren los azúcares y otros las proteínas.

La degradación de los alimentos depende del tipo de alimento y de cómo este conservado. Algunos de los productos que han sido estudiados están envasados lo que hace que la mayoría de los microorganismos que provocan la pérdida de frescura son bacterias anaeróbicas. En el caso del pollo, al ser un producto fresco manipulado en el loncheado, su degradación es rápida y significativa. El pavo y jamón cocidos aunque son productos con un tratamiento térmico, al

ser éste suave (pasteurización) no genera la esterilidad. Esto provoca que la proliferación de microorganismos se produzca de forma normal y más teniendo en cuenta que en su elaboración se añaden nutrientes como son compuestos azucarados. En cuanto al salmón ahumado, al ser un producto derivado de la pesca es muy susceptible de ser degradado dado que su estructura nitrogenada es una buena base para el desarrollo de microorganismos, sin embargo, al aplicarse el tratamiento de ahumado este desarrollo se ve retrasado en gran medida.

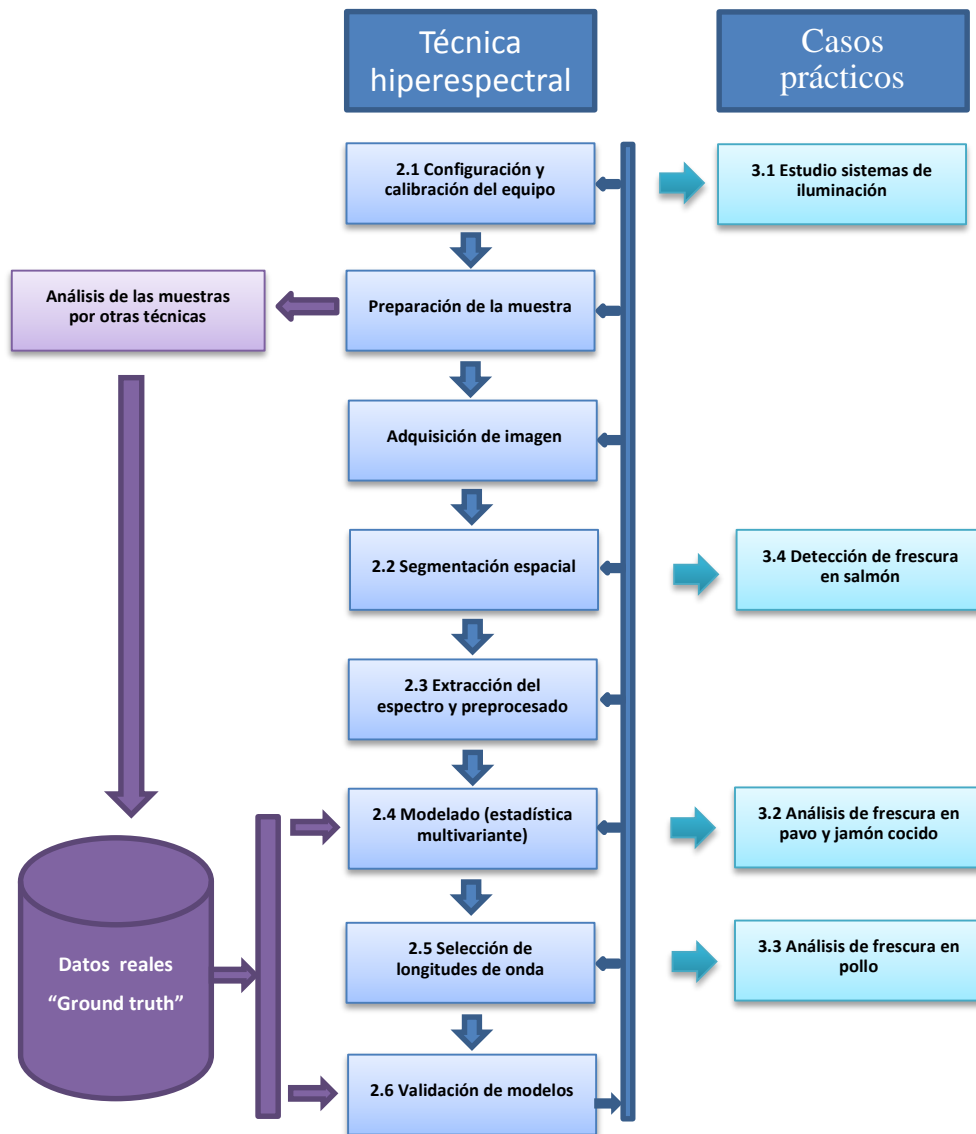
2.- Análisis de frescura de productos alimentarios

Los dispositivos hiperespectrales se pueden clasificar en tres tipos según la información espacial que registran por captura: un punto, una línea o un plano. El dispositivo que registra por puntos obtiene el espectro de una pequeña región de la muestra, con lo que para poder escanearla entera requiere que ésta se mueva en las dos direcciones del plano perpendiculares a la cámara. El equipo que registra por líneas presenta la misma dificultad pero reducida, puesto que solo requiere que la muestra se desplace en una sola dirección del plano (perpendicular a la línea de captura). En cuanto al dispositivo que captura todo un plano, sucede lo contrario, que requiere que durante la captura la muestra permanezca inmóvil y con una iluminación constante. Esto es debido a que cada plano que adquiere corresponde a una longitud de onda con lo que necesita muchas capturas consecutivas para tener todo el espectro y, por tanto, un mayor tiempo de adquisición.

Los dispositivos hiperespectrales más adecuados para el sector alimentario son los lineales debido a que son lo más rápidos (solo dependen de la velocidad de adquisición de la cámara), no necesitan tener la muestra iluminada durante mucho tiempo y por tanto evitan calentamientos innecesarios en los alimentos (como los que requieren los equipos que capturan un plano) y no necesitan un equipo electro-mecánico muy preciso para poder repetir las capturas (como los puntuales) puesto que solo necesitan una cinta transportadora y un

2.- Análisis de frescura de productos alimentarios

encoder para sincronizar el desplazamiento de ésta con la cámara. A partir de este momento se explicarán las fases necesarias para el análisis de frescura en alimentos suponiendo que se trata de un dispositivo lineal. En el esquema siguiente se muestran las diferentes fases y los casos prácticos que se han desarrollado centrados en cada una de las fases.



Esquema 4.1: Fases del proceso de obtención de resultados de imágenes hiperespectrales y los casos prácticos realizados.

2.1.- Configuración y calibrado del equipo

Capítulo 4: Aportaciones técnicas hiperespectrales

Los equipos hiperespectrales lineales se componen principalmente de tres partes: objetivos y lentes dependientes del tamaño del sensor, tipo de montura y distancia a la muestra, un filtro que dispersa el espectro electromagnético por longitudes de onda y un sensor bidimensional sensible a esas longitudes de onda. Estas partes se pueden ver en el esquema de la figura 4.1.




Figura 4.1 Esquema de un espectrógrafo hiperespectral (Paviotti & Poletto, 2008)

En el paso de configuración del equipo hay que ajustar el objetivo para que enfoque correctamente usando para ello por ejemplo un patrón como el de la figura 4.2 en el que se tiene que alinear la línea de inspección con el centro del patrón de forma que se vean franjas del mismo grosor. Otra tarea a realizar es ajustar el diafragma de la lente y el tiempo de integración de la cámara para evitar que sature en ningún punto del espectro en el que se trabaja. En el caso de que se quiera escanear la muestra entera hay que configurar la cinta transportadora teniendo en cuenta el tiempo de adquisición de la cámara y sincronizar el desplazamiento de la cinta con el disparador de la cámara.

En las técnicas hiperespectrales es fundamental utilizar un sistema de iluminación adecuado a las longitudes de onda en las que trabaja el equipo. Así mismo, hay que concretar las distancias y ángulos de incidencia de la luz entre las muestras y los sistemas de iluminación para conseguir unas condiciones óptimas de captura.




Figura 4.2 Patrón de calibración para alinear el equipo hiperespectral

Como en todos los equipos que realizan análisis cuantitativos y cualitativos el paso de calibración es muy importante para obtener resultados válidos de la cámara hiperespectral. Concretamente, el calibrado de la imagen hiperespectral se realiza para cumplir los siguientes objetivos (ElMasry & Sun, 2010):

- Estandarizar los espectros para poder compararlos con otras muestras adquiridas con otros equipos o en otras condiciones.
- Comprobar el correcto funcionamiento del equipo.
- Tener una medida de la precisión del espectro obtenido.
- Detectar y eliminar posibles causas de ruido en la señal.

La calibración de la imagen consiste en cuatro fases: relacionar las dimensiones de imagen con los ejes espaciales y espectrales, una calibración espectral, una calibración de reflectancia y un estudio temporal. Durante cualquiera de ellas es necesario prestar atención a posibles causas de ruido, como por ejemplo iluminación no controlada, variaciones de temperaturas, vibraciones o ruido electromagnético que pueda afectar a la cámara o a los cables que llevan la información.

En la fase de relacionar los píxeles (u,v) con los ejes espaciales y espectral, se asigna las filas u a la dimensión espacial y las columnas v a las dimensión espectral (o viceversa dependiendo de la colocación del filtro). En la figura 4.3 se muestra un esquema de este proceso en una cámara hiperespectral.




Figura 4.3 Esquema sistema hiperespectral

La calibración espectral consiste en relacionar cada píxel en el eje espectral de la cámara con la longitud de onda que le corresponde. Esto se realiza utilizando una fuente de luz con un espectro conocido. Las lámparas que usualmente se utilizan por tener espectros más característicos y estables son las de mercurio (Hg), helio (He), argón (Ar), neón (Ne) y cadmio (Cd). Primero se adquiere el espectro que emite esta fuente de iluminación. Una vez obtenido, se calcula la regresión de este espectro con el espectro teórico de esa fuente de luz. Aplicando esta regresión se sabe a qué píxel corresponde cada longitud de onda y se puede comprobar el rango espectral real del equipo. Este paso de calibración es muy importante, porque permite comprobar el buen funcionamiento del equipo y estandariza los resultados para que puedan ser comparados con otros estudios.

La calibración de la reflectancia tiene el propósito de normalizar la no linealidad del iluminante a lo largo del espectro y eliminar posibles ruidos constantes. Esto se realiza capturando un patrón que tenga un alto coeficiente de reflexión en el rango que se está trabajando, llamado comúnmente "blanco" y otro patrón "negro" que consiste en adquirir una imagen con el objetivo de la cámara tapado para eliminar el posible ruido que tenga la cámara. El patrón que se utiliza normalmente en el rango del visible y del infrarrojo cercano es el espectralon por su alto valor de reflectancia en esas longitudes de onda. Una vez obtenidos

estos dos patrones se utiliza la ecuación 4.1 (Paviotti & Poletto, 2008) para calcular el espectro rectificadado.

$$R = \frac{I-N}{B-N} \quad (4.1)$$

Donde I es la intensidad del píxel de la muestra, N es la intensidad del patrón negro y B la del patrón blanco.

Además de la configuración y la calibración del equipo es necesario un análisis de la variabilidad de condiciones. Estas condiciones son el tiempo, la temperatura de las muestras, la humedad y la temperatura del entorno y el medio entre el sensor y la muestra. El estudio temporal se realiza para comprobar la repetitividad de la señal a lo largo del tiempo. Tanto la cámara como el sistema de iluminación requieren de un transitorio hasta que alcanzan el régimen estacionario de funcionamiento. Esto es debido principalmente al cambio de temperatura que sufren los equipos al funcionar, siendo especialmente importante su control en el sistema de iluminación. Básicamente consiste en capturar imágenes periódicamente hasta que no existan variaciones significativas en la señal. Este tiempo que tarda el equipo en llegar al régimen estacionario es conocido como el tiempo de estabilización del sistema.

2.2.- Segmentación espacial

La segmentación espacial consiste en adquirir el espectro solo de los puntos que nos interesan de la muestra. La primera segmentación que hay que realizar siempre es la segmentación de la muestra dentro de la imagen, es decir, eliminar el fondo. Una vez segmentada la muestra en la imagen existen dos casos: que la muestra sea homogénea o no. En el caso de muestras homogéneas, donde el espectro no cambia dependiendo del punto donde se captura, no es necesario realizar ninguna segmentación siendo incluso posible realizar una media o mediana de todos los puntos espaciales para una medida más robusta del espectro. En el caso donde la muestra es heterogénea, se requiere hacer una segmentación espacial de

forma que se extraigan solo los espectros que nos interesen o para agrupar los espectros según los puntos de los que se han extraído. Las muestras heterogéneas se tratan de alimentos compuestos por diferentes tipos de tejidos que presentan espectros diferentes.

La segmentación espacial puede realizarse usando directamente los espectros. Una de las aportaciones de la presente tesis es realizar la segmentación espacial mediante dos aproximaciones diferentes. Una de ellas es transformar las imágenes hiperespectrales en imágenes 2D en un espacio de color como el RGB con todas las ventajas que ello comporta como poder segmentar posteriormente la imagen utilizando algoritmos clásicos de visión por computador, confirmar visualmente que se están analizando las partes correctas de la muestras o aportar información usuario entre otras muchas. Esta aproximación se explicará en detalle en la sección 3.4.4 La otra aproximación es utilizar conocimiento externo tridimensional de la escena para la segmentación. Esta aproximación se explicará en el capítulo 5 sección 3.4.

2.3.- Preprocesado

El preprocesado de los datos se puede dividir en operaciones espaciales y operaciones espectrales. Se trata de una serie de operaciones que tienen como objetivo optimizar el ratio señal-ruido, eliminar ruidos no deseados y maximizar la información útil que aportan los espectros. Muchas operaciones de preprocesado se realizan como pasos previos necesarios para poder utilizar modelos de calibración, como por ejemplo el centrado espectral a media 0 y a desviación estándar ± 1 necesario para modelos de regresión parcial de mínimos cuadrados (PLS). Las operaciones más comunes de preprocesado espectral son: centrado a media 0 por espectro o por clases, desviación estándar 1, derivadas de diferente orden (Savitsky-Golay), eliminación de línea base, alineación espectral, transformar de transmitancia a absorbancia ($\log(1/R)$), medias y medianas de muchos espectros y todo tipo de operaciones de suavizado.

En lo que respecta a las operaciones espaciales, se trata de las mismas que se aplican a las imágenes 2D normales, como por ejemplo filtros paso-bajo o paso-alto.

2. 4.- Análisis estadístico multivariante

Debido a la gran cantidad de información que se obtiene de los equipos hiperespectrales y a la gran colinealidad entre sus variables, no se pueden emplear métodos estadísticos tradicionales y hay que recurrir a los análisis estadísticos multivariantes para modelar y extraer información útil. Los modelos más usados para realizar análisis cuantitativos para datos con tantas dimensiones son la regresión de componentes principales (PCR) y la regresión de mínimos cuadrados parciales (PLS) con todas sus variantes (RPLS, OPLS). Si lo que se pretende es realizar una clasificación, los métodos más comunes son el análisis de componentes principales (PCA), análisis de clúster o análisis discriminantes (DA). Existen también métodos que son una combinación de ambas como por ejemplo el PLS-DA que se trata de realizar un PLS combinado con un DA de forma que a la hora de realizar la regresión factorial se tiene en cuenta la pertenencia a una clase. También se puede realizar un DA combinado con un PCA (PCA-DA) pero se obtienen peores resultados que con el PLS-DA al no tener en cuenta la clase (Roger, Palagos, Guillaume, & Bellon-Maurel, 2005) . Otro modelo basado en el PCA enfocado a la clasificación es el SIMCA que se trata de realizar tantos modelos PCA como clases existen de forma que luego las muestras se clasifican atendiendo en que modelo encajan mejor.

Se puede consultar más información acerca de estos métodos estadísticos multivariantes en el apéndice A.

2. 5.- Selección de longitudes de onda

En el análisis de imágenes hiperespectrales se trabaja con cientos de variables, muchas de las cuales solo contienen ruido y/o información redundante por lo que es muy conveniente

aplicar un algoritmo capaz de reducirlas y trabajar con un número reducido de ellas. Este aspecto se hace incluso más importante de cara a aplicaciones prácticas donde el reducir la cantidad de información a tratar mejora mucho la velocidad además de que suele mejorar los resultados cualitativos. Asimismo, en muchas industrias, el tener más variables supone más dinero, por lo que se hace vital el reducir el número de mediciones de un proceso al mínimo, manteniendo la información necesaria para un correcto funcionamiento del proceso, con el objetivo de reducir costes.

Aunque existen muchos tipos de métodos de selección de variables, los algoritmos genéticos (GA) nos dan un método directo para ello basado en la supervivencia de las variables que mejor se ajustan. Otro método interesante es el IPLS o intervalos de PLS para selección de variables que a diferencia del algoritmo genético realiza una búsqueda exhaustiva. Ambos métodos son explicados detalladamente en el apéndice A.

2. 6.- Validación de resultados

Para la validación de resultados se han utilizado principalmente métodos de validación cruzada. La validación cruzada es una técnica utilizada para evaluar los resultados de un análisis estadístico y garantizar que el modelo desarrollado es robusto. Para ello se emplean diferentes técnicas de validación cruzada basadas en dividir las muestras en datos de entrenamiento y datos de prueba. Estas técnicas se utilizan en entornos donde el objetivo principal es la predicción y donde se quiere estimar cómo de precisos y robustos son los modelos generados.

Las técnicas más comunes de validación cruzada son:

- Dejando uno fuera: Cada muestra del total es usada como muestra de predicción.
- Por bloques contiguos: Se utilizan m grupos de n muestras contiguas para testear el modelo.

3.- Caso práctico: evaluación de tres sistemas de iluminación

- Por muestras aleatorias: Se utilizan m grupos de n muestras escogidas aleatoriamente. Este procedimiento se repite un determinado número de iteraciones.
- Por “persianas venecianas”: Se utilizan m grupos de n muestras escogidas saltando l muestras para testear el modelo.

La eficiencia del modelo para predecir las muestras que no se utilizaron al realizar el modelo se realizó con el error medio cuadrático de validación cruzada (RMSECV) siguiendo la ecuación 4.2.

$$\text{RMSECV} = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (4.2)$$

Donde \hat{y}_i son los valores de las variables predichas por el modelo para las muestras seleccionadas por el método de validación cruzada, y_i son los valores conocidos de las variables y n es el número total de muestras.

3.- Caso práctico: evaluación de tres sistemas de iluminación

La experiencia consistió en evaluar tres sistemas de iluminación distintos de cara a su uso en la captura de imágenes hiperespectrales de productos alimenticios envasados.

Uno de los sistemas de iluminación estaba formado por dos focos halógenos de 75W 230V HI-SPOT (Havells Sylvania, Gennevilliers, Francia) colocados a una distancia de 18 cm del patrón encarados de forma indirecta. El segundo sistema consistió en un solo foco halógeno FL150Q de 150W (Intermatic, Spring Grove, Estados Unidos) con IP44 colocado a una distancia de 45 cm en diagonal del patrón y a una altura de 35 cm encarado de forma indirecta al patrón. El tercer sistema se trató también de un foco halógeno diseñado especialmente para sistemas hiperespectrales que se situó en la misma posición que el foco de 150W. El foco es el modelo

Illuminator (ASDInc, Atlanta, Estados Unidos). Se puede ver un esquema de los sistemas de iluminación en la figura 4.4




Figura 4.4: Esquemas de los sistemas de iluminación

Durante la experiencia se capturaron imágenes durante 15 minutos de un patrón blanco cada minuto con los sistemas de iluminación encendidos durante todo el proceso (por separado) y siendo estas las únicas fuentes de luz. Este procedimiento se realizó por duplicado obteniendo resultados equivalentes.

En la figura 4.5 se pueden observar los espectros de las imágenes capturadas. El color de las líneas va cambiando de azul a rojo conforme van avanzando los minutos para una mejor visualización. Como se puede observar, el tiempo de estabilización de la luz de los tres sistemas son semejantes (entre 3 y 4 minutos) descartando este parámetro como discriminante para el mejor sistema de iluminación. A nivel de rango de longitudes de onda presentan el mismo comportamiento los dos primeros sistemas, sin embargo el tercero, a pesar de basarse en la misma tecnología de halógenos, consigue una mejor iluminación del infrarrojo cercano debido a que funciona con un mayor amperaje tal y como se puede observar en la figura 4.6.

3.- Caso práctico: evaluación de tres sistemas de iluminación




Figura 4.5: Variación lumínica de los sistemas de iluminación: A) dos focos 75w, B) foco 150w, C) foco Illuminator




Figura 4.6: Comparación sistemas 1 y 2 con el 3

4.- Caso práctico: estudio de frescura en jamón de pavo y jamón cocido

4.1.- Descripción del estudio

El estudio se llevó a cabo con 14 muestras de jamón de pavo y el mismo número de muestras de jamón cocido obtenidas en un supermercado. Para establecer un parámetro de frescura inicial se decidió elegir productos de diferentes lotes, pero con el mismo período de caducidad (40 días). El muestreo se realizó a los 0, 30, 40 (fecha límite de consumo propuesta por el productor) y 60 días (con el fin de garantizar la vida útil).

Para el análisis de nucleótidos, las muestras fueron tomadas en los días 0, 15, 25 y 40 días. Durante el estudio, las muestras fueron almacenadas a 4 °C.

En cada tiempo de muestreo, primero se adquirieron las imágenes y posteriormente se abrieron los paquetes de forma aséptica y se extrajeron las muestras para su análisis microbiológico. Las muestras restantes se utilizaron para análisis posteriores.

4.2.- Análisis destructivos

Para la determinación de pH, se analizaron soluciones de 10g de carne de pavo y jamón cocido homogeneizada en 90 ml de agua destilada con un medidor de pH portátil MM40 (Crison Instrumentos S. A, Alella, Barcelona, España) siguiendo el procedimiento propuesto por (Fuentes, Barat, Fernández-Segovia, & Serra, 2008).

El Nitrógeno básico volátil total (TVB-N) se determinó de acuerdo a los procedimientos descritos por (Malle & Tao, 1987).

4.- Caso práctico: estudio de frescura en jamón de pavo y jamón cocido

Los compuestos relacionados con el ATP, que consta de inosina-5'-monofosfato (IMP), inosina (Ino) y la hipoxantina (Hx), fueron analizadas por HPLC según el método descrito por (Barat et al., 2008), con algunas modificaciones menores.

El análisis de HPLC se llevó a cabo en un cromatógrafo de líquidos Jasco (Milán, Italia) con la bomba (modelo PU-1580), el muestreador automático (modelo AS-1555-10), la unidad de gradiente ternario (modelo LG-1580-02), el desgasificador (modelo DG-1580-54), y el detector de diodos (modelo MD-1510). La adquisición de datos se realizó con la versión de software ChromPass 17.403.1 (Jasco). Las separaciones se lograron en una fase inversa C18 Ultrabase 250x4, 6 mm, diámetro de la partícula interior de 5 µm (Análisis Vínicos, SL, Tomelloso, España). Una columna de seguridad que contiene el mismo empaque C18 que el anterior se colocó en frente de la columna de análisis, para protegerlo de la contaminación.

El recuento de microorganismos aerobios mesófilos (ufc/g) se estimó siguiendo el método propuesto por (UNE-EN ISO, 2003). Se prepararon 10 disoluciones de 0,1% de agua peptonada de cada una de las muestras en cada uno de los días de medidas (n=4) y se cultivaron en placas de cultivo a las que se agregó 1mL de una disolución de medio de cultivo Plate Count Agar (PCA). Se incubaron durante 48h a 28 °C. Todos los análisis destructivos se realizaron por triplicado después de la trituración y homogeneización de las muestras.

4.3.- Equipo hiperespectral utilizado y condiciones de adquisición

Las imágenes fueron tomadas con una cámara CCD 102F (Basler Vision Technologies., Ahrensburg, Alemania) con un filtro SPECIM ImSpector V10 de 1.2" (SPECIM Spectral Imaging, LTD., Oulu, Finlandia), que funciona como una cámara hiperespectral lineal. El iluminante son dos lámparas halógenas de 75W 230V HI-SPOT (Havells Sylvania, Gennevilliers, Francia) que producen una luz indirecta para reducir los reflejos. La posición del sistema de iluminación y la cámara de la muestra fue siempre constante para controlar las condiciones de iluminación y

para obtener un tamaño de imagen constante. La distancia entre la fuente de iluminación y la muestra fue de 18 cm, con una distancia de 40 cm entre la cámara y la muestra. La imagen (la línea escaneada) obtenida se compone de 256 niveles de gris (8 bits). El espectro de reflectancia difusa se recogió utilizando 1.040 píxeles (cada longitud de onda es digitalizada en 8 bits). Las longitudes de onda se distribuyen a intervalos de 11.2 nm en el rango de 400 a 1000 nm. Esta línea escaneada se compone de 1.392 píxeles en el eje espacial, por lo que la imagen tiene una resolución de 1392 x 1040 píxeles.

Las condiciones de adquisición permanecieron constantes durante todo el estudio estando la temperatura ambiental constante a 22 °C y un tiempo de espera de 10 minutos para asegurar el estado estacionario del equipo.

Se realizó una calibración del equipo hiperespectral tal y como esta explicado en la sección 2.2. Los datos de reflectancia fueron transformados de reflectancia a absorbancia aplicando la ecuación $\log 1/R$, donde la R es el valor de reflectancia.

Primero se realizó una segmentación de la muestra eliminando el fondo basándose en los niveles de intensidad en longitudes de onda del visible conocidas del fondo. Después, como preprocesado de la imagen se realizó una media espacial con el objetivo de quitar ruidos y tener una información espectral más robusta. Se realizaron otras operaciones matemáticas para el posterior tratamiento estadístico como centrar la media a 0 y normalizar la varianza a 1.

El software de control de la cámara fue el pilón Viewer 2.1.0.1664 (Basler Vision Technologies, Ahrensburg, Alemania). El tratamiento y preprocesado de las imágenes fueron realizados en el entorno de programación Matlab (The Mathworks, Natick, Massachussets, USA) mediante código propio desarrollado.

4.4.- Análisis estadístico realizado

Para analizar la información espectral se utilizó el método de mínimos cuadrados parciales de análisis discriminante (PLSDA) (Wallays, Missotten, Baerdemaeker, & Saeys, 2009). El PLSDA es muy similar al LDA. De hecho, (Barker & Rayens, 2003) demuestra que el PLSDA es la aproximación utilizando la inversa de los mínimos cuadrados al LDA, obteniendo los mismos resultados pero con la ventaja de la reducción de ruido y selección de variables del método PLS. El método PLSDA consiste en desarrollar tantos modelos PLS como clases, ajustando cada vez una de estas clases de forma que luego es posible determinar la pertenencia o no de una muestra dependiendo de en qué modelo se ajuste mejor.

El método empleado para la validación cruzada fue la separación en grupos contiguos pertenecientes al mismo día utilizando un máximo de 20 componentes principales y un tamaño de bloque de 2.

La relación entre los espectros y las variables de los análisis destructivos se obtuvo mediante una regresión de mínimos cuadrados parciales (PLS) (Bharati & Champagne, 2004).

Todos los procedimientos estadísticos se realizaron con la herramienta PLSToolbox (Eigenvector Research Inc., Wenatchee, Washington, USA), que es una librería del entorno de computación Matlab (The Mathworks, Natick, Massachusetts, EE.UU.).

4.5.- Resultados imágenes hiperespectrales

El espectro medio calculado del pavo después del preprocesado (centrado a media 0 y desviación estándar 1) y del suavizado se muestra en la figura 4.7. El suavizado solo se realizó para una mejor visualización de la información. Además se le aplicó el logaritmo y la inversa de

la reflectancia ($\log(1/R)$). Visualmente, los espectros se pueden dividir fácilmente entre las medias de las muestras del día 0, de los días 30-40 y del día 60, sin embargo la dispersión de cada muestra hizo necesario un estudio estadístico multivariante.




Figura 4.7 Espectro medio de todos los días del pavo

La calibración y validación cruzada del tiempo de almacenamiento se llevó a cabo utilizando un modelo PLS-DA cuyos resultados se muestran en la tabla 4.1. Para ambos productos el número de factores (LV) empleado fue de 8. Los coeficientes de determinación en calibración (R^2C) obtenidos en diferentes tiempos de almacenamiento, presentaron valores altos a pesar de que fueron disminuyendo con el tiempo (el peor valor $R^2C = 0.965$ fue de jamón cocido a los 60 días). Este comportamiento combinado con los bajos valores de la media cuadrática del error de calibración (RMSEC) puede revelar una fuerte relación entre espectros y tiempo de almacenamiento, especialmente en el pavo (valores más altos de R^2C e inferior de RMSEC). De hecho, los altos valores de los coeficientes de determinación de la validación cruzada (R^2CV), aunque inferiores a los de R^2C , reforzarían esta idea. Incluso el peor ajuste obtenido para el jamón cocido a 60 días ($R^2CV = 0,856$ y $RMSECV = 0,1356$) puede ser considerado como adecuado.

4.- Caso práctico: estudio de frescura en jamón de pavo y jamón cocido

Tabla 4.1: Resultados PLS-DA para el pavo y el jamón york

	LVs	Tiempo (Días)	RMSEC	R ² Cal	RMSECV	R ² CV
Pavo	8	0	0.0388	0.994	0.0815	0.974
		30	0.0502	0.986	0.1131	0.943
		40	0.0589	0.977	0.1345	0.909
		60	0.0540	0.973	0.1268	0.896
Jamón york	8	0	0.0814	0.973	0.1320	0.929
		30	0.0483	0.987	0.1123	0.934
		40	0.0678	0.970	0.1474	0.861
		60	0.0691	0.965	0.1356	0.856

En la figura 4.8 se muestra la sensibilidad (líneas grises), especificidad (líneas negras) y el valor umbral (seleccionado por el algoritmo PLS-DA) (línea vertical discontinua negra) de jamón de pavo. El umbral se calcula usando el teorema de Bayes y los datos disponibles con el fin de minimizar los errores totales. Se trata del mismo umbral utilizado para calcular las funciones de discriminación. Idealmente, estas líneas se cruzan cuando aún están en un valor de 1. El cruce por debajo de un valor de 1 indica que, como el umbral se incrementa, la sensibilidad comienza a sufrir (cae por debajo de 1) antes de que el modelo sea completamente específico.

El punto en que la línea del umbral vertical cruza la línea gris continua es la sensibilidad de calibración, y el punto donde la línea discontinua gris cruza el umbral es la sensibilidad de la validación cruzada. Del mismo modo, el punto donde la línea de color negro cruza el umbral es la especificidad de calibración y el punto donde la línea negra discontinua cruza el límite es la especificidad de la validación cruzada.

Cabe señalar que la línea del umbral, para todos los tiempos, cruza la especificidad en el valor de 1 tanto en calibración (línea de color negro sólido) como en la validación cruzada (línea

discontinua negra). Sin embargo, la línea del umbral se cruza en valores inferiores a 1 para la de sensibilidad disminuyendo conforme aumenta el tiempo de muestreo, siendo inferior para la validación cruzada.

Se observó el mismo comportamiento para el jamón york obteniéndose los peores valores de sensibilidad a los 60 días (sensibilidad de calibración = 0,989 y 0,875 de la validación cruzada).

De acuerdo con estos resultados es razonable utilizar los espectros para discriminar el tiempo de almacenamiento, a pesar de que la sensibilidad disminuye ligeramente con el tiempo de almacenamiento.

Se realizó una regresión de mínimos cuadrados parciales (PLS 20 LV) para correlacionar la variación del espectro en las longitudes de onda seleccionadas durante el tiempo de almacenamiento con las características fisicoquímicas, parámetros bioquímicos y microbiológicos. Se obtuvieron valores de R^2 y R^2CV altos en los dos productos, siendo ligeramente superiores en los del pavo.

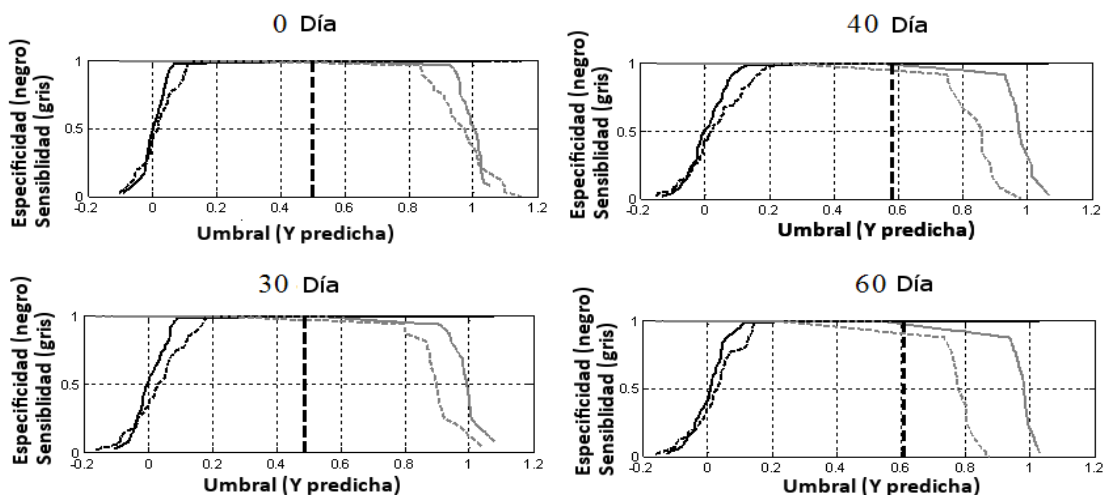


Figura 4.8 Gráfica de sensibilidad y especificidad del modelo PLS-DA para el pavo. Sensibilidad (líneas grises) y especificidad (líneas negras) para calibración (líneas continuas) y validación cruzada (líneas discontinuas)

4.- Caso práctico: estudio de frescura en jamón de pavo y jamón cocido

A pesar del estudio de los espectros y su derivadas primera y segunda, a menudo utilizadas para procesar datos NIR debido a que ayuda a separar las bandas de absorción, eliminar los cambios de base y aumentar la resolución aparente espectral (Lin, Mousavi-Hesary, Al-Qadiri, H., & Rasco, 2004), no se lograron identificaciones claras de picos o valles conocidos que podrían estar relacionados con los parámetros estudiados, sin embargo, los modelos desarrollados para la predicción de TVB-N, el pH y los recuentos microbianos se considera que proporcionan resultados realistas (tabla 4.2). Esto podría explicarse por el hecho de que los parámetros se deben a mediciones indirectas y que por ese motivo no existen bandas de absorción específica que puedan ser reconocidas en la región de SW-NIR.

Tabla 4.2 Resultados estadísticos del PLS entre análisis no destructivos y los destructivos para Jamón de york y de pavo

	Físico-químicos	LVs	RMSEC	R ² cal	RMSECV	R ² CV
Jamón york	TVB-N	6	0.985	0.3397	0.900	0.8900
	log (cfu g ⁻¹)		0.982	0.1508	0.892	0.3828
	pH		0.703	0.0264	0.907	0.0728
Pavo	TVB-N	6	0.992	0.3987	0.959	0.9094
	log (cfu g ⁻¹)		0.995	0.1841	0.974	0.4443
	pH		0.984	0.0299	0.925	0.0745

4.6.- Conclusiones

La pérdida de frescura en el jamón cocido y en el pavo ha sido asociada principalmente a un aumento de la carga microbiana log (cfu g⁻¹) y de los valores de TVB-N asimismo como a una disminución de los valores de pH, a pesar de que estos no se pueden utilizar para definir la fecha límite de consumo.

Las imágenes obtenidas mediante visible y SW-NIR se han relacionado con el tiempo de almacenamiento de las muestras con buena especificidad en todos los tiempos estudiados (60 días). La sensibilidad, aunque ha disminuido con el tiempo de almacenamiento, al final del estudio fue aceptable (0.875). El análisis de las imágenes presenta una buena relación con la

carga microbiana, TVB-N y los valores de pH, aunque no así con las bandas de absorción específicas conocidas en la región visible-SW-NIR.

Basándose en los resultados obtenidos, el uso de equipos de adquisición de imagen en el rango visible y SW NIR podría ser utilizado para evaluar la pérdida de frescura en el jamón cocido y pavo, debido a sus múltiples ventajas como son: velocidad, bajo coste y ser no destructivos. Sin embargo, se requieren trabajos futuros para asociar el espectro a bandas de absorción específicas y un estudio específico de su utilización en línea.

4.7.- Aportaciones del estudio

Además de demostrar la viabilidad del análisis de frescura en pavo y jamón york, el estudio se ha centrado en el estudio estadístico y en el modelado de datos. Debido a que las muestras eran homogéneas, no requirió una fase de segmentación espacial a excepción de eliminar el fondo. Tampoco se realizó la fase de selección de variables por dos motivos: primero porque se obtuvieron buenos resultados sin realizarla y segundo porque en este estudio no se le dio importancia al tiempo de procesado de datos. Este estudio se podría considerar como el procedimiento básico para el análisis basado en imagen hiperespectral de frescura en productos alimenticios.

Como resultado de este estudio se ha publicado el siguiente artículo en revista indexada (Girón J. et al., 2013).

5.- Caso práctico: estudio de frescura en pechuga de pollo

5.1.- Descripción del estudio

El estudio se llevó a cabo sobre 50 pechugas de pollo broiler, que fueron obtenidas de una granja avícola local 24 horas después de matarlos. Las muestras, sin grasa ni piel, fueron cortadas en tajadas de 200 gramos cada una con un grosor de 20mm. Las muestras fueron manipuladas asépticamente y empaquetadas en una barqueta de plástico de 14 cm por 11 cm al vacío con un film plástico (n=45). El tamaño de las muestras dentro de las bandejas fue aquel que ocupase toda la superficie de ésta, siendo las dimensiones aproximadas de cinco centímetros de ancho, ocho centímetros de largo y dos centímetros de alto.

Los puntos temporales en los que se evaluó la calidad fueron a los 0 días (inmediatamente después de empaquetar), a los 7 y a los 14 días de almacenamiento a 4°C. Concretamente, la monitorización de los componentes nucleótidos fueron medidos a los 0, 3, 7, 9,12 y 14 días.

El análisis de imágenes (visuales y SW NIR) se llevó a cabo en el día 0 en todas las muestras antes y después del envasado. Para cada tiempo de muestreo, las imágenes fueron capturadas antes y después de la apertura de las muestras (n = 10). La apertura se llevó a cabo en condiciones asépticas con el fin de tomar muestras para el análisis microbiológico. Las muestras restantes sin envasar se utilizaron para la captura de imágenes y análisis posteriores físico-químicos. Las 15 muestras restantes se utilizaron para la monitorización de componentes nucleótidos en los días 3, 9 y 12.

5.2.- Análisis destructivos

Los análisis destructivos realizados fueron los mismos que en la experiencia 3.2 que recordemos que eran:

- La humedad x^w .

- La actividad del agua a_w .
- pH.
- El nitrógeno total volátil (TVB-N).
- Nucleótidos relacionados con el ATP (inosina-5'-monofosfato (IMP), inosina (Ino) y la hipoxantina (Hx)).
- Recuento de microorganismos aerobios mesófilos (ufc/g).

Todos los análisis destructivos se realizaron por triplicado después de la trituración y homogeneización de las muestras.

5.3.- Equipo hiperespectral utilizado y condiciones de adquisición

El equipo empleado y las condiciones de adquisición fueron las mismas que para la experiencia 3.2. La captura de imágenes se realizó en 6 líneas diferentes de acuerdo con el esquema de la figura 4.9 para cada una de las muestras.




Figura 4.9: Esquema de la barqueta de plástico empleada y las líneas de captura de espectro de las muestras

5.4. – Modelos estadísticos empleados

Para describir la relación entre las longitudes de onda y el tiempo de almacenamiento, se utilizó un análisis de regresión múltiple y un método de selección de variable hacia adelante. La influencia de la película de embalaje y el tiempo de almacenamiento en los valores de los espectros se evaluó mediante un análisis discriminante. Los datos de espectros obtenidos para las muestras sin película de embalaje fueron etiquetados como “WPF2” y los envases con la película “PF”.

El método de mínimos cuadrados parciales (PLSDA) fue empleado para obtener métodos de predicción de la calibración y el tiempo de almacenamiento. Las muestras fueron seleccionadas al azar en dos grupos, tres cuartas partes del total de muestras se utilizaron para la calibración y validación cruzada y el resto para validar las calibraciones. Las longitudes de onda seleccionadas más relevantes se obtuvieron con el método de selección de variables IPLSDA.

La relación entre los espectros y las variables físico-químicas obtenidas de los análisis destructivos se realizó mediante una regresión de mínimos cuadrados parciales (PLS).

Todos los procedimientos estadísticos se realizaron con la herramienta PLSToolbox (Eigenvector Reserach Inc., Wenatchee, Washington, USA), que es una librería del entorno de computación Matlab (The Mathworks, Natick, Massachusetts, EE.UU.).

5.5.- Resultados de las imágenes hiperespectrales

Se realizó una evaluación del efecto del film con los datos de reflectancia adquiridos durante el tiempo de almacenamiento. Los espectros obtenidos para cada imagen se clasificaron según el tiempo de muestreo (tiempo de almacenamiento), independientemente

de la presencia o ausencia de la película de envasado. Las imágenes fueron tomadas por tanto, antes y después de que las muestras de pollo fueran envasadas. La figura 4.10 muestra los resultados de un discriminante basado en un PCA en los datos de las muestras envasadas y no envasadas. El primer componente principal (PC1) explicó 73.51% de la varianza total, mientras que PC2 explicó sólo el 19.7% de la variación. Aunque las muestras no pueden ser diferenciadas sobre la base de la presencia o ausencia de película de plástico a 0 y 7 días, hubo una ligera diferencia entre los dos grupos a los 14 días de almacenamiento. Estas observaciones fueron consistentes con los resultados observados por otros autores (Ellekjaer & Isaksson, 1992), quienes encontraron que la adición de la película a las muestras de carne sólo causó leves, o insignificantes, errores de predicción con las técnicas de NIR y NIT. Por otro lado, hubo una clara discriminación basada en el tiempo de almacenamiento (días 0, 7 y 14). Es por ello que la leve influencia de la película de embalaje no se tuvo en cuenta para los estudios posteriores, considerando todas las muestras (con y sin embalaje película) como iguales.




Figura 4.10 PCA de las muestras con film (PF) y sin film (WPF) durante el tiempo de almacenamiento

La tabla 4.3 muestra los resultados estadísticos obtenidos al aplicar el algoritmo PLS-DA con el objetivo de predecir la clasificación de las muestras en función del tiempo de almacenamiento. La calibración (C) y la validación cruzada (CV) fueron obtenidas por el error estándar (SE), la raíz del error medio cuadrático (RMSE) y el coeficiente de determinación (R^2).

5.- Caso práctico: estudio de frescura en pechuga de pollo

Aunque el coeficiente de determinación para la calibración (R^2C) fue muy alto para todos los tiempos ($R^2 = 0,94$), el coeficiente de validación cruzada (R^2CV) sólo fue elevado a los 7 días ($R^2 = 0,82$) y luego ligeramente inferior a los 0 y los 14 días ($R^2 = 0,72$ y $R^2 = 0,75$ respectivamente).

Con el fin de mejorar los resultados, se redujeron el número de variables independientes disponibles, buscando la mejor selección de longitudes de onda del espectro que tuvieran la mejor correlación con el tiempo de almacenamiento. Las longitudes de onda obtenidas, empleando el algoritmo de selección de variables de IPLSDA, fueron: 413, 426, 449, 460, 473, 480, 499, 638, 942, 946, 967, 970 y 982 nm. Las variables resultantes requieren el uso de un equipo con rango espectral del visible hasta el infrarrojo cercano.

Los resultados de las validaciones cruzadas y de los test realizados para los modelos predictivos empleando la selección de las longitudes de onda obtenidas fueron mejores que los obtenidos empleando todo el espectro (tabla 4.3). La información proporcionada por todo el espectro podría ocultar la aportada por los puntos seleccionados. Concretamente, la información proporcionada en los puntos de inflexión del espectro a 525, 560, 570 y 600 nm redujo el valor de R^2 , para el estudio PLS, a 0,65 siendo este de 0,89 cuando se usan los 13 puntos seleccionados.

Tabla 4.3 Resultados estadísticos del PLSDA para todo el espectro y para una selección de 13 longitudes de onda

Modelo estadístico	Todo el espectro			Selección de 13 puntos		
	Día 0	Día 7	Día 14	Día 0	Día 7	Día 14
SE (C)	0	0	0	0	0	0
SE (CV)	0.1094	0	0.0781	0	0	0
RMSE (C)	0.1110	0.1193	0.1137	0.1040	0.0933	0.1231
RMSE (CV)	0.2984	0.1987	0.2878	0.1580	0.1666	0.2236
R2 (C)	0.9352	0.9359	0.9419	0.9513	0.9609	0.9318
R2 (CV)	0.7179	0.8673	0.7510	0.8894	0.8754	0.7766

La figura 4.11 muestra la segunda derivada de los espectros de todos los tiempos y las longitudes de onda seleccionadas usando el algoritmo IPLSDA. Se empleó la técnica de la

segunda derivada para procesar los datos NIR que como ya se ha comentado ayuda a separar la superposición de bandas de absorción, eliminar ruidos de base y aumentar la resolución espectral. La mayoría de las longitudes de onda seleccionadas fueron en el rango de 400-500 y 940-980 nm, aunque las longitudes de onda alrededor de 638 fueron influyentes también. Algunos autores han relacionado algunas longitudes de onda del espectro visible y SW-NIR con los componentes bioquímicos que cambian durante el almacenamiento de carne.

Las longitudes de onda 430-435 nm forman la banda de Soret que se atribuye a una intensa transición $\pi \rightarrow \pi^*$ observada en todos los anillos de porfirinas conjugadas (tetrapirrol macrocíclicas) en los que la deslocalización de electrones se extiende por todo el anillo macrocíclicas (por ejemplo, el grupo hemoprotéico en la mioglobina) (Liu et al., 2003; Andres, A.L, Martins C., & I, 2008)

Las bandas de absorción a 545, 575 y 635 nm sugieren una dinámica de conversión y degradación de una serie de derivados de la mioglobina (Liu et al., 2003). Los bajos niveles de pigmento rojo (derivados de la mioglobina) en pechugas de pollo podrían ser responsable de los cambios observados a 638 nm. La débil banda del infrarrojo cercano a 760 nm puede ser debida al tercer sobretono del OH o a una banda de absorción producidas por la oxidación de la mioglobina. Por otra parte, las bandas características del agua se identificaron a 980 nm (segundo sobretono de OH).

5.- Caso práctico: estudio de frescura en pechuga de pollo




Figura 4.11: Segunda derivada de la media de espectros para todas las longitudes de onda; Las longitudes de onda marcadas son las seleccionadas por el IPLSDA

Las diferencias entre los espectros para el tiempo de monitorización con los obtenidos en el día 0 se muestran en la figura 4.12. Las mayores diferencias se obtuvieron, para las longitudes de onda seleccionadas, entre el tiempo 0 y 14 días. La máxima diferencia entre el tiempo 0 y 7 días estuvo en el rango de 460 nm y 499 nm. Este rango de longitudes de onda es especialmente útil para diferenciar entre las muestras a los 0 días.

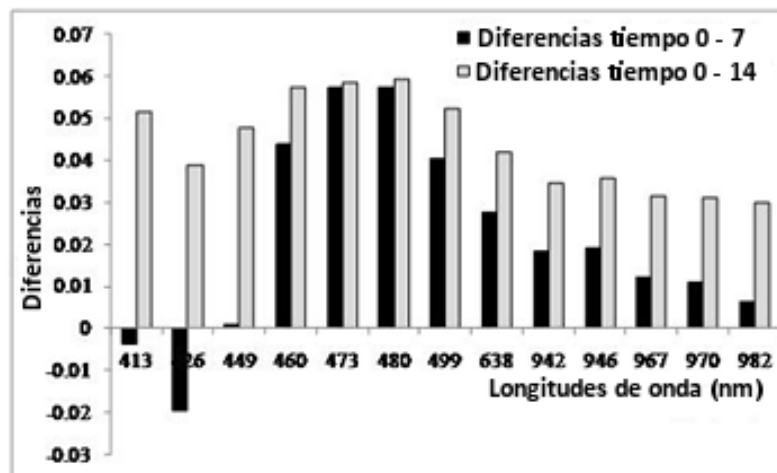


Figura 4.12: Diferencias espectrales entre los días 7 y 14 respecto al día 0, para las 13 longitudes de onda seleccionadas

5.6.- Correlación entre los análisis destructivos y los no destructivos

Se realizó una regresión de mínimos cuadrados parciales (PLS) para correlacionar la variación del espectro en las longitudes de onda seleccionadas durante el tiempo de almacenamiento con las características fisicoquímicas, parámetros bioquímicos y microbiológicos (tabla 4.4). El mayor coeficiente de determinación para la predicción (R^2P) se obtuvo para K1, TVB-N, pH, a_w y ufc/g, lo que indica una relación entre estos cinco parámetros.

Comportamientos similares fueron encontrados por otros autores que trabajaron en longitudes de onda mayores y que observaron una relación entre los cambios de espectro en las muestras de carne y pescado y una disminución de la frescura asociados con el crecimiento microbiano (Ellis & Goodacre, 2001; Lin et al., 2004; Horváth, Seregély, Andrásy, Dalmadi, & Farkas, 2008).

Tabla 4.4: Resultados estadísticos del PLS. Se presentan los resultados de la calibración (C) y los obtenidos al comprobar el modelo con datos independientes (P)

	x^w	a_w	pH	TVB-N (mg/100g)	k1 valores (%)	log ufc/g
RMSE (C)	0.3130	0.0009	0.0693	3.8190	4.1478	0.7264
RMSE (P)	0.4210	0.0016	0.0834	6.0118	6.5294	0.7994
R2 (C)	0.352	0.756	0.580	0.736	0.799	0.789
R2 (P)	0.593	0.878	0.767	0.883	0.893	0.804

5.7.- Conclusiones

La pérdida de frescura en filetes de pechuga de pollo envasado ha sido asociada principalmente con un aumento en los valores de TVB-N, el parámetro K1, pH, a_w y el crecimiento microbiano (ufc/g). Los espectros obtenidos de las muestras utilizando espectroscopia visible y SW-NIR se han relacionado con el tiempo de almacenamiento de las

5.- Caso práctico: estudio de frescura en pechuga de pollo

muestras, donde las mejores longitudes onda para la predicción de frescura fueron 413, 426, 449, 460, 473, 480, 499, 638 , 942, 946, 967, 970 y 982 nm.

La presencia de películas de embalaje no afectó a la información obtenida de las imágenes. De especial interés es la correlación lineal entre la espectroscopia visible y SW-NIR y parámetros tales como el K1 y los índices de TVB-N, que indica la evolución simultánea de ciertos metabolitos (inosina 5'-monofosfato, inosina e hipoxantina).

El método de espectroscopia visible y SW-NIR se reafirma en este estudio como un método rápido, de bajo coste y no destructivo y que consideramos adecuado para el control de la frescura de pechuga de pollo envasado.

5.8.- Aportaciones del estudio

Además de demostrar la viabilidad del análisis de frescura en pechugas de pollo, el estudio se ha centrado en dos puntos: la selección de variables y el estudio de cómo influye la adquisición de imágenes hiperespectrales directamente sobre envases comerciales. Debido a que las muestras eran homogéneas no se realizó fase de segmentación espacial aparte de la identificación de muestra y fondo. La fase de selección de variables usando el método de IPLSDA resultó muy beneficiosa por varios motivos: el primero porque se obtuvieron mejores resultados que sin realizarla con lo que sirve como un filtro de ruido e información redundante, segundo porque resulta mucho más rápido procesar 13 longitudes de onda que todo el espectro, tercero porque de cara a una futura implantación se podrían desarrollar sensores que solo capturarán estas longitudes de onda ahorrando dinero y tiempo de adquisición. Otro importante aspecto de esta experiencia es la demostración de que el film a pesar de atenuar el espectro, con el adecuado tratamiento preprocesamiento y tratamiento estadístico no afecta al análisis de frescura. Esto reafirma la técnica hiperespectral como muy adecuada para el sector de la alimentación puesto que no requiere ninguna manipulación ni preparación de la muestra.

Este estudio se podría considerar como una ampliación a la experiencia anterior de análisis de frescura en pavo y jamón york. La repetición de los buenos resultados en esta experiencia demuestra que el equipo y el rango del espectro que se está utilizando es el adecuado para la tarea de análisis de frescura en alimentos envasados. Como resultado de este estudio se ha publicado el siguiente artículo en revista indexada (Grau et al., 2011a)

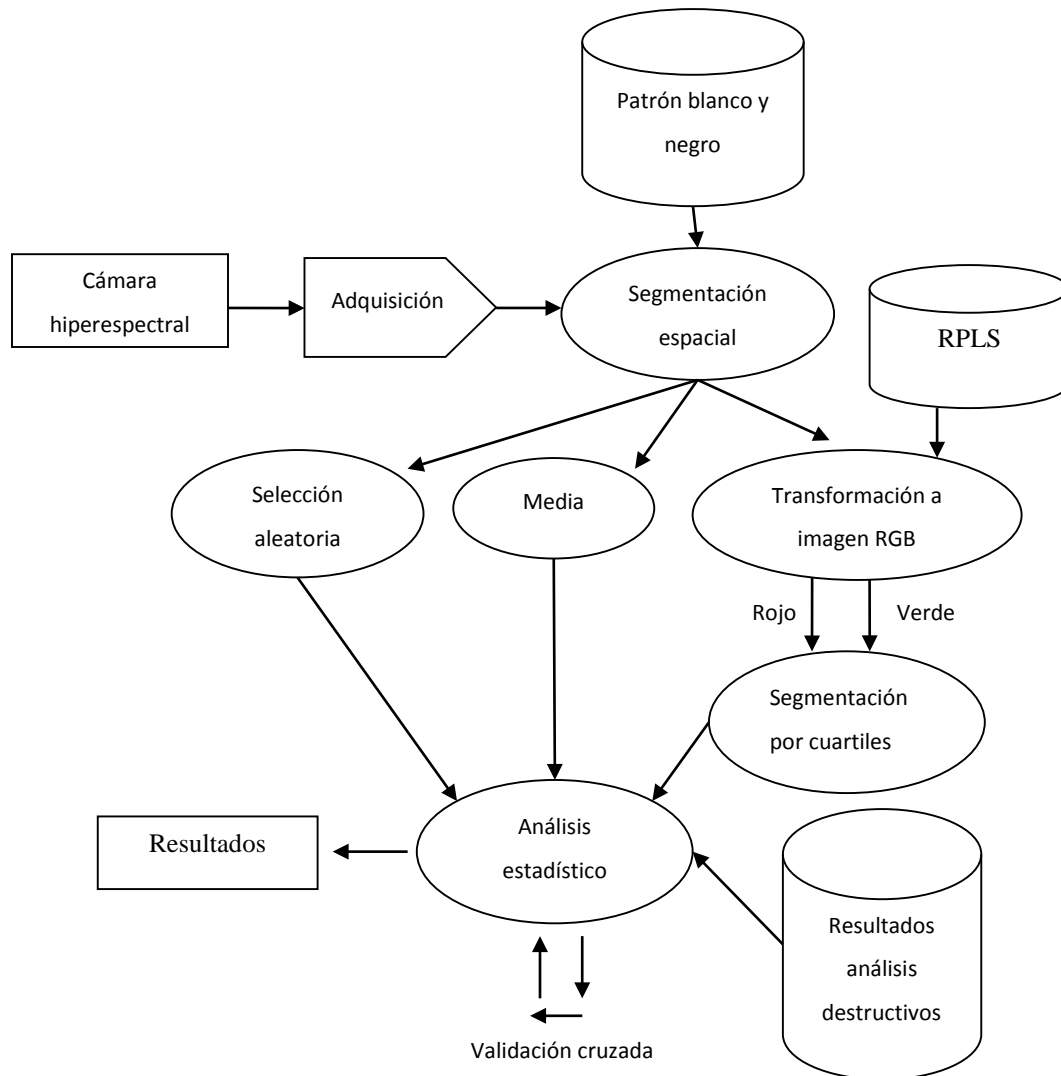
6.- Caso práctico: detección de caducidad en salmón ahumado

6.1.- Descripción del estudio

El estudio se llevó a cabo con 30 muestras de salmón ahumado en su envase comercial. Las muestras eran de 3 marcas comerciales distintas, 10 de cada, pero con la misma fecha de caducidad (para establecer un parámetro inicial de frescura). Cada muestra se dividió en 3 y fue reenvasado al vacío en condiciones asépticas, obteniendo de esta forma 90 muestras. Se adquirió imagen en los días 0, 10, 20, 40 (fecha de caducidad del fabricante) y a los 60 días (para asegurar vida útil del producto). Los análisis destructivos se hicieron a los días 0, 20, 40 y 60. En cada fecha de adquisición, se utilizaron 15 muestras. Las imágenes fueron adquiridas antes de abrir el envase. Después de abrir los paquetes asépticamente, se extrajo una muestra representativa para el análisis microbiano. Tras esto, las muestras restantes de los paquetes sin abrir fueron usadas para análisis posteriores. Durante el estudio, las muestras fueron almacenadas a 4 °C.

En el esquema 4.2 se muestra un diagrama de la técnica empleada para detectar salmón caducado desde la adquisición hasta la obtención de resultados. Cada paso se detalla en las siguientes subsecciones.

6.- Caso práctico: detección de caducidad en salmón ahumado



Esquema 4.2: Diagrama esquemático simplificado de las distintas fases de la técnica utilizada para detectar salmón caducado.

6.2.- Análisis destructivo

Los análisis destructivos realizados fueron los mismos que en las dos experiencias anteriores (3.2 - 3.3) a excepción de los nucleótidos que no se realizaron. Por lo tanto, los análisis que se efectuaron para conocer el estado del salmón fueron: x_w , a_w , ph , $TVB-N$ y el cultivo de microorganismos. Todos los análisis destructivos se realizaron por triplicado después de la trituración y homogeneización de las muestras.

6.3.- Equipo hiperespectral utilizado y condiciones de adquisición

El equipo empleado y las condiciones de adquisición fueron las mismas que para las experiencias 3.2 y 3.3 tal y como se puede observar en la figura 4.13. La cámara hiperespectral se montó sobre una cinta transportadora para que fuera capaz de escanear las muestras enteras línea a línea. La cinta transportadora estaba controlada con un controlador de motor de velocidad ajustable Altivar31 (Schneider Electric Rueil-Malmaison, France).




Figura 4.13 Sistema de adquisición hiperespectral

6.4.- Segmentación espacial

Debido a la gran cantidad de información que tienen las imágenes hiperespectrales se probaron tres tipos diferentes de filtros para reducir la cantidad de datos. Además, el salmón tiene diferentes tipos de tejidos (magro y grasa) con espectros muy diferenciados que requieren una segmentación espacial previa para no mezclarlos. Estos tres filtros fueron: selección aleatoria de píxeles, una media espacial y un filtro avanzado basado en color que es el que se explicará en detalle a continuación. Este filtro avanzado se basa en desarrollar un modelo de color capaz de transformar la imagen hiperespectral a una imagen en el espacio de color RGB en el visible donde ya se puedan aplicar las técnicas de segmentación tradicionales.

6.4.1.- Modelo de color

Existen diferentes formas de transformar una imagen hiperespectral a un espacio de color típico de imágenes 2D como el RGB mediante el uso de solo las longitudes de onda del espectro visible [400:700] nm. Una de ellas es usar las funciones estándar de transformación establecidas por la comisión internacional de iluminación como CIE 1931 o CIE 1964 (Wyszecki, 2000). Sin embargo, este método requiere de una calibración espectral muy precisa para aplicar cada función de color de forma correcta. Otra manera de realizar la transformación es conociendo la curva de respuesta específica del sensor CMOS de la cámara a cada color, el espectro del sistema de iluminación y el modelo físico de cómo afecta los prismas y ópticas del filtro a la luz. Si se tiene toda la información facilitada por los fabricantes es posible realizarlo, sin embargo, se ha optado por utilizar una tercera vía. El método utilizado en esta tesis se basa en emplear una aproximación de “caja negra” como la empleada por (Nyström, 2007) donde se calcula un modelo RGB de forma empírica sin necesidad de una calibración espectral precisa.

La caracterización empírica del sistema hiperespectral se realizó adquiriendo 215 imágenes hiperespectrales de un patrón RGB impreso en un folio A3 (figura 4.14) de forma continua. Se desarrolló un programa para asignar el valor conocido RGB extraído de la versión digital del

patrón a cada imagen hiperespectral. Tras la calibración del equipo (sección 2.2), se realizó una media espacial de 280 píxeles para cada fila de color incluyendo la fila de blanco-negro de forma que se correló 860 (215 x 4) espectros con sus valores RGB. Se utilizó una regresión por mínimos parciales en su versión robusta (RPLS) (Hubert & Branden, 2003) para construir el modelo matemático.




Figura 4.14: Patrón RGB usado para crear el modelo de color

Con el propósito de testear este modelo se escaneó otro patrón de color con colores que no se usaron en el modelo RGB construido (figura 4.15a). La figura 4.15b muestra el resultado del patrón reconstruido ($R^2=0.912$) que se obtuvo usando 4 variables latentes.




Figura 4.15: Patrón RGB usado para testear el modelo de color (a) y su resultado (b)

6.4.2.- Segmentación basada en RGB

Una vez se transformaron las imágenes hiperespectrales al espacio de color RGB mediante el modelo de color anterior, se realizó una segmentación basada en dos pasos: Primero, se eliminó el fondo y los reflejos utilizando para ello una segmentación por intensidades con umbrales fijos. Y segundo, se dividió la imagen en 4 cuartiles (Q) usando primero los niveles del canal rojo y luego los del canal verde.

El objetivo de dividir la imagen en cuartiles es detectar los píxeles con valores de intensidad parecidos en los canales rojo y verde que pertenecen a los mismos tejidos (Sánchez, Albarracín, Grau, Ricolfe, & Barat, 2008b).

El canal azul no se estudió porque proporciona la misma información que el canal verde para esta aplicación. Además, se decidió dividir las intensidades en cuatro cuartiles porque se demostró experimentalmente que hasta el 25% de los píxeles pueden ser tejidos oscuros (Q1) y hasta otro 25% pueden ser tejidos claros (Q4).

El primer paso de la segmentación se realizó porque las muestras estaban empaquetadas con un film transparente, que aunque no afecta en general a la respuesta espectral como se demostró en la sección 3.35, sí puede producir reflejos. Este paso se realizó con dos umbrales fijos obtenidos experimentalmente considerando que por debajo del umbral inferior son píxeles de fondo y por encima del superior son píxeles de reflejos.

Para el segundo paso, los cuartiles fueron calculados usando tres umbrales adaptativos. En la figura 4.16 se muestra un histograma donde estos umbrales (T1, T2 y T3) se pueden observar junto a los cuatro cuartiles (Q1, Q2, Q3 y Q4) en los que se divide los valores de intensidades. El umbral T1 se calcula como la mediana de los valores de intensidades del canal rojo de los píxeles que quedan después del primer paso (la eliminación de fondo y reflejos). El segundo y tercer umbrales son ambos también la mediana pero de los píxeles por debajo de T1 para el

segundo y por encima de T1 para el tercero. De esta forma se divide la imagen en cuatro cuartiles utilizando estos umbrales. Este segundo paso se repite también empleando el canal verde en vez del rojo obteniendo así otros cuatro cuartiles. Se realizó un análisis estadístico de los espectros resultantes de los píxeles de estos cuatro cuartiles (por canal) y sus combinaciones con el objetivo de obtener la mejor detección de frescura posible.




Figura 4.16 Ejemplo de histograma dividido en cuatro cuartiles para el canal rojo.

6.5.- Resultados imagen hiperespectral

Las muestras se dividieron en dos grupos en base a los resultados de los análisis destructivos: no caducados (días 0, 10 y 20) y caducados (días 40 y 60). A pesar de que las muestras a los 40 días se encontraban en el límite legal atendiendo a los análisis destructivos, se decidieron poner en el grupo de las caducadas con el objetivo de garantizar la seguridad de las muestras.

En una primera aproximación, como se ha dicho en el apartado de segmentación espacial, se realizó un modelo PLS-DA utilizando para ello 62 píxeles (px) seleccionados aleatoriamente para cada una de las muestras. Se decidió utilizar 62 píxeles por problemas de memoria debido a la cantidad de información a tratar. Los bajos resultados de validación cruzada que se obtuvieron usando esta técnica ($R^2C=0.37$; $R^2CV=0.30$) pueden verse en la figura 4.17.

6.- Caso práctico: detección de caducidad en salmón ahumado

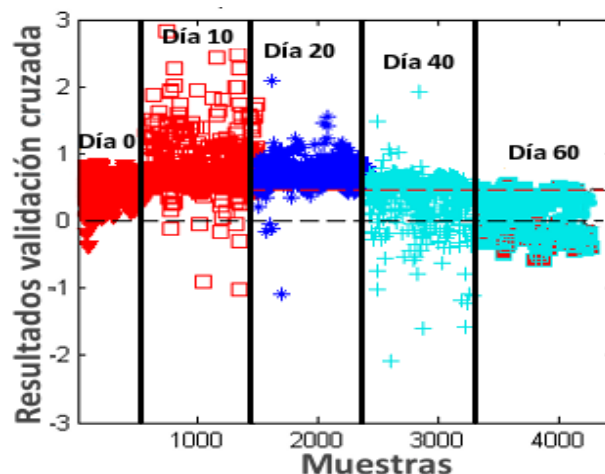


Figura 4.17: Resultados PLS-DA usando segmentación aleatoria

El ruido y el hecho de mezclar píxeles de diferentes tejidos provocaron que las muestras tuvieran una gran dispersión y que, por tanto, no se pudiera construir un buen discriminante. Es por ello que se justifica la necesidad de realizar una segmentación espacial adecuada.

La segunda aproximación utilizada fue usar un filtro básico y rápido a los datos antes de hacer el modelo PLS-DA. En este caso se probaron la media y la mediana espacial para todos los píxeles de cada muestra. La tabla 4.5 muestra los resultados de R^2C y R^2CV así como los errores RMSE usando la media y la mediana como filtros. Se trata de una gran mejora respecto a utilizar píxeles aleatorios pero los valores de R^2CV sugieren que aún existe ruido en el modelo por lo que se realizó una tercera aproximación.

Tabla 4.5 Resultados estadísticos del modelo PLS-DA para discriminar muestras caducadas usando como segmentación espacial la media y la mediana.

	R^2Cal	R^2CV	RMSEC	RMSECV	NºLV
Media	0.926	0.797	0.136	0.253	12
Mediana	0.973	0.769	0.081	0.244	12

En la última aproximación, la segmentación espacial que se realizó fue basada en el color de las imágenes RGB reconstruidas. Para corroborar el buen funcionamiento del equipo y del modelo de reconstrucción de imagen RGB se escaneó un salmón entero con una resolución de 216 imágenes hiperespectrales. Usando el modelo RPLS desarrollado, explicado en la sección 3.4.4.1, se obtuvo una imagen RGB reconstruida de la muestra. Con el objetivo de reducir el ruido y mejorar el contraste visual entre diferentes tejidos (Cláudio Rosito, 2007; Jackman, Sun, Du, & Allen, 2009; Joo Kim, Deng, & Brown, 2011) se aplicó una mejora de color basada en formas fundamentales multiescala (MFF) (Scheunders, 2002). Esta MFF consiste en usar una transformada de ondas de Mallat (Mallat & Zhong, 1992). Se utilizó un nivel de detalle de 4 para la MFF, al ser un valor compromiso entre incrementar el detalle y reducir el ruido. La imagen mejorada reconstruida se muestra en la figura 4.18b. Debido a los métodos para mejorar el contraste entre las diferentes partes del pescado, los colores entre las figuras 4.18a que fue adquirida con una cámara RGB y la figura 4.18b, que se trata de la imagen reconstruida, fueron diferentes. Además, los ruidos tales como los reflejos debidos al film, fueron eliminados (agujeros negros en la figura 4.18b).




Figura 4.18: a) Fotografía de una muestra de salmón ahumado empaquetada b) Imagen RGB reconstruida usando el modelo de color desarrollado y mejorada por la transformada de ondas de Mallat.

Los resultados del estudio estadístico para los cuatro cuartiles en los canales rojo y verde para todas las muestras se exponen en la tabla 4.6. Los mejores resultados obtenidos fueron utilizando el canal verde. Esto puede ser debido al hecho de que los diferentes tejidos del salmón se diferencian mejor en este canal (Stien, Kiessling, & Manne, 2007) mientras que en el canal rojo dentro de un mismo cuartil se mezclan diferentes tipos de tejidos. Esto es debido a

6.- Caso práctico: detección de caducidad en salmón ahumado

que tanto la grasa como el magro tiene valores más próximos en el canal rojo que en el verde como se puede observar en la figura 4.19. En la figura 4.19b se muestran los perfiles de intensidad de los canales rojo y verde de la línea azul de la figura 4.19a. Como se puede observar la línea 4.19b verde presenta mayores picos que la línea roja que corresponde a las vetas de grasa del salmón.

Tabla 4.6 Resultados estadísticos de los modelos PLS-DA para el salmón envasado basado en los valores segmentados usando los canales rojos y verdes.

	Canal rojo				Canal verde			
	Q1	Q2	Q3	Q4	Q1	Q2	Q3	Q4
R ² Cal	0.726	0.632	0.757	0.746	0.814	0.907	0.736	0.725
R ² CV	0.506	0.464	0.675	0.300	0.726	0.800	0.537	0.288
RMSEC	0.260	0.302	0.246	0.251	0.215	0.152	0.256	0.261
RMSECV	0.396	0.377	0.289	0.572	0.284	0.228	0.367	0.537
N ^o LV	7	6	6	9	9	7	10	9

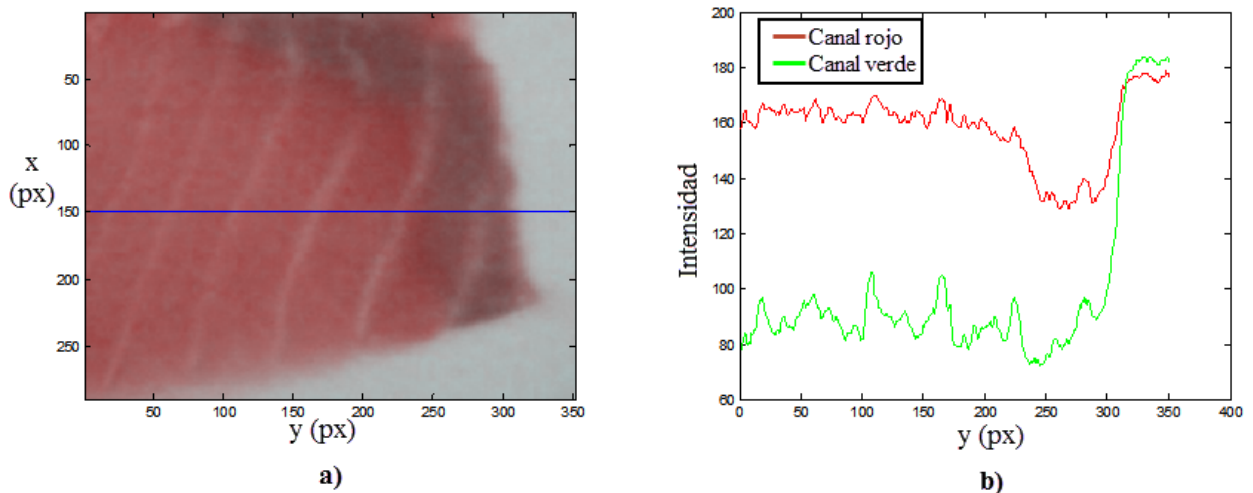


Figura 4.19: a) Fotografía de una muestra de salmón ahumado empaquetada b) Perfiles de intensidad correspondientes a la línea azul de la figura a) para el canal rojo y verde.

Capítulo 4: Aportaciones técnicas hiperespectrales

El mejor cuartil para discriminar si las muestras están caducadas o no fue el Q2 ($R^2C= 0.907$; $R^2CV = 0.80$). Este cuartil está compuesto de píxeles con intensidades relacionadas principalmente al tejido magro como se puede observar en la figura 4.20C. Pero además, si se le añade el cuartil Q3, los resultados mejoran hasta ($R^2C= 0.97$; $R^2CV = 0.83$, $RMSEC: 0.08$, $RMSECV: 0.21$) tal y como se refleja en la figura 4.21. Esto confirma la suposición realizada de que al menos el 50% de píxeles (píxeles entre T2 y T3) están libres de ruido. La diferencia entre realizar una segmentación espacial inteligente y no realizar ninguna resulta evidente al comparar las figuras 4.17 y 4.21.




Figura 4.20: Píxeles seleccionados por el modelo de color en cada cuartil. a) Fotografía de una muestra de salmón ahumado empaquetada; b) Área negra=Q1; c) Área roja=Q2; d) Área blanca=Q3; e) Área negra=Q4




Figura 4.21: Píxeles seleccionados por el modelo de color en cada cuartil. a) Fotografía de una muestra de salmón ahumado empaquetada; b) Área negra=Q1; c) Área roja=Q2; d) Área blanca=Q3; e) Área negra=Q4

La línea roja, en las figuras 4.17 y 4.21, es el umbral calculado con el teorema de Bayes a partir de los datos para minimizar el error total. Este cálculo se basa en la suposición que los

valores predichos para una clase se distribuyen de acuerdo a una distribución normal. La dispersión de los datos se redujo para todos los tiempos pero especialmente para los días 40 y 60. Como resultado, esto garantiza la seguridad de las muestras puesto que ninguna muestra en mal estado fue clasificada como segura.

Se puede concluir también que los resultados obtenidos con esta última aproximación ofrecen mayores garantías de que la información usada para realizar los modelos PLS-DA es más precisa y sin ruido, lo cual puede ser especialmente importante en un producto como el salmón que presenta tejidos muy diferenciados.

6.6.- Conclusiones

Este estudio se enfocó en resolver el importante problema de detectar salmón ahumado y empaquetado en mal estado de una forma no-destructiva. Las imágenes hiperespectrales en el rango del infrarrojo cercano de onda corta demostraron que disponen de suficiente información y cumplen los requisitos necesarios para esta aplicación. Sin embargo, estas imágenes presentan ruido que tiene que ser filtrado con la dificultad añadida de que el salmón presenta diferentes tejidos que tienen que ser tenidos en cuenta. Así pues, es necesario usar un filtro adecuado para conseguir resultados fiables. Los resultados experimentales comparando tres tipos de filtros (selección de píxeles aleatorios, media y mediana y segmentación por modelo de color) usando modelos PLS-DA demostraron que el filtro avanzado propuesto, basado en color, presentó los mejores de R^2 en validación cruzada (82.7%). El resultado obtenido demuestra que el sistema desarrollado puede ser muy prometedor para resolver el problema propuesto.

Como trabajo futuro, se planea trabajar en una segmentación de tejidos más precisa mediante análisis de texturas basadas en detección de bordes (Xiaohan, Ylä-Jääski, & Baozong, 1991) y redes neuronales (Verikas, Malmqvist, & Bergman, 1997). Otra posibilidad para mejorar

los resultados es realizar una selección de variables que no solo reduce la información sino que además puede mejorar los resultados (Grau et al., 2011b). La posibilidad de extender este estudio a otros alimentos con diferentes tejidos también se está considerando.

6.7.- Aportaciones del estudio

Además de demostrar la viabilidad de la técnica para discriminar entre salmones caducados y no caducados, la importancia de este estudio radica en que se trata de un alimento no homogéneo y por tanto requiere de una fase de segmentación espacial significativa. Se ha demostrado experimentalmente con este estudio que es necesario realizar un filtro espacial para tener una señal utilizable y fiable. De los filtros empleados se ha concluido que como mínimo hay que utilizar un filtro básico como el de media y mediana pero que, aunque son adecuados para alimentos homogéneos, para alimentos con tejidos diferentes se consiguen mejores resultados al utilizar filtros más avanzados. En este estudio se ha empleado un filtro basado en un modelo de color desarrollado que transforma la imagen hiperespectral a una imagen 2D en el espacio de color RGB. El transformar la imagen hiperespectral a una imagen clásica 2D en color presenta muchas ventajas entre las cuales destaca el poder emplear cualquiera de las muchas técnicas existentes en 2D, el que un experto en alimentación pueda segmentar los tejidos de forma manual en la imagen y entrenar así un modelo de clasificación o el poder obtener el espectro de un punto específico del alimento. Al igual que en el estudio anterior se ha trabajado sobre muestras en envases comerciales sin ningún tipo de manipulación, lo que reafirma lo apropiada que resulta la técnica hiperespectral para el sector de la alimentación.

Este estudio se podría considerar como una ampliación a la experiencia anterior que extiende la posibilidad de utilizar esta técnica a alimentos con diferentes tejidos. Como resultado de este estudio se ha publicado el siguiente artículo en revista indexada (Eugenio Ivorra et al., 2013).

Capítulo 5: Aportaciones de la combinación de técnicas 3D e hiperespectrales

1.- Introducción

Existen plataformas de sensores comerciales que incorporan gran variedad de sistemas de visión como dispositivos hiperespectrales, cámaras de visión en color y sensores tridimensionales. Sin embargo, la mayoría de estas plataformas tratan la información de los sensores por separado. Un ejemplo es la plataforma de sensores “BreedVision” (Busemeyer et al., 2013) que se utiliza para el estudio del fenotipo de cereales en el campo (figura 5.1). En la última década, se ha empezado a fusionar información de sensores tridimensionales con sensores hiperespectrales para aprovechar al máximo ambas tecnologías. Estas combinaciones se han usado principalmente para estudiar la distribución de biomasa de vegetación (Mundt, Streutker, & Glenn, 2006) o para la clasificación de árboles (Naidoo, Cho, Mathieu, & Asner, 2012) desde dispositivos de reconocimiento aéreo.

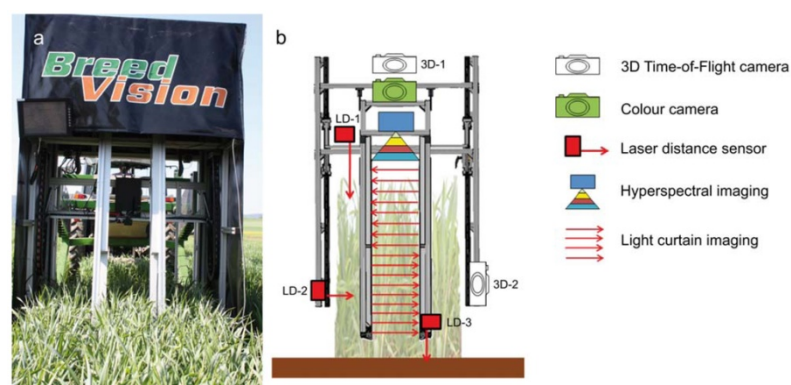


Figura 5.1: a) Plataforma de sensores BreedVision b) Esquema de los sensores montados. (Busemeyer et al., 2013)

Otro campo en el que se realiza esta combinación de tecnologías es en la geología para el estudio de afloramientos de minerales (Kurz, Buckley, Howell, & Schneider, 2008; Buckley, Kurz,

Howell, & Schneider, 2013). En estos estudios se realiza la fusión de datos usando láseres LIDAR de tiempo de vuelo con sensores hiperespectrales, sin embargo, esta fusión se puede también realizar con otro tipo de sensores tridimensionales como demuestra la combinación de una cámara estéreo con una cámara hiperespectral para el estudio de heridas superficiales (Paluchowski, Denstedt, Røren, Pukstad, & Randeberg, 2013).

Actualmente, no conozco ningún otro estudio en el campo de la alimentación que aúne información tridimensional con hiperespectral. En este capítulo se van a exponer dos casos prácticos donde se utilizan ambas informaciones. En el primer caso práctico la información tridimensional se utilizó para caracterizar las muestras conjuntamente a los análisis físico-químicos y cuyos resultados luego fueron usados para modelar la información espectral. En el segundo caso, la información tridimensional se emplea en la fase de la segmentación espacial para utilizar únicamente el espectro de las regiones de interés de las muestras.

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales

2.1.-Descripción del estudio

El estudio se llevó a cabo en 6 lotes diferentes de harina de trigo vendidas como “harina fuerte” empleadas para productos de panadería obtenidas de un productor local (Molí del Picó-Harinas Segura S.L, Valencia-Spain). Las harinas se obtuvieron durante 6 semanas (B1, B2, B3, B4, B5 y B6). El estudio se compone de dos fases, una en la que se caracteriza las masas mediante el análisis reológico y mediante los parámetros de comportamiento dinámico obtenidos por un sistema 3D de luz estructurada y otra en la que se caracterizan las harinas mediante la adquisición de imágenes hiperespectrales. Finalmente se realizó una correlación de los resultados obtenidos.

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperspectrales

Tabla 5.1 Esquema del estudio realizado

Fases	Características	Análisis estadístico	Muestras					
1	Análisis reológico	ANOVA	B1	B2	B3	B4	B5	B6
	Análisis 3D (SL)							
2	Imagen hiperspectral	PCA						
1 y 2		PLS						

2.2.- Preparación de la masa y del proceso de fermentación

Los ingredientes empleados con sus respectivos porcentajes fueron:

- 56% Harina de trigo.
- 35% Agua.
- 2% aceite refinado de girasol (Acidez máxima de 0.2 ° Koipesol Semillas S.L, España).
- 2% Levadura comercial (*Saccharomyces cerevisiae*, Lesafre Ibérica S.A , España).
- 4% Azúcar blanco (≥ 99.8 % of sacarose. Azucarera Ebro S.L ,España).
- 1.5% NaCl (sal marina refinada ≥ 97 % NaCl. Salinera Española, S.A , España).

Las masas panarias se realizaron mezclando todos los ingredientes en un mezclador de alimentos (Thermomix® TM31, Vorwerk, Alemania) de acuerdo al siguiente método. En primer lugar los componentes líquidos (agua y aceite), azúcar y la sal se mezclaron durante 4 minutos a 37 °C. La levadura se añadió a continuación y se repitió el mezclado 30 segundos más. Finalmente, se añadió la harina con el resto de ingredientes y se utilizó el programa de amasado del dispositivo para conseguir una masa homogénea. El programa se basa en el mezclado de los ingredientes con cambios aleatorios del sentido de la rotación de las hélices de mezclado (550 revoluciones por minuto). Este programa estuvo en funcionamiento durante 4.5

minutos a 37 °C. A continuación, se colocó 450g de masa en un molde de metal (8x8x30cm) para el proceso de fermentación con un grosor aproximado de 1 cm. La fermentación se realizó en una cámara climática (KBF720, Binder, Tuttlingen, Alemania), que mantuvo la humedad relativa a 90% y la temperatura a 37 °C. El proceso de fermentación duró hasta que las masas perdieron su estabilidad y tamaño (Ft) que es el momento en que colapsaron durante el crecimiento.

2.3.- Análisis reológicos

Los análisis reológicos efectuados se basaron en el análisis de las masas mediante alveógrafos, obteniéndose los alveogramas y los parámetros que de él se extraen en función a la normativa expresada por la International Association for Cereals Science and Technology (ICC standard No.121). Los parámetros obtenidos fueron: P (máxima presión (mm)), L=extensibilidad (mm) y W=fuerza (J⁻⁴).

2.4.- Sistema de adquisición hiperespectral

El sistema de adquisición hiperespectral que se utilizó fue una cámara CMOS Photonfocus MV1-D1312 40gb 12 (Photonfocus AG, Lachen, Suiza) y un filtro SpecimImSpector V10 1/2" (Specim Spectral Imaging, LTD., Oulu, Finlandia) que funcionan como una cámara hiperespectral lineal en el rango del SW-NIR. Se utilizó un sistema de iluminación estable a lo largo de todo el espectro de trabajo mediante el foco comercial ASD illuminator (ASD Inc, Boulder, EE. UU) (figura 5.2).

La posición relativa de la iluminación y la cámara respecto a las muestras permaneció constante para preservar las condiciones de adquisición a lo largo del estudio. La distancia entre el foco y la muestra fue de 0.525m para asegurar que no modificara la temperatura de la misma. La cámara se encontraba a una distancia de 0.225m respecto a la muestra. La imagen obtenida se compone de 256 niveles de gris (8 bits). El espectro obtenido por reflectancia tiene

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales

un rango de 400 a 1000 nm divididos en 53 valores lo que resulta en una resolución de 11.2 nm. La resolución espacial fue de 1312 píxeles que unido a la distancia de trabajo que se utilizó da una resolución espacial de 1 píxel/mm.




Figura 5.2 Sistema de adquisición hiperespectral

Las muestras se colocaron en una placa de Petri de vidrio de 10 cm de diámetro y el espectro se adquirió a temperatura ambiente (21°C). No se realizó ningún tipo de preparación de la muestra.

Se controló la cámara mediante un programa propio desarrollado en el lenguaje C++ utilizando el entorno de desarrollo proporcionado por Photonfocus.

2.5.- Sistema de adquisición tridimensional

El objetivo del sistema de adquisición tridimensional es obtener los perfiles 3D de las muestras durante la fermentación. Para ello se empleó un sistema tridimensional por luz estructurada desarrollado específicamente para ello compuesto por una cámara de grises In-Sight 5100 (Cognex, Boston, Massachusetts EEUU) y un láser rojo lineal Lasiris SNF 410, (Coherent Inc. Santa Clara, California, EEUU), ambos montados dentro de la cámara de fermentación en las posiciones mostradas en la figura 5.3. Aunque la cámara tiene un índice de protección 67 (IP67) y el láser es lo suficiente robusto para trabajar en las condiciones de la cámara de fermentación, se decidió colocarlos dentro de dos recipientes cúbicos de polietileno de alta densidad, con uno de los lados de vidrio, diseñados específicamente para aportar una mayor seguridad al equipo y un entorno más higiénico.

El sistema tiene una resolución de $2.1 \cdot 10^{-4} \text{m}$ y $1.4 \cdot 10^{-4} \text{m}$ para los ejes X y Z respectivamente. Esta resolución proviene del ángulo β de 0.65 radianes en combinación con la resolución de la cámara 640 x 480 y su distancia a la muestra. El rango de trabajo del equipo fue de 0.1m en el eje X y de 0.08m en el eje Z. La calibración del equipo y el procesado de imagen se realizó con el mismo procedimiento explicado en la sección 2.3 del capítulo 3 que recordemos consistía en calibrar los parámetros intrínsecos de la cámara, calcular la homografía entre el plano de imagen y el plano del láser, en segmentar la línea proyectada del láser en la imagen y en convertir de coordenadas de píxel a coordenadas 3D utilizando la homografía previamente calculada. La frecuencia de adquisición fue de una imagen por segundo debido al largo periodo de tiempo que requiere la fermentación (alrededor de dos horas).

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperspectrales




Figura 5.3 Sistema 3D montado en la cámara de fermentación

Se extrajo la siguiente información de forma continua de los perfiles 3D a lo largo del tiempo con el propósito de analizar el crecimiento de las muestras durante la fermentación:

- Área transversal (A): La integración de las alturas Z a lo largo de la dirección X de la muestra.
- Instante de máxima área transversal (Ft): Momento en que se alcanza la máxima A .

Además, para modelar el comportamiento temporal, la información proveniente del 3D se ajustó a modelos de predicción de Gompertz. Este modelo es una función no-lineal sigmoide de crecimiento desarrollada por Gompertz en 1825 para el cálculo de la mortalidad de microorganismos. Esta función ha sido adaptada para el crecimiento de masas panarias dando como resultado la ecuación siguiente:

$$h(t) = M \exp \left(- \exp \left(\frac{V}{M} (Lt - t) + 1 \right) \right) \quad (5.1)$$

Donde t es el tiempo, M es el valor máximo de altura o área a lo largo del proceso, V es el crecimiento máximo y Lt es el tiempo de latencia antes del comienzo de crecimiento de la

masa. Los parámetros fueron calculados mediante una regresión no lineal minimizando la suma de los cuadrados de los errores de predicción.

La adquisición se realizó con un programa desarrollado en el entorno In-sight 3.4.2 (Cognex Corporation Boston, Massachusetts, Estados Unidos) mientras que la calibración y procesamiento de datos se realizó con código propio desarrollado en Matlab 2012b (The Mathworks, Natick, Massachusetts, Estados Unidos).

2.6.- Resultados

2.6.1.- Resultados del sistema tridimensional

En la figura 5.4 se puede ver un vídeo capturado por la cámara del sistema 3D donde se puede observar claramente el punto Ft en el que colapsó la masa panaria B1 debido a que no tiene la suficiente capacidad de retención de gases para soportar esas dimensiones.



Figura 5.4 Vídeo del sistema 3D del proceso de fermentación donde colapsa en el minuto 1.10 ([url=http://tinyurl.com/laqfrw7](http://tinyurl.com/laqfrw7))

La figura 5.5 es un ejemplo de la representación 3D de una masa panaria B1 que se obtuvo con el sistema tridimensional y que permite una interpretación más intuitiva.

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales




Figura 5.5 Representación 3D de la evolución de una masa panaria durante el proceso de fermentación

Como se puede observar en la figura 5.5 las harinas clasificadas como iguales por medio de análisis reológicos presentan un comportamiento muy diferente durante la fermentación pudiéndose clasificar en dos grupos: harinas débiles (B4, B6 y B1) y harinas fuertes (B2, B3 y B5). Cabe destacar que las harinas B2 y B5 fueron las que tuvieron comportamientos dinámicos más similares entre sí. Las harinas débiles presentaron áreas transversales (A) más pequeñas (alrededor de un 50% inferiores) debido a que tuvieron velocidades de crecimiento (C) similares en ambos grupos pero tiempos de fermentación más cortos (Ft).




Figura 5.6 Valor medio del área transversal (A) de 5 muestras de cada tipo de harina a lo largo del tiempo de

fermentación. B1 —; B2 —; B3 —; B4 —; B5 —; B6 —.

El análisis estadístico ANOVA de los parámetros reológicos no mostró ninguna diferencia estadística entre las diferentes harinas en estudio. El análisis de regresión lineal entre los análisis reológicos y los parámetros obtenidos del sistema tridimensional (tabla 5.2) no mostró valores de regresión que reflejasen una relación entre el comportamiento de las harinas (masas) durante su fermentación y las características reológicas evaluadas según las analíticas que habitualmente se realizan en la industria, si bien el parámetro P (tenacidad) fue el que en mayor medida ($R^2=0.79$) se relacionó con A (área) y Ft (tiempo máximo de fermentación).

Tabla 5.2 Coeficientes de correlación entre los análisis físico-químicos y los parámetros obtenidos del Sistema 3D.

	P	L	W	P/L
A	0.79	0.59	0.27	0.2
V	0.12	0.01	0.01	0.09
Lt	0.02	0.09	0.01	0.20
Ft	0.79	0.58	0.17	0.01

2.6.2.- Resultados imagen hiperespectral

Los espectros medios de los 6 tipos de harinas extraídos de las imágenes hiperespectrales se muestran en la figura 5.7. Fue posible distinguir diferentes zonas de actividad a lo largo de todo el espectro puesto que tanto en el visible como en la zona del infrarrojo cercano existieron picos con información relevante sobre las muestras. En base a esos resultados se decidió analizar todas las longitudes de onda tanto del visible como del infrarrojo. Sin embargo, tal y como se puede observar en la figura 5.7 en la longitud de onda de 900 nm del infrarrojo cercano es posible diferenciar muy bien los grupos formados en base a los parámetros tridimensionales.

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales

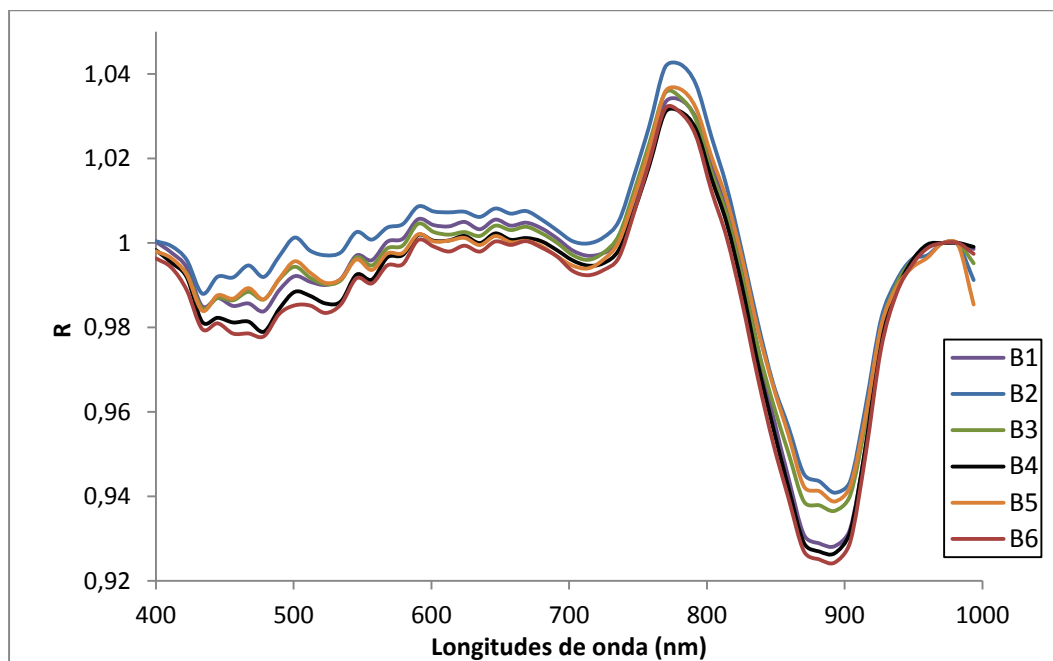


Figura 5.7 Media de los espectros de los 6 tipos de harinas.

Los espectros, se preprocesaron mediante una estandarización normalizada de la variabilidad, se estudiaron mediante un análisis de componentes principales. Los resultados de este estudio con 9 componentes principales y que recogen el 95,6% de la varianza se muestran en la figura 5.8. Utilizando los dos primeros componentes y en especial el segundo (PC2), se vio una tendencia de agrupación. Esta tendencia mostró como las diferentes harinas se posicionaron en zonas coherentes con los comportamientos en fermentación que tuvieron. En primer lugar, se observó como B2 y B5 se colocaron en zonas positivas de PC2. En segundo lugar, B4 y B6 se aislaron en la zona negativa de PC2. Por lo que respecta a B1 y B3, ambas se colocaron en la zona intermedia sin diferencias significativas respecto a las otras harinas. Aunque B1 y B3 no se agruparon estadísticamente con sus correspondientes grupos, es posible ver que presentan una tendencia de agrupación correcta, acercándose por un lado B1 más a la zona de B4 y B6 y por el otro lado B3 a la zona de B2 y B5. Las harinas con valores menores de A y Ft (B4 y B6) se agruparon en zonas diferentes que las harinas con valores superiores (B2 y B5) mientras que las harinas con valores intermedios (B1 y B3) se posicionaron entre ambas zonas.




Figura 5.8 Valores de los dos componentes principales de un modelo PCA para los 6 tipos de harinas.

Con el objetivo de relacionar el espectro SW-NIR de las harinas con el comportamiento durante la fermentación se realizó una regresión de mínimos cuadrados PLS con los parámetros reológicos y los del sistema tridimensional. La validación cruzada se realizó por el método de muestreo ciego veneciano. Se usó el número de variables latentes que minimizaba el error cuadrático de predicción con el propósito de evitar un modelo centrado exclusivamente en las muestras usadas para hacer el modelo y perder poder de predicción. Los resultados de estos análisis se muestran en la tabla 5.3.

El parámetro reológico más relacionados con el espectro fue la tenacidad ($R^2_{CV}= 0.79$), siendo los parámetros A y Ft, obtenidos mediante el análisis 3D los que mayor correlación mostraron ($R^2_{CV}=0.88$ y 0.9 , respectivamente). La relación existente entre la información procedente del espectro y la obtenida mediante la técnica de imagen 3D se muestra en la figura 5.9. en la que se ha representado el valor promedio de la PC2, para cada una de las harinas, con los valores de A y de Ft de cada una de ellas. Como se puede apreciar, existió una linealidad

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales

para ambos parámetros que reflejaría la correlación existente entre el comportamiento de la harina (masa) durante su fermentado y el espectro obtenido para cada una de ellas.

Tabla 5.3. Resultados análisis PLS del espectro SW-NIR de las harinas y los parámetros físico-químicos y del sistema tridimensional.

Parámetros	LV	Calibración		Validación cruzada	
		R ² cal	RMSEC	R ² CV	RMSECV
P	4	0.86	0.28	0.79	0.34
L	4	0.66	0.53	0.49	0.65
W	4	0.24	3.56	0.24	4.45
P/L	4	0.12	3.56	0.13	0.01
A	4	0.89	1.02	0.88	1.17
V	1	0.03	0.03	0.01	0.26
Lt	2	0.66	0.16	0.62	0.17
Ft	4	0.93	8.65	0.90	1.52




Figura 5.9 Relación entre los promedios de los valores de la componente 2 del análisis de PCA hecho con la información procedente de los espectros y los valores de área máxima (A) y tiempo en la que se obtiene (Ft) obtenidos mediante la técnica 3d..

Los resultados han demostrado que existe una relación entre el espectro y el comportamiento en fermentación de las harinas y esta relación puede ser debida

principalmente a la cantidad de gluten y a la de sus proteínas derivadas presentes en las harinas, las cuales también influirían directamente en los parámetros A y Ft (Barak, Mudgil, & Khatkar, 2013). Así otros autores (Sinelli, Cerretani, Egidio, Bendini, & Casiraghi, 2010) han informado que es posible predecir la cantidad de gluten en el rango del infrarrojo cercano (830-2700 nm). En este estudio se analizó hasta los 1000 nm pero analizando el espectro se puede ver un pico importante entorno a los 800-900 nm que presuntamente estaría relacionado con la cantidad de gluten y confirmaría los resultados de (Z.-P. Chen, Morris, & Martin, 2006).

2.7.- Conclusiones

En este trabajo se estableció una alta correlación entre el espectro en el rango del visible y del infrarrojo cercano entre harinas supuestamente iguales (basándose en los análisis oficiales de calidad) y su posterior comportamiento durante la fermentación.

Las diferencias observadas entre los espectros, las cuales podrían ser atribuidas a diferencias en las cantidades de gluten, fueron correlacionadas mediante análisis multivariable de componentes principales con los parámetros de fermentación, tanto reológicos como los obtenidos mediante el análisis de imagen 3D basado en la luz estructurada. Así tanto el área total, que describe una sección de la masa durante la fermentación, como el tiempo final al que se alcanza ésta (ambos parámetros obtenidos mediante la técnica 3D) fueron los que presentaron una mayor correlación.

Basándose en estos resultados, el análisis hiperespectral, en el rango del visible y del infrarrojo cercano, se podría usar como una herramienta muy útil para predecir a priori el comportamiento que tendrán las harinas de trigo durante el proceso de fermentación.

2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales

Como trabajo futuro, se planea ampliar el número de muestras y variedades de harinas con el objetivo de obtener modelos de predicción más robustos capaces de ser implementados en entornos industriales de producción de pan. Otro estudio que se pretende realizar es la modificación de los parámetros de la cámara climática y de la duración del proceso de fermentación basándose en los resultados hiperespectrales de las harinas con el objetivo de optimizar los resultados del proceso.

2.8.- Aportaciones del estudio

En este estudio se utilizó un sistema tridimensional por luz estructurada desarrollado específicamente para caracterizar harinas durante el procesado de fermentación. La importancia de este estudio es que harinas que tienen comportamientos diferentes durante la fermentación pero que son iguales reológicamente fueron diferenciadas mediante una técnica hiperespectral. Pero no solo esto, sino que los espectros de las harinas se relacionaron directamente con la caracterización realizada por el sistema tridimensional mediante un modelo PLS. Utilizando este modelo se puede predecir el comportamiento que tendrá una harina durante el proceso de fermentación y por tanto, ajustar de forma óptima los parámetros de la cámara climática o procesar solo harinas que vayan a tener un comportamiento semejante. Este estudio es un claro ejemplo del gran potencial que tienen utilizar técnicas hiperespectrales y tridimensionales conjuntamente en el sector alimentario.

3.- Caso práctico: estudio de frescura en sparus aurata usando técnicas hiperespectrales y segmentación 3D

3.1.-Descripción del estudio

El estudio se llevó a cabo en 24 muestras de sparus aurata (dorada) frescas adquiridas en un supermercado local. Para establecer un parámetro de frescura inicial se decidió elegir productos de diferentes lotes, pero con el mismo período de caducidad. Se adquirió imagen en los días 0, 1, 2, 3, 4, 5, 8, 9. Los análisis destructivos se hicieron los mismos días. En cada fecha de adquisición, se utilizaron 2 muestras para los análisis destructivos. Las muestras fueron escaneadas por ambas caras con el equipo hiperespectral y con el sistema adquisición tridimensional. Tras la adquisición de imágenes, las muestras eran almacenadas en bandejas de PVC tapadas con film y almacenadas en cámaras frigoríficas 4 °C.

3.2.- Análisis destructivos

Los análisis destructivos realizados para conocer el estado de las doradas fueron: PH, NTVB y el humor vítreo. Todos los análisis destructivos se realizaron por triplicado después de la trituración y homogeneización de las muestras excepto para el humor vítreo que se realizó extrayendo el humor vítreo de los ojos de las doradas.

3.3.- Equipo utilizado

El equipo que se utilizó consta de dos subsistemas (figura 5.10): por una parte el sistema de adquisición tridimensional por luz estructurada que aporta información espacial muy precisa y por otra el sistema de adquisición hiperespectral que proporciona información espectral. Ambos subsistemas estaban montados sobre una cinta transportadora Nikatrans NT130 (Nikai Systems S.L. Guadalajara, España) accionada por un motor de alterna Nord 71s/4 (Nord

3.- Caso práctico: estudio de frescura en *sparus aurata* usando técnicas hiperespectrales y segmentación 3D

Drivesystems S.L., Bargteheide, Alemania) y controlado por un variador de frecuencia Telemecanique altivar 31 (Schneider Electric, Rueil-Malmaison, Francia). La sincronización entre los dos sistemas y la cinta transportadora se realizó por medio de un encoder Wachendorff LMS WDG (Wachendorff Automation, Geisenheim, Alemania) y conociendo los parámetros extrínsecos de ambos sistemas.




Figura 5.10 Sistema de adquisición tridimensional e hiperespectral para el análisis de frescura de la dorada

3.3.1.- Sistema de adquisición hiperespectral

El sistema de adquisición hiperespectral que se utilizó fue una cámara CMOS Photonfocus MV1-D1312 40gb 12 (Photonfocus AG, Lachen, Suiza), un filtro SpecimImSpector V10 1/2" (Specim Spectral Imaging, LTD., Oulu, Finlandia) y un foco comercial ASD illuminator (ASD Inc, Boulder, EE. UU). El equipo fue el mismo que el explicado en la sección 2.4.

La posición relativa de la iluminación y la cámara respecto a las muestras permaneció constante para preservar las condiciones de adquisición a lo largo del estudio. La distancia

entre el foco y la muestra fue de 0.525 m para asegurar que no modificara la temperatura de la misma. La cámara se encontraba a una distancia de 0.225 m respecto a la muestra. Se adquirieron las imágenes a una temperatura ambiente constante de 21 °C.

Se controló la cámara mediante un programa propio desarrollado en el lenguaje C++ utilizando el entorno de desarrollo proporcionado por Photonfocus.

3.3.2.- Sistema de adquisición tridimensional

El sistema de adquisición tridimensional por luz estructurada utilizado fue una evolución del usado en la sección 3.2.3 con la diferencia de que en éste se emplearon dos láseres rojos lineales (Lasiris SNF 410, Coherent Inc. Santa Clara, California (USA)). Los láseres fueron colocados uno delante del otro a una distancia de 0.21 m con el propósito de reducir las zonas ocultas. Los láseres proyectaban dos líneas rectas paralelas sobre la cinta transportadora orientadas para que cada una de ellas se encontrara en una sola fila de la imagen de la cámara. La cámara era la AD-080CL (JAI Company, Yokohama, Kanagawa, Japón) situada a 0.35 m de la cinta transportadora. Las posiciones y orientaciones de la cámara y los láseres permanecieron constantes durante el estudio. Se escanearon las muestras completas gracias al movimiento constante de la cinta transportadora a una velocidad de $15 \cdot 10^{-4}$ m/s medida por el encoder. La calibración del sistema y el procesado de datos para obtener la información 3D se realizó de la misma forma que en la sección 3.2.3 para ambos láseres. En la figura 5.11 se puede ver un vídeo en el que aparece la reconstrucción 3D completa de una dorada y cuyo resultado final es el que aparece en la figura 5.12.

3.- Caso práctico: estudio de frescura en *sparus aurata* usando técnicas hiperespectrales y segmentación 3D



Figura 5.11 Vídeo de la adquisición y la reconstrucción 3D (url= <http://tinyurl.com/mjarf2b>)




Figura 5.12 Reconstrucción 3D de una dorada mediante el sistema 3D de luz estructurada



3.4.- Segmentación espacial mediante 3D

La segmentación espacial se puede realizar a partir de diferentes fuentes de información. Concretamente, en este caso se dispone de información espacial capturada por la cámara hiperespectral, la cámara RGB de luz estructurada y el mapa de profundidad reconstruido D . La resolución espacial disponible con la cámara RGB y el mapa de profundidad D es mayor que el de la cámara hiperespectral, por ello se proponen tres métodos diferentes de segmentación basados en la imagen RGB y el mapa de profundidad D .

El primer método de segmentación basado en la imagen RGB consiste en aplicar un detector de circunferencias sobre los bordes detectados en la imagen original. En particular se ha utilizado la transformada de Hough como método de detección y se ha utilizado el nivel de intensidad medio de los píxeles internos de la circunferencia para filtrar falsos positivos (figura 5.13a).

El segundo método de segmentación basado en el mapa de profundidad D reconstruido permite detectar el ojo de la dorada fácilmente ya que en el ojo aparece como un agujero circular en la superficie reconstruida. Esto se debe a que la luz del láser, cuando incide sobre el ojo de la dorada, no se refleja porque se introduce en su interior.

Finalmente, el tercer método propuesto fusiona los dos métodos anteriores con el objetivo de aumentar la robustez de dicha segmentación. El planteamiento ha sido componer una imagen RGBD relacionando espacialmente ambos espacios de trabajo y poder así aplicar los dos métodos anteriores para detectar el ojo de la dorada. Para poder relacionar espacialmente la imagen RGB con el mapa de profundidades D , se ha calibrado la cámara RGB con respecto al sistema de referencia del mundo reconstruido para posteriormente proyectar la reconstrucción y formar la imagen que capturaría la cámara introduciendo como datos de la imagen la altura de los puntos reconstruidos (figura 5.13 b).



3.- Caso práctico: estudio de frescura en *sparus aurata* usando técnicas hiperespectrales y segmentación 3D

Figura 5.13 a) Imagen RGB. La circunferencia azul marca la detección del ojo con el método de Hough.
b) Imagen de alturas proyectada sobre la cámara RGB. El ojo de la dorada aparece como un agujero.

3.5.- Resultados imagen hiperespectral

En la tabla 5.4 se pueden observar los resultados de dos modelos PLS realizados para predecir los 4 primeros días en base a los espectro con y sin segmentación espacial. La segmentación espacial realizada mediante el 3D permitió extraer el espectro únicamente de los ojos de las doradas. Los espectros se normalizaron a media 0 y a desviación estándar de 1. La mejora que supuso realizar la segmentación es superior al 100% ($R^2CV = 0.39 \rightarrow R^2CV = 0.84$). Se realizó este estudio previo solo en los cuatro primeros días debido a que en ese periodo de tiempo resulta muy difícil evaluar por otros medios el día exacto del pescado. Los resultados respaldan la necesidad de realizar una segmentación espacial precisa para poder evaluar la frescura de la dorada. Estos resultados respaldan los obtenidos por otros autores (Dowlati et al., 2013). Los estudios posteriores se realizaron siempre usando la segmentación espacial.

Tabla 5.4 Resultados de dos modelos PLS para predecir los cuatro primeros días.

	LVs	RMSEC	R ² Cal	RMSECV	R ² CV
Con segmentación espacial	6	0.233	0.951	0.419	0.844
Sin segmentación espacial	6	0.662	0.566	0.803	0.391

Cuando se realizó el estudio para todos los tiempos, tal y como se puede ver en la figura 5.14 el valor de R^2CV mejoró a 0.875 usando un modelo PLS de 8 variables latentes, sin

embargo los valores de RMSEC y RMSECV empeoraron a 0.789 y 0.920 respectivamente. Esto pudo ser debido a que en los últimos días el proceso de deterioramiento en las muestras se aceleró.




Figura 5.14 Modelo PLS de 8 Lvs usando el espectro segmentado

La correlación entre los espectros y los parámetros físico-químicos se muestran en la tabla 5.5 donde el NVBT presenta la mejor correlación (parámetro más relacionado con crecimiento microbiano y por tanto con la pérdida de frescura) y el humor vítreo la peor. Al graficar las medias de los datos experimentales del humor vítreo con el tiempo (figura 5.15) se pudo apreciar una tendencia ascendente proporcional al tiempo ($R^2=0.746$), sin embargo también presentó una fuerte dispersión especialmente en los últimos días lo cual explicaría los bajos resultados obtenidos en la correlación con el espectro.

Tabla 5.5 Resultados de la correlación PLS del espectro segmentado con los parámetros físico-químicos mediante PLS

	LVs	RMSEC	R ² Cal	RMSECV	R ² CV
Ph	8	0.048	0.870	0.069	0.744

3.- Caso práctico: estudio de frescura en sparus aurata usando técnicas hiperespectrales y segmentación 3D

NVBT	9	3.571	0.924	4.957	0.856
Humor Vitreo	6	0.002	0.472	0.002	0.325




Figura 5.15 Resultados experimentales del análisis de humor vítreo a lo largo de 9 días

3.6.- Conclusiones

Este estudio se enfocó en resolver el problema de detectar la frescura de la sparus aurata (dorada) de una forma no-destructiva. La complejidad del problema radica en que se trabaja sobre muestras sin ningún tipo de preparación. Las imágenes hiperespectrales en el rango del infrarrojo cercano de onda corta demostraron que disponen de suficiente información y cumplen los requisitos necesarios para esta aplicación. Sin embargo, tal y como se demuestra en este estudio, solo es válida la información espectral extraída de los ojos de las muestras. Así pues, es necesario realizar una segmentación espacial precisa y robusta como la que se llevó a

cabo mediante el sistema 3D por luz estructurada. Utilizando el espectro extraído de los ojos se consiguió un R^2 CV de 0.844 mediante un modelo PLS para los 4 primeros días y de 0.875 para los 9 primeros días. Para corroborar los buenos resultados obtenidos se corrélo con éxito con parámetros destructivos indicativos de la frescura como el PH (R^2 CV =0.744) y el NVBT (R^2 CV =0.856). Los resultados conseguidos demuestran que el sistema desarrollado resuelve el problema propuesto.

Como trabajo futuro, se planea extraer información útil del sistema 3D que permita una mayor caracterización de las muestras como por ejemplo el volumen (o el peso suponiendo una densidad constante), las dimensiones o la detección de defectos en las muestras. La posibilidad de extender este estudio a otras especies de pescado o incluso a otros tipos de alimentos que requieran un análisis espectral con mucha precisión espacial.

3.7.- Aportaciones del estudio

Además de demostrar la viabilidad de la técnica para el análisis de frescura de doradas a los pocos días de su captura, la importancia de este estudio radica en que fusiona una gran resolución espacial obtenida con el sistema 3D de luz estructurada y una resolución espectral capaz de predecir la frescura del alimento. Se ha demostrado experimentalmente con este estudio la necesidad de realizar una buena segmentación espacial para tener una señal utilizable y fiable. Se ha optado por utilizar un sistema tridimensional y no realizar la segmentación espacial como en el estudio del salmón en el capítulo 2 sección 3.4 debido a las numerosas ventajas que aporta tener informacional tridimensional de la muestra como por ejemplo, una mayor caracterización de la muestra, detección de defectos o posteriores manipulaciones automáticas de las muestras. Al igual que en los demás estudios de la presente tesis se ha trabajado sobre muestras sin ningún tipo de manipulación, lo que corrobora lo apropiadas que son las técnicas hiperespectrales y de adquisición de información 3D para el sector de la alimentación.



Capítulo 6: Conclusiones y trabajos futuros

En este capítulo se exponen las conclusiones obtenidas en el desarrollo de la tesis, así como las posibles líneas de trabajo futuro abiertas. Además, se citan los artículos presentados en revistas internacionales que avalan el trabajo realizado en la tesis.

1.- Conclusiones

En esta tesis se han desarrollado técnicas no destructivas de control de calidad de productos agroalimentarios. Para ello, se han utilizado sistemas de adquisición de información tridimensional y espectral en el rango SW-NIR de bajo coste. Las técnicas desarrolladas se han aplicado en diferentes productos tanto de origen animal como vegetal y con diferentes finalidades. Estas técnicas son muy interesantes a nivel de industria debido a las numerosas ventajas que presentan respecto a controles de calidad clásicos que se realizan actualmente. Una de estas ventajas es que estas técnicas realizan el control de calidad sobre el 100% de los productos y no solo sobre muestras representativas de la producción. Otras importantes ventajas son que resultan más económicos que un laboratorio de control y que una vez instalado el sistema no requiere de personal experto para su utilización. Además, los sistemas hiperespectrales empleados son considerados de bajo coste al compararlos con espectrógrafos cuyo coste es del orden de 5 veces superior. Respecto a los sistemas tridimensionales, también se han utilizado equipos económicos dentro del amplio catálogo de sensores existentes. Un aspecto importante para la automatización es el coste computacional de los métodos propuestos. Los modelos de predicción empleados tienen un coste del orden de $O(n)$ donde n es el número de variables latentes empleadas. Los procesados de imágenes y cálculos de la información 3D propuestos no son especialmente costosos con lo que utilizando hardware específico e implementaciones optimizadas se mejoraría notablemente los tiempos de trabajo

actuales del orden de segundos. En cualquier caso, los tiempos obtenidos son muy inferiores a las horas de trabajo requerido por los análisis destructivos.

Debido al trabajo realizado, se puede afirmar que la presente tesis cumple el objetivo general propuesto. Además, las 7 publicaciones en revistas internacionales avalan la novedad y la corrección de la investigación realizada. Respecto a los objetivos específicos, la tesis se ha estructurado de forma que cada capítulo este enfocado a cumplir cada uno de ellos.

Analizando en detalle cada uno de los capítulos, en el primero se ha realizado una revisión constante del estado del arte de técnicas de control de calidad de productos agroalimentarios. Concretamente, se ha hecho un repaso de las diferentes técnicas de obtención de información tridimensional así como de sus usos en la industria alimentaria. Además, se han explicado los fundamentos de las técnicas hiperespectrales, el contexto actual en el que se encuentran, las diferencias que existen entre las diferentes variantes de técnicas espectrales y las ventajas y desventajas que conllevan. Se han revisado y citado solo en este capítulo más de 70 publicaciones con fechas tan recientes como el 2014. Este gran número de trabajos analizados ha permitido definir con claridad y precisión el actual estado del arte.

En el tercer capítulo se han realizado estudios específicos para las tres técnicas tridimensionales más prometedoras para su aplicación en el sector alimentario que recordemos que son: por tiempo de vuelo, por luz estructurada y por visión estéreo. Se ha realizado concretamente una comparativa entre TOF y SL para productos animales y vegetales donde se ha concluido que aunque ambas técnicas son utilizables, la técnica SL dispone de una mayor precisión. También se han definido nuevos descriptores tridimensionales a nivel de puntos para su clasificación mediante modelos Adaboost. Estos descriptores se emplearon para segmentar nubes de puntos obtenidas mediante SL de tubérculos. Asimismo se desarrolló un proceso de refinamiento de los resultados que permitió simplificar los modelos Adaboost sin perder precisión. Otra aportación realizada fue la determinación de la compacidad de racimos de uva mediante nuevos descriptores 3D definidos en esta tesis. Para ello se basó en modelos

tridimensionales obtenidos de forma semiautomática con técnicas de estéreo visión en condiciones de adquisición difíciles (baja resolución y reflejos).

En el cuarto capítulo se explica la metodología desarrollada para el análisis de imágenes hiperespectrales en el rango del espectro visible hasta el infrarrojo cercano de diferentes productos agroalimentarios. Se han realizado casos prácticos para la evaluación de la frescura en diferentes tipos de alimentos de origen animal. Se han analizado alimentos sin ningún tipo de procesado para la estimación de su vida útil como la pechuga de pollo, con procesamientos suaves como el jamón cocido y con procesamientos intensivos como el del salmón ahumado. Además, en cada uno de los casos hay diferentes aportaciones como la selección de longitudes de onda en el caso del pollo o el modelo de color estimado para el equipo hiperespectral para la segmentación espacial desarrollado en el caso del salmón. En todos los casos prácticos se han alcanzado buenos resultados para estimar de forma no destructiva la frescura.

En el quinto capítulo se explica la principal aportación de la tesis que es la metodología diseñada y testada en el sector alimentario basada en la combinación de técnicas 3D e hiperespectrales. Mediante las técnicas 3D se obtiene una resolución espacial elevada y con las técnicas hiperespectrales una muy buena resolución espectral. Existen muchas posibilidades de aprovechamiento de esta ventaja, entre las cuales se han escogido dos. La primera de ellas consiste en utilizar la información tridimensional para el estudio temporal del proceso de fermentación de masas de harina. La información tridimensional en este caso se emplea para para caracterizar harinas reológicamente iguales pero cuyo comportamiento es diferente durante la fermentación. Al utilizar ambas técnicas se consigue que con una captura del equipo hiperespectral se sepa el comportamiento que va a tener la muestra durante el proceso de fermentación. La rápida y no destructiva caracterización conseguida permitiría por ejemplo ser más selectivo con la materia prima u optimizar el proceso agrupando las muestras con tiempos similares de fermentación. El segundo caso donde se ha empleado esta conjunción de técnicas consiste en aprovechar la gran resolución espacial obtenida de las técnicas 3D. Concretamente se utiliza para segmentar imágenes hiperespectrales de pescados y obtener solo la información

espectral de zonas específicas del pescado como los ojos donde se puede estimar mejor la frescura. Aunque en el caso práctico presentado solo se utilizó la información tridimensional para segmentar, otra gran ventaja de la fusión de técnicas es que se podrían usar tanto características espectrales como geométricas en vectores de descriptores para la segmentación y reconocimiento de objetos o regiones de interés.

2.- Trabajos futuros

La novedad de las técnicas presentadas, especialmente en cuanto a la integración de las informaciones de tipo espectral y espacial, permite abrir una gran cantidad de líneas de investigación. Existen principalmente dos grandes vías de extensión del trabajo realizado, por un lado las líneas de investigación desde un punto de vista más teórico y por otro lado las que están más enfocadas a aplicaciones y resolución de problemas concretos.

Por lo que respecta a las teóricas,

- Profundizar en el estudio de la influencia de las condiciones de iluminación variables en entornos no controlados como por ejemplo, al aplicar la técnica de medida de compacidad de racimos de uva en el campo. Evaluar sus efectos sobre los resultados de clasificación obtenidos y realizar las adaptaciones y filtros en caso de que fuera necesario.
- Estudio de la posibilidad de realizar técnicas tridimensionales de estéreo visión con dos o más cámaras hiperespectrales. Esto permitiría por ejemplo buscar las correspondencias para realizar el 3D en diferentes longitudes de onda.
- Estudio de modelos multivariantes para el control de procesos dinámicos en tiempo real mediante técnicas hiperespectrales.

- Estudio de otros posibles rangos espectrales de interés en la caracterización de alimentos como el ultravioleta o el infrarrojo lejano.
- En la tesis se ha estimado el modelo teórico de la cámara hiperespectral empleando una aproximación de “caja negra”. Un trabajo futuro sería calcular el modelo teórico de la cámara hiperespectral y compararlo con el estimado en esta tesis.

A nivel de aplicaciones:

- En esta tesis se ha desarrollado y aplicado una metodología para la evaluación de la frescura en productos alimentarios mediante técnicas hiperespectrales. Esta metodología se podría utilizar para otros casos prácticos como por ejemplo la identificación de productos adulterados, una mejor categorización de calidades de alimentos o la detección de restos de cascara o cuerpos extraños en frutos secos.
- Estudiar la posibilidad de emplear información espectral junto a la tridimensional para segmentar las raíces en tubérculos.
- Implantación en líneas de producción de los casos prácticos realizados en condiciones de laboratorio. Para ello, una de las tareas a realizar sería migrar el código propio realizado en Matlab a lenguajes más eficientes computacionalmente.

3.- Publicaciones

A continuación se citan los artículos publicados en revistas internacionales que avalan la investigación realizada así como la referencia cruzada a la sección de la tesis donde están desarrollados:

1. Raúl Grau, Antonio J. Sánchez, Joel Girón, Eugenio Iborra, Ana Fuentes, Jose M. Barat, Nondestructive assessment of freshness in packaged sliced chicken breasts using SW-NIR spectroscopy, Food Research International, Volume 44, Issue 1, January 2011, Pages 331-337, ISSN 0963-9969. Índice de impacto (JCR2011): 3.150. Q1. *Referencia en la tesis: 4.5.- Caso práctico: estudio de frescura en pechuga de pollo* Página: 104
2. Samuel Verdú, Eugenio Iborra, Antonio J. Sánchez, Joel Girón, Jose M. Barat, Raúl Grau, Comparison of TOF and SL techniques for in-line measurement of food item volume using animal and vegetable tissues, Food Control, Volume 33, Issue 1, September 2013, Pages 221-226, ISSN 0956-7135. Índice de impacto (JCR2013): 2.819. Q1. *Referencia en la tesis: 3.2.- Caso práctico: Comparación de las técnicas TOF y SL para la medida en línea de producción de alimentos de origen animal y vegetal.* Página 33
3. Eugenio Iborra, Joel Girón, Antonio J. Sánchez, Samuel Verdú, Jose M. Barat, Raúl Grau, Detection of expired vacuum-packed smoked salmon based on PLS-DA method using hyperspectral images, Journal of Food Engineering, Volume 117, Issue 3, August 2013, Pages 342-349, ISSN 0260-8774. Índice de impacto (JCR2013): 2.576. Q1. *Referencia en la tesis: 4.6.- Caso práctico: detección de caducidad en salmón ahumado.* Página 113
4. Iborra Martínez, Eugenio; Verdú Amat, Samuel; Sánchez Salmerón, Antonio José; Barat Baviera, José Manuel; Grau Meló, Raúl; Continuous monitoring of bread dough fermentation using a 3D vision, Journal of Food Engineering, Volume 130, Pages 8-13, ISSN 0260-8774, 2013. Índice de impacto (JCR2013): 2.576. Q1. *Referencia en la tesis: 5.2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales.* Página 127

5. Ivorra Martínez, Eugenio; Sánchez Salmerón, Antonio José; et al. Preliminary study using Visible and SW-NIR analysis for evaluating the loss of freshness in commercially packaged cooked ham and turkey ham, Czech Journal of Food Sciences, Pages 1-6 (ISSN 1212-1800), 2014. Índice de impacto (JCR2013): 0.741. Q3. *Referencia en la tesis: 4.4.- Caso práctico: estudio de frescura en jamón de pavo y jamón cocido. Página 95*

6. Ivorra Martínez, Eugenio; Sánchez Salmerón, Antonio José; Camarasa, Josep; Diago, Mari Paz; Tardaguila, Javier; Assessment of Grape Cluster Yield Components Based on 3D Descriptors Using Stereo Vision. Food Control, Volume 50, Pages 273-282, (ISSN 0956-7135), 2014. Índice de impacto (JCR2013): 2.819. Q1. *Referencia en la tesis: 3.4.- Caso práctico: Determinación de la compacidad de racimos de uva basándose en descriptores 3D usando técnicas de estéreo visión. Página 58*

7. Verdú Amat, Samuel; Ivorra, Eugenio; Sánchez Salmerón, Antonio José Barat Baviera, José Manuel; Grau Meló, Raúl; Study of high strength wheat flours considering their physicochemical and rheological characterisation as well as fermentation capacity using SW-NIR imaging. Journal of Cereal Science (Available online, In Press, Accepted Manuscript). 2015. Índice de impacto (JCR2013): 1.943. Q2. *Referencia en la tesis: 5.2.- Caso práctico: Estudio de la capacidad fermentativa de harinas de trigo evaluadas mediante análisis reológicos y de 3D, respecto a su capacidad de fermentación mediante técnicas hiperespectrales. Página 127*

Capítulo 6: Conclusiones y trabajos futuros

Además de los artículos publicados en revistas internacionales, se difundieron los siguientes resultados en congresos:

Título	Lugar Fecha	Organización	Título del evento	Tipo de participación
Prediction of chicken meat freshness using Near Infrared Spectroscopy	Valencia 29/09/2009	Grupo de Ingeniería Estadística Mutivariante. UPV	1st International Workshop on Multivariate Image Analysis	Abstract & Poster
Aplicación de la técnica de espectrofotometría de infrarrojo cercano (SW-NIR) para la determinación de la frescura de jamón cocido loncheado y envasado	Logroño 06/10/2010	Centro tecnológico de la industria cárnica & Centro de innovación y tecnología alimentaria.	VI Congreso Español de Ingeniería de Alimentos. CESIA 2010	Abstract & Poster
Estudio de la vida útil de bacalao ahumado fileteado y envasado mediante la técnica de imagen multiespectral SW-NIR	Valencia 08/06/2011	Universitat Politècnica de València y la Universitat de València	VI Congreso Nacional de Ciencia y Tecnología de los Alimentos (CyTA 2011)	Abstract & Poster
Aplicación de la técnica de imagen multiespectral SW-NIR como posible herramienta para la detección de carnes de vacuno alteradas	Valencia 08/06/2011	Universitat Politècnica de València y la Universitat de València	VI Congreso Nacional de Ciencia y Tecnología de los Alimentos (CyTA 2011)	Abstract & Poster
Evaluación de la técnica de imagen multiespectral SW-NIR como posible herramienta para la clasificación de lomo de cerdo	Ciudad Real 09/11/2012	Departamento de Tecnología de Alimentos. Universidad de Castilla-La Mancha	VII Congreso Español de Ingeniería de Alimentos. CESIA 2012	Abstract & Poster
Estudio de la influencia de la incorporación de harina de salvia en la panificación	Valencia 13/01/2014	Universitat Politècnica de València	CIBIA 9 ,Congreso Iberoamericano de Ingeniería de Alimentos,	Abstract & Poster
Reconstrucción 3D de racimos de uva basada en estéreo-visión	Valencia 03/09/2014	Universitat Politècnica de València	XXV Jornadas de Automática	Paper & Poster

Apéndice A: Modelos estadísticos para el análisis de imagen multivariante

1.- PCA

En estadística, el análisis de componentes principales (en español ACP, en inglés, PCA) es una técnica utilizada para reducir la dimensionalidad de un conjunto de datos. Intuitivamente la técnica sirve para determinar el número de factores subyacentes explicativos tras un conjunto de datos que expliquen la variabilidad de dichos datos. (S. Wold, Geladi, Esbensen, & Jerker, 1987).

Técnicamente, el PCA busca la proyección según la cual los datos queden mejor representados en términos de mínimos cuadrados. PCA se emplea sobre todo en análisis exploratorio de datos y para construir modelos predictivos. PCA implica el cálculo de la descomposición en autovalores de la matriz de covarianza, normalmente tras centrar los datos en la media de cada atributo.

1.1.-Fundamento

El PCA construye una transformación lineal que escoge un nuevo sistema de coordenadas para el conjunto original de datos en el cual la varianza de mayor tamaño del conjunto de datos es capturada en el primer eje (llamado el Primer Componente Principal), la segunda varianza más grande es el segundo eje, y así sucesivamente. Para construir esta transformación lineal debe construirse primero la matriz de covarianza o matriz de coeficientes de correlación. Debido a la simetría de esta matriz existe una base completa de vectores propios de la misma. La transformación que lleva de las antiguas coordenadas a las coordenadas de la nueva base es

precisamente la transformación lineal que reduce la dimensionalidad de datos. Además las coordenadas en la nueva base dan la composición en factores subyacentes de los datos iniciales.

Una de las ventajas de PCA para reducir la dimensionalidad de un grupo de datos, es que retiene aquellas características del conjunto de datos que contribuyen más a su varianza, obteniendo primero los más importantes. Es decir, que los componentes principales de orden bajo contienen más información que los de orden alto, pudiendo ser estos últimos ignorados.

1.2.-Matemáticas del PCA

Supongamos que existe una muestra con n individuos para cada uno de los cuales se han medido m variables (aleatorias) F_j . El PCA permite encontrar un número de factores subyacentes $p < m$ que explican aproximadamente el valor de las m variables para cada individuo. El hecho de que existan estos p factores subyacentes puede interpretarse como una reducción de la dimensionalidad de los datos: donde antes necesitábamos m valores para caracterizar a cada individuo ahora nos bastan p valores. A cada uno de los p encontrados se llama componente principal, de ahí el nombre del método.

Existen dos formas básicas de aplicar el PCA:

- Método basado en la matriz de correlación: cuando los datos no son dimensionalmente homogéneos o el orden de magnitud de las variables aleatorias medidas no es el mismo.
- Método basado en la matriz de covarianzas, que se usa cuando los datos son dimensionalmente homogéneos y presentan valores medios similares.

1.2.1.- Método basado en correlaciones

El método parte de la matriz de correlaciones, consideremos el valor de cada una de las m variables aleatorias F_j . Para cada uno de los n individuos tomemos el valor de estas variables y lo escribimos en forma de matriz:

$$F_j^\beta \Big|_{\substack{\beta = 1, \dots, n \\ j = 1, \dots, m}} \quad (\text{A.1})$$

Obsérvese que cada conjunto

$$M_j = \{F_j^\beta \mid \beta = 1, \dots, n\} \quad (\text{A.2})$$

puede considerarse una muestra aleatoria para la variable F_j . A partir de los $m \times n$ datos correspondientes a las m variables aleatorias, puede construirse la matriz de correlación muestral que viene definida por:

$$R = [r_{ij}] \in M_{m \times n} \quad \text{con} \quad r_{ij} = \frac{\text{cov}(F_i, F_j)}{\sqrt{\text{var}(F_i) \text{var}(F_j)}} \quad (\text{A.3})$$

Al ser la matriz de correlaciones una matriz simétrica, entonces resulta que la matriz es diagonalizable y sus valores propios verifican:

$$\sum_{i=1}^m \lambda_i = 1 \quad (\text{A.4})$$

Debido a la propiedad anterior, estos m valores propios reciben el nombre de pesos de cada uno de los m componentes principales. Los factores principales identificados matemáticamente se representan por la base de vectores propios de la matriz R . Está claro que cada una de las

variables puede ser expresada como combinación lineal de los vectores propios o componentes principales.

1.2.2.- Método basado en las covarianzas

El objetivo es transformar un conjunto dado de datos X de dimensión $n \times m$ a otro conjunto de datos Y de menor dimensión $n \times l$ con la menor pérdida de información útil posible utilizando para ello la matriz de covarianza.

Se parte de un conjunto n de muestras cada una de las cuales tiene m variables que las describen y el objetivo es que, cada una de esas muestras, se describa con solo l variables, donde $l < m$. Además, el número de componentes principales l tiene que ser inferior a la menor de las dimensiones de X .

Los datos para el análisis tienen que estar centrados a media 0 (restándoles la media de cada columna) y/o autoescalados (centrados a media 0 y dividiendo cada columna por su desviación estándar).

$$X = \sum_{a=1}^l t_a p_a^T + E \quad (\text{A.5})$$

Los vectores t_a son conocidos como *scores* y contienen la información de cómo las muestras están relacionadas unas con otras, además tienen la propiedad de ser ortogonales. Los vectores p_a se llaman *loadings* e informan de la relación existente entre las variables y tienen la cualidad de ser ortonormales. Al coger menos componentes principales que variables y debido al error de ajuste del modelo con los datos, se produce un error que se acumula en la matriz E .

El PCA se basa en la descomposición en vectores propios de la matriz de covarianza la cual se calcula con las siguientes ecuaciones:

$$\text{cov}(X) = \frac{X^T X}{n-1} \quad (\text{A.6})$$

$$\text{cov}(X) p_a = \lambda_a * p_a \quad (\text{A.7})$$

Donde λ_a es el valor propio asociado al vector propio p_a . Por último:

$$t_a = X * p_a \quad (\text{A.8})$$

Esta ecuación la podemos entender como que t_a son las proyecciones de X en p_a , donde los valores propios λ_a miden la cantidad de varianza capturada, es decir, la información que representan cada uno de los componentes principales. La cantidad de información que captura cada componente principal va disminuyendo según su número es decir, el componente principal número uno representa más información que el dos y así sucesivamente.

1.1.3. Limitaciones

La aplicación de los modelos PCA está limitada por varios supuestos:

- Supuesto de linealidad: Se asume que los datos observados son combinaciones lineales de una cierta base.
- Importancia estadística de la media y la covarianza: el PCA utiliza los vectores y valores propios de la matriz de covarianzas lo que provoca que encuentre las direcciones de ejes en el espacio de variables asumiendo que los datos se distribuyen de manera gaussiana.

1.1.4.- Parámetros estadísticos

Es posible comprobar el error de ajuste estadístico en los modelos de PCA mediante el estadístico Q . Es una medida de la diferencia entre una muestra y su proyección en k componentes principales del modelo. La forma de calcular Q es simplemente la suma al cuadrado de los residuos de cada muestra.

$$Q_i = e_i e_i^T = x_i (I - P_k P_k^T) x_i^T \quad (\text{A.9})$$

Donde e_i es la fila i de la matriz E de la ecuación A.6, I la matriz identidad y P_k la matriz de loadings del modelo PCA.

El límite de confianza de Q se puede calcular siempre que todos los valores propios de la matriz de covarianza de X estén calculados (Jackson & Mudholkar, 1979).

$$Q_a = \theta_1 \left(\frac{c_a \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right)^{\frac{1}{h_0}} \quad (\text{A.10})$$

$$\theta_i = \sum_{j=k+1}^n \lambda_j^i \text{ para } i = 1, 2, 3 \quad (\text{A.11})$$

$$h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2} \quad (\text{A.12})$$

Otro estadístico importante es el Hotelling's T^2 que mide la variación de cada muestra dentro del modelo PCA. Se calcula como la suma normalizada al cuadrado de los scores tal y como expresa la siguiente ecuación:

$$T_i^2 = t_i \lambda^{-1} t_i^T = x_i P_k \lambda^{-1} P_k^T x_i^T \quad (\text{A.13})$$

Donde t_i es una fila de scores, λ es una matriz diagonal con k valores propios y P_k es la matriz de loadings. Los límites de confianza para el estadístico Hotelling's T^2 se calculan utilizando una distribución F como sigue:

$$T_{k,m,a}^2 = \frac{k(m-1)}{m-k} F_{k,m-k,a} \quad (\text{A.14})$$

2.- PLS

El método Partial Least Square (PLS) es un modelo desarrollado en 1970 por Herman Wold y perfeccionado en años posteriores (Geladi & Kowalski, 1986; S. Wold et al., 1987; Norgaard et al., 2000).

El modelo PLS se trata de una proyección a estructuras latentes mediante una aproximación por mínimos cuadrados parciales. La finalidad de este método es explicar la relación entre dos conjuntos de variables X e Y (siendo X los datos del proceso e Y los datos de calidad) capturando la máxima información posible. Dicho formalmente, el algoritmo PLS lo que realiza es capturar la mejor varianza posible de ambas variables consiguiendo correlacionarlas lo que se traduce en maximizar la covarianza.

Existen varias formas para el cálculo de los parámetros del modelo PLS. Entre ellos cabe destacar el método “Non-Iterative Partial Least Squares” (NIPALS) de (H. Wold & Lyttkens, 1969) y el “Straightforward Implementation of a Statistically Inspired Modification of the PLS” (SIMPLS) de (Sijmen de Jong, 1993), siendo el NIPALS el más intuitivo pero menos eficiente.

Tanto NIPALS como SIMPLS funcionan para el PLS cuando hay más de una variable de predicción (Y). En el caso de solo una variable de predicción, ambos algoritmos dan el mismo resultado. Cuando hay más de una variable de predicción el método SIMPLS es más eficiente.

2.1.- NIPALS

NIPALS calcula los scores T y los loadings P (de igual forma que el PCA), y un nuevo conjunto de vectores llamados pesos W , con las mismas dimensiones que los loadings. El vector de pesos sirve para mantener la ortogonalidad de los scores.

Apéndice A: Modelos estadísticos para el análisis de imagen multivariante

En los casos de más de un variable de predicción, se calculan los scores U y los loadings Q del vector Y . Además es necesario calcular un vector de coeficientes b que relaciona los scores T y los scores U .

Los parámetros del PLS se calculan de forma secuencial, es decir, se empieza por la primera columna de Y (y_j) que tiene la mayor varianza.

Empezando por el bloque de datos de X :

$$w_1 = \frac{X^T u_1}{\|X^T u_1\|} \quad (\text{A.15})$$

$$t_1 = X w_1 \quad (\text{A.16})$$

En el bloque de datos de Y :

$$q_1 = \frac{Y^T t_1}{\|Y^T t_1\|} \quad (\text{A.17})$$

$$u_1 = Y q_1 \quad (\text{A.18})$$

La convergencia se comprueba comparando t_1 con el valor de la iteración anterior. Si son iguales se pasa a la ecuación A.19 sino, se vuelve a la ecuación A.15 utilizando el u_1 obtenido anteriormente en A.18. En el caso de que solo se tenga una variable en Y , q_1 vale 1 y se omiten la ecuaciones A.17 y A.18.

El siguiente paso es calcular los loadings de las X y actualizar los scores y los pesos.

$$p_1 = \frac{X^T t_1}{\|t_1^T t_1\|} \quad (\text{A.19})$$

$$p_{1nuevo} = \frac{p_{1viejo}}{\|p_{1viejo}\|} \quad (\text{A.20})$$

$$t_{1nuevo} = t_{1viejo} * \|t_{1viejo}\| \quad (\text{A.21})$$

$$w_{1nuevo} = w_{1viejo} * \|w_{1viejo}\| \quad (A.22)$$

Se calcula también el coeficiente de regresión b :

$$b_1 = \frac{u_1^T t_1}{\|t_1^T t_1\|} \quad (A.23)$$

El último paso de la iteración es el cálculo de residuos tanto en X como en Y :

$$E_1 = X - t_1 p_1^T \quad (A.24)$$

$$F_1 = Y - b_1 t_1 q_1^T \quad (A.25)$$

Una vez realizado esto, se repite el mismo proceso para la siguiente variable latente utilizando los residuos obtenidos e incrementando todos los subíndices en 1.

Se puede demostrar que con el PLS se obtiene la siguiente matriz inversa:

$$X^+ = W(P^T W)^{-1}(T^T T)^{-1} T^T \quad (A.26)$$

Cabe recalcar que el superíndice T indica la transpuesta y no se debe confundir con la matriz T de scores. Se puede observar en la ecuación A.26 que los scores y los loadings calculados en el PLS no se corresponden a los de la PCA. Sin embargo, se puede pensar en los scores y loadings del PLS como unos del PCA rotados de forma que se potencia la predictibilidad de Y .

2.2.- SIMPLS

Existe otro algoritmo para calcular modelos PLS llamado SIMPLS que fue creado en 1993 por Sijmen de Jon.

El método se basa en la ortogonalización de la secuencia de Krylof para calcular los pesos del PLS, esto aumenta mucho la velocidad y su precisión acostaba de dejar de ser intuitivo.

Se puede demostrar que el primer vector de pesos viene dado por el vector propio de $X^T Y Y^T X$ y que éste, está asociado con el valor propio más grande, como vemos en la siguiente ecuación.

$$\lambda w_1 = X^T Y Y^T X w_1 \quad (\text{A.27})$$

Para aplicar el modelo a nuevos datos, los scores se calculan empleando la ecuación A.28 y no utilizando simplemente los loadings como sucede con la PCA.

$$\lambda T_{nuevo} = X_{nuevo} W (P^T W)^{-1} \quad (\text{A.28})$$

3.- Métodos de clasificación

A menudo, la información de las muestras pertenece a distintos grupos o clases. Las clases pueden ser diferentes por muchas razones y motivos, pudiendo ser nuestro objetivo el saber a qué clase pertenece una muestra.

Para la determinación de clases de forma automática existen básicamente dos criterios:

- Clasificación supervisada: Se parte de un conjunto de clases conocido a priori. Estas clases deben caracterizarse en función del conjunto de variables mediante la medición de las mismas en individuos cuya pertenencia a una de las clases no presente dudas (áreas de entrenamiento).
- Clasificación no supervisada. No se establece ninguna clase a priori, aunque es necesario determinar el número de clases que queremos establecer, y dejar que las defina un procedimiento estadístico.

3.- Métodos de clasificación

La mayoría de algoritmos se basan en la asunción de que las muestras que se encuentran cerca en el espacio de medida son similares y por tanto pertenecen a la misma clase. Sin embargo, existen muchas formas de definir la distancia entre muestras, siendo la más conocida la Distancia Euclidia.

La distancia Euclidia como podemos observar en la ecuación A.29 es simplemente la raíz cuadrada de la suma al cuadrado de las diferencias entre las muestras. Es recomendable realizar preprocesados de los datos antes de calcular la distancia.

$$e(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T (\vec{x} - \vec{y})} \quad (\text{A.29})$$

Otra distancia muy empleada es la distancia de Mahalanobis que es una medida de la distancia introducida por el P. Mahalanobis en el 1936. Se basa en las correlaciones entre variables por las cuales diversos patrones pueden ser identificados y analizados. La diferencia con la distancia Euclidia es que considera las correlaciones del conjunto de datos y que no es dependiente de la escala de medidas. Esto se puede comprobar en la ecuación A.30 que solo se diferencia de la ecuación A.31 en la matriz de covarianza

$$m(\vec{x}, \vec{y}) = \sqrt{(\vec{x} - \vec{y})^T S^{-1} (\vec{x} - \vec{y})} \quad (\text{A.30})$$

En la figura A.1 podemos observar como la distancia Euclidia del punto A respecto al origen (x, y) es mayor a la distancia Euclidia del punto B con el origen. Por el contrario, la distancia de Mahalanobis del punto A es menor a la del punto B.

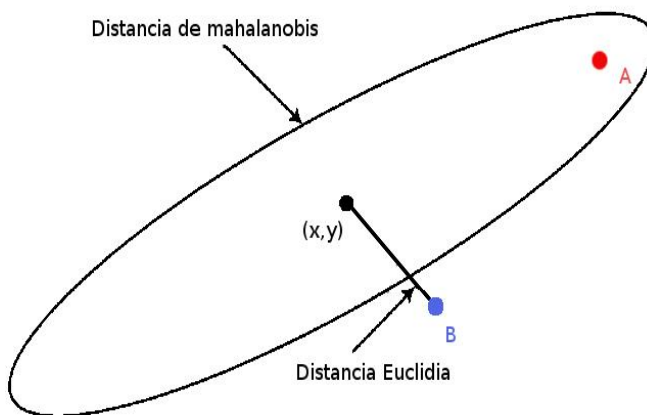


Figura A.1 Gráfico comparando la distancia Euclidia con la de Mahalanobis respecto a los puntos A y B

En los casos en que tenemos muchas dimensiones no es recomendable utilizar la distancia de Mahalanobis debido a que puede reforzar las variaciones debidas a ruidos.

Una interesante forma de medir la distancia entre muestras es realizarla respecto a los scores de un modelo de PCA. De esta forma reducimos el número de cálculos y además sirve como filtro contra el ruido al haber desechado información no relevante.

3.1.- *K-means*

K-means es un algoritmo de clustering, es decir de clasificación no supervisada, cuyo objetivo es partir n muestras en k clases donde cada muestra pertenece a la clase con la media más cercana.

Dado un conjunto de muestras (x_1, x_2, \dots, x_n) , donde cada observación es un vector de dimensión d , el algoritmo intenta partir las n muestras en k conjuntos ($k < n$) S_1, S_2, \dots, S_k de forma que minimice la distancia al cuadrado dentro de las clases (WCSS).

$$\operatorname{argmin} = \sum_{i=1}^k \sum_{x_j \in S_i} \|x_j - \mu_i^2\| \quad (\text{A.31})$$

Donde μ es la media de los puntos contenidos en S_i .

El algoritmo más común es iterativo y se llama algoritmo de Lloyd. Consiste en los siguientes pasos:

1. Condiciones iniciales: Especificar el número de clases y los centroides escogidos aleatoriamente.
2. Asignación: Pone cada muestra en la clase con la media más cercana.

$$S_i^t = \{X_j: \|x_j - m_i^t\| \leq \|x_j - m_{i'}^t\| \text{ para } \forall i' = 1, \dots, k\} \quad (\text{A.32})$$

3. Actualización: Calcula las nuevas medias de cada clase que van a ser los nuevos centroides.

$$m_i^{t+1} = \frac{1}{\|S_i^t\|} \sum_{x_j \in S_i} x_j \quad (\text{A.33})$$

Se repiten los pasos 2 y 3 hasta que las asignaciones de las muestras a cada clase no cambian. Al ser un algoritmo heurístico no se garantiza la convergencia al óptimo y el resultado depende mucho de las clases iniciales. Como normalmente es un algoritmo muy rápido, lo típico es ejecutarlo muchas veces con diferentes condiciones iniciales y averiguar la tendencia.

Existen muchas variantes de este algoritmo como utilizar la mediana en vez de la media o utilizar mediodes en vez de centroides, otra opción es utilizar otras medidas de distancia aparte de la Euclídea.

3.2.- SIMCA

Se ha demostrado que el PCA sirve para diferenciar muestras y las variables que más les afectan pero no se garantiza que sea capaz de diferenciar entre distintas clases. PCA solo intenta describir la máxima variación posible en la información sin tener en cuenta clases conocidas a priori para realizar el modelo.

SIMCA (Soft Independent Method of Class Analogy) es un algoritmo de clasificación supervisado consistente en realizar un modelo de PCA para cada una de las clases (S. Wold & Sjostrom, 1977).

Cada modelo de cada clase puede tener un número diferente de componentes principales, preprocesado etc, es decir, se construyen modelos independientes para cada clase que se ajusten lo mejor posible.

Una vez hecho los modelos, las nuevas muestras a clasificar se proyectan en cada uno de los modelos y se decide que clase es la más cercana con la siguiente ecuación:

$$d_{ij} = \sqrt{Q_r^2 + T_r^2} \quad (\text{A.34})$$

$$Q_r = \frac{Q}{Q_{0,95}} \quad (\text{A.35})$$

$$T_r = \frac{T}{T_{0,95}} \quad (\text{A.36})$$

En la ecuación A.34 se utilizan los estadísticos reducidos para poder comparar entre los diferentes modelos de PCA de cada clase, ya que cada modelo puede tener unos valores de T^2 y Q en diferentes escalas numéricas y ser muy complicados de comparar. Los coeficientes de límites de confianza de los estadísticos Q y T^2 son los calculados con las ecuaciones A.11 y A.14 respectivamente.

3.3.- PLSDA

El objetivo del algoritmo PLSDA es encontrar modelos que permitan la máxima separación entre distintas clases de muestras (Barker & Rayens, 2003).

El algoritmo consiste en crear una matriz Y de variables dummy que representa la pertenencia o no de la muestra a la clase. Se hacen tantas columnas (variables) como clases hay, y se pone a 1 si la muestra pertenece a esa clase o 0 sino pertenecen.

La predicción de un modelo PLSDA es un valor aproximadamente cero o uno. Un valor cercano a cero indica que la nueva muestra no pertenece a esa clase y de igual forma un valor cercano a 1 indica su pertenencia. En la práctica, se utiliza un umbral a partir del cual se considera o no perteneciente a la clase.

El modelo PLSDA devuelve dos valores de salida ante una nueva muestra: la predicción de su valor como un PLS normal y la probabilidad de predicción.

La probabilidad de predicción se calcula utilizando los valores predichos en Y mediante un PLS aplicándoles una distribución normal y luego calculando la probabilidad de un valor dado de Y .

3.4.- Adaboost

Con la creación del algoritmo Adaboost (Freund, Schapire, & Abe, 1999) se resolvieron muchas de las dificultades prácticas de los anteriores algoritmos basados en *Boosting*. *Boosting* es una familia de algoritmos, entre los cuales Adaboost es el más conocido y utilizado, que consiste en crear clasificadores fuertes a partir de la unión de clasificadores débiles. Las dificultades resueltas por Adaboost son cómo generar la hipótesis y cómo determinar los pesos en función del error. Adaboost es un algoritmo de clasificación cuyo objetivo es resolver

problemas de optimización produciendo hipótesis con el mínimo error, o por lo menos con una certeza mayor al 50%. Dando los suficientes datos de entrenamiento, Adaboost va generando nuevas hipótesis que se van mejorando con cada iteración.

Adaboost produce un clasificador débil el cual selecciona una característica candidata con el menor error al cual asigna unos pesos específicos dependiendo de su precisión. A partir de esta ponderación realizada con los pesos, se calcula el error para la siguiente iteración en la que se producirá un clasificador débil que se centrará en clasificar las muestras mal clasificadas en la iteración previa. Esto continúa hasta que no hay más iteraciones o se alcanza unos resultados aceptables.

En esta tesis el algoritmo de Boosting utilizado es el Minimalist Adaboost (Barnes, Duckett, Cielniak, Stroud, & Harper, 2010b), el cual se basa en el algoritmo Real Adaboost (Freund et al., 1999). Este algoritmo permite la clasificación de múltiples clases, en la que cada clasificador devuelve un voto de certeza para cada una que se utiliza en una votación de “uno-contratodos”. Los valores de certeza se comparan unos con otros, y el algoritmo devuelve el voto con mayor rango de certeza. Barnes en 2010 presento su versión del Real Adaboost llamada Minimalist Adaboost la cual limitaba el número de características candidatas que se usaban. Simplemente, el algoritmo requiere que el usuario le fije un límite de características. Una vez el sistema ha seleccionado características hasta el límite, se utilizan estas características seleccionadas para entrenar Adaboost, hasta que una de las condiciones para finalizar se cumpla. Este método permite al sistema empezar problemas que tienen un espacio extremadamente grande utilizando 100 o 1000 características candidatas. Debido a la gran carga computacional de buscar entre todas las características candidatas a lo largo de todo el problema espacial Adaboost puede reutilizar las características ya utilizadas en iteraciones previas para acelerar el proceso.

El algoritmo Adaboost consiste en tres fases en las que el bucle iterativo recalcula el error en cada una de las iteraciones. El proceso comienza con el cálculo de un clasificador débil

utilizando un error igual para todas las clases. Se pondera y en la siguiente iteración se crea otro clasificador débil que se centra en minimizar el error de las muestras mal clasificadas por la iteración anterior. El clasificador débil busca entre todas las características aquellas que ayuden a clasificar las muestras mal clasificadas. Estos clasificadores débiles se combinan en un árbol de decisión llamado clasificador fuerte que se recorre para calcular el grado de certidumbre.

3.4.1- Algoritmo Minimalist Real Adaboost (Barnes et al., 2010b)

Dado un conjunto de datos $S = \{(x_1, y_1), \dots, (x_m, y_m)\}$ donde $x_i \in X$ y $y_i \in \{-1, +1\}$, el conjunto de clasificadores débiles K que contiene todos los posibles clasificadores débiles para F_c características candidatas, una cantidad máxima de clasificadores débiles que pueden ser seleccionados T y un máximo número de características únicas F_S que pueden ser usadas por los clasificadores débiles (Barnes et al., 2010b).

Inicializando la distribución de la muestra como $D_1(i) = 1/m$

Para $t = 1, \dots, T$

1. Para cada clasificador débil h en K :
 - a. Dividir X en varios bloques separados X_1, \dots, X_n
 - b. Utilizando los pesos en la distribución D_t calcular

$$W_i^j = P(x_i \in X_j, y_i = l) = \sum_{i: x_i \in X_j, y_i = l} D_t(i) \quad (\text{A.37})$$

Donde $l = \pm 1$

- c. Fijar la salida de h para cada X_j como:

$$\forall x \in X_j, h(x) = \frac{1}{2} \ln \frac{(W_{+1}^j + \epsilon)}{(W_{-1}^j + \epsilon)} \quad (\text{A.38})$$

- d. Calcular el factor de normalización como :

$$Z = 2 \sum_j \sqrt{W_{+1}^j \cdot W_{-1}^j} \quad (\text{A.39})$$

2. Seleccionar el h_t minimizando Z

$$Z_t = \min_{h \in K} Z \quad (\text{A.40})$$

$$h_t = \arg \min_{h \in K} Z \quad (\text{A.41})$$

3. Actualizar la distribución de la muestra

$$D_{t+1}(i) = D_t(i) \exp[-y_i h_t(x_i)] \quad (\text{A.42})$$

y normalizar D_{t+1} para dar una función de distribución de probabilidad.

4. Contar el número de características únicas utilizadas por todos los clasificadores débiles. Si el total de características es igual a F_S entonces se actualiza K utilizando solo las características que ya contienen los clasificadores débiles.

El clasificador fuerte final H será:

$$H(x) = \text{sign}[\sum_{t=1}^T h_t(x) - b] \quad (\text{A.43})$$

Y la certidumbre de H :

$$\text{Conf}H(x) = [\sum_{t=1}^T h_t(x) - b] \quad (\text{A.44})$$

3.5. SVM

El modelo SVM es un modelo estadístico que construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad alta que puede ser utilizado en problemas de clasificación o regresión. La idea se basa en utilizar hiperplanos que maximicen la separación entre clases para obtener una buena clasificación. Fue inventado por Vladimir Vapnik y sus colaboradores y presentado por primera vez en “Computational Learning Theory” (COLT) en 1992.

Normalmente el algoritmo SVM debe tratar con muchas variables predictoras, curvas no lineales de separación o casos donde los conjuntos de datos no pueden ser completamente separados. Esto significa que no se pueden separar las clases únicamente mediante una línea recta, un plano recto o un hiperplano N -dimensional. Para solucionarlo, SVM utiliza una serie de funciones de Kernel que consisten en proyectar la información a un espacio de características de mayor dimensionalidad en el que se puedan diferenciar mejor las clases. Otras de las

principales características de este algoritmo son que no tiene mínimos locales y que tiene una gran capacidad de configuración para adaptarse a la información.

Algunas de las funciones de Kernel más populares son:

- Polinomial-homogénea: $k(x_i, x_j) = (x_i, x_j)^n$
- Perceptron: $k(x_i, x_j) = \|x_i - x_j\|$
- Función de base radial Gaussiana: separado por un hiperplano en el espacio transformado (RBF): $k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$
- Sigmoid: $K(x_i, x_j) = \tanh(x_i \cdot x_j - \theta)$

3.5.1 ϵ -SVR

SVM también se utiliza para realizar regresiones donde se busca y optimiza los límites dados para la regresión. Esto consiste en definir la función de pérdida intensiva ϵ que se encuentra situada a cierta distancia del valor correcto pero dentro de la cual se ignora el error.

Dado un conjunto de puntos de entrenamiento $\{(x_1, z_1) \cdots (x_l, z_l)\}$, donde $x_i \in R^n$ es un vector de características y $z_i \in R^1$ es el resultado. Dados los siguientes parámetros $C > 0$ y $\epsilon > 0$, la forma estándar del support vector regression (Vapnik, 1998) es:

$$\min_{\omega, b, \xi, \xi^*} \frac{1}{2} \omega^T \omega + C \sum_{i=1}^l \xi_i + C \sum_{i=1}^l \xi_i^* \quad (\text{A.45})$$

$$\text{Donde } \begin{cases} \omega^T \phi(x_i) + b - z_i \leq \epsilon + \xi_i \\ z_i - \omega^T \phi(x_i) - b \leq \epsilon + \xi_i^* \\ \xi_i \xi_i^* \geq 0, i = 1, \dots, l \end{cases} \quad (\text{A.46})$$

El problema dual es:

$$\min_{\alpha, \alpha^*} \frac{1}{2} (\alpha - \alpha^*)^T Q (\alpha - \alpha^*) + \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l (\alpha_i - \alpha_i^*) \quad (\text{A.47})$$

$$\text{Donde } \begin{cases} e^T (\alpha - \alpha^*) = 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, \dots, l, \\ Q_{ij} = K(x_i x_j) \equiv \phi(x_i)^T \phi(x_j) \end{cases} \quad (\text{A.48})$$

Resolviendo A.47, la función aproximada es

$$\sum_{i=1}^l (-\alpha_i + \alpha_i^*) K(x_i, x) + b \quad (\text{A.49})$$

4.- Selección de variables

En el análisis de imágenes hiperespectrales se trabaja con cientos de variables, muchas de las cuales solo contienen ruido y/o información redundante por lo que es muy conveniente aplicar un algoritmo capaz de reducirlas y trabajar con un número reducido de ellas. Este aspecto se hace incluso más importante de cara a aplicaciones prácticas donde reducir la cantidad de información a tratar mejora mucho la velocidad además de que suele mejorar los resultados cualitativos.

En muchas industrias, el tener más variables supone más dinero, por lo que se hace vital el reducir el número de mediciones de un proceso al mínimo, manteniendo la información necesaria para un correcto funcionamiento del proceso, con el objetivo de reducir costes.

Aunque existen muchos tipos de métodos de selección de variables, los algoritmos genéticos (GA) nos dan un método directo para ello basado en la supervivencia de las variables que mejor se ajustan. Otro método interesante es el IPLS o intervalos de PLS para selección de variables que a diferencia del algoritmo genético realiza una búsqueda exhaustiva.

4.1. Algoritmos genéticos

Dado un conjunto de datos X para predecir Y valores, se escogen un subconjunto aleatorio de variables de X . A través de la validación cruzada se determina el error cuadrático medio de la validación cruzada (RMSECV) obtenido al usar solo ese subconjunto de variables. Los algoritmos genéticos utilizan esta aproximación de forma iterativa para obtener el subconjunto que proporciona el menor RMSECV (Leardi, 2000).

El primer paso es generar un número muy grande de selecciones aleatorias de variables, o el máximo posible si se utiliza un método de regresión como PLS, y calcular el RMSECV para cada una de ellas.

Cada subconjunto de variables vamos a llamarlos individuos, a las variables que pertenecen a estos individuos lo llamaremos genes y al conjunto de individuos población.

El grado de ajuste del modelo puede ser superior utilizando menos variables debido a que puede que estemos eliminando variables que contienen más ruido que información útil.

El segundo paso es seleccionar todos los individuos cuyo grado de ajuste (menor RMSECV) esté por encima de la mediana de la población y descartar el resto. Con esto se consigue filtrar más de la mitad de la población inicial. Para reemplazar los individuos quitados, se “mutan” los retenidos que consiste en mezclarlos.

Se pueden mezclar de muchas formas, pero los métodos más utilizados son:

Apéndice A: Modelos estadísticos para el análisis de imagen multivariante

- El cruce simple: Se dividen dos individuos aleatorios en dos partes de sus genes cada uno. Ahora se intercambian esas partes entre los individuos generando nuevos individuos que se añaden a la población.
- El cruce doble: La diferencia respecto al anterior es que se escoge una sección de los genes de los individuos y se cambia ese trozo con el trozo de otro individuo.

La principal diferencia práctica entre ambos métodos es que el cruce doble produce nuevos individuos más parecidos a los antiguos que con el cruce simple.

Después de añadir los nuevos individuos, se da una posibilidad de que los genes de los individuos muten. El objetivo de esto es que haya probabilidades de reducir o aumentar el número de variables para mejorar el modelo dentro de la población.

Por último, se vuelve al segundo paso hasta que se alcance el criterio de parada, que puede ser que los individuos no cambien, que el valor de RMSECV no varíe de forma sustancial o que se programe su parada después de n iteraciones.

Uno de los mayores riesgos al utilizar un algoritmo genético es el “over-fitting” es decir, que se elijan variables que sean muy buenas para los datos de los que se dispone pero a la hora de probar el modelo con datos nuevos funcione mal.

Para evitar el over-fitting se recomiendan seguir estos consejos:

- Ajustar un criterio de parada razonable dependiendo de la aplicación.
- Repetir el algoritmo genético muchas veces y observar la tendencia que sigue.
- Utilizar grupos de variables cuando se empleen muchas variables.

4.2. Intervalos de PLS

De forma similar al algoritmo GA descrito anteriormente, IPLS selecciona un sub-conjunto de variables que producen un valor superior de predicción respecto a utilizar todas las variables. A diferencia del GA, este método realiza una búsqueda secuencial y exhaustiva para encontrar la mejor combinación de variables posible (Norgaard et al., 2000). Puede funcionar hacia adelante o hacia atrás. La diferencia radica en que hacia adelante empieza con una variable o intervalo y va añadiendo las mejores y hacia atrás en que empieza con todas y va quitando las peores. El método consiste en realizar tantos modelos PLS como variables se tiene y que en cada uno de ellos solo se utilice esa variable de forma que se escoja la mejor variable en función del RMSECV.

El siguiente paso es coger esa variable y combinarla con cada una del resto de variables, realizar modelos PLS y quedarse con la mejor.

De esta forma se van añadiendo variables hasta que el RMSECV no mejora o hasta alcanzar el número de variables deseadas.

Se puede utilizar las variables individuales, grupos de variables individuales o grupos de variables repetidas dependiendo de si las variables tiene información correlacionada entre ellas o del número de variables con las que se trabaje.

Hay que tener en cuenta que por la forma de trabajar del PLS de coger cada vez el mejor intervalo, se puede dar la situación que por ejemplo primero escoja el intervalo 10 y luego el 3 cuando la mejor combinación de dos intervalos sean la 5 y la 6. Para evitar estas situaciones se puede repetir el algoritmo varias veces con distintos bloques de variables y ver la tendencia que siguen.

Al igual que con los métodos genéticos, se corre el riesgo del over-fitting por lo que se recomienda seguir los mismo consejos anteriormente comentados.

Bibliografía

Abney, & Festing. (1886). Intensity of Radiation through Turbid Media. *Proceedings of the Royal Society of London*, 40, 378 – 380.

Alander, J. T., Bochko, V., Martinkauppi, B., Saranwong, S., & Mantere, T. (2013). A review of optical nondestructive visual and near-infrared methods for food quality and safety. *International Journal of Spectroscopy*, 2013. Retrieved from <http://www.hindawi.com/journals/ij/s/2013/341402/abs/>

Andres, S., A.L, S. A. S.-P., Martins C., B.-S. A. ., & I, M. (2008). The use of visible and near infrared reflectance spectroscopy to predict beef M. longissimus thoracis et lumborum quality attributes. *Meat Science*, 78, 217 – 224.

Awad, T. S., Moharram, H. A., Shaltout, O. E., Asker, D., & Youssef, M. M. (2012). Applications of ultrasound in analysis, processing and quality control of food: A review. *Food Research International*, 48(2), 410 – 427. doi:<http://dx.doi.org/10.1016/j.foodres.2012.05.004>

Barak, S., Mudgil, D., & Khatkar, B. S. (2013). Relationship of gliadin and glutenin proteins with dough rheology, flour pasting and bread making performance of wheat varieties. *LWT - Food Science and Technology*, 51(1), 211–217. doi:10.1016/j.lwt.2012.09.011

Barat, L, G., E, G.-B., M.C, K. C. A., F, T., R, M., & J, S. (2008). Freshness monitoring of sea bream (*Sparus aurata*) with a potentiometric sensor. *Food Chemistry*, 108, 681 – 688.

- Barcelon, E. G., Tojo, S., & Watanabe, K. (1999). X - ray Computed Tomography for Internal Quality Evaluation of Peaches. *Journal of Agricultural Engineering Research*, 73(4), 323 – 330. doi:DOI: 10.1006/jaer.1999.0409
- Barker, M., & Rayens, W. (2003). Partial least squares for discrimination. *Journal of Chemometrics*, 17, 8.
- Barnes, M., Duckett, T., Cielniak, G., Stroud, G., & Harper, G. (2010a). Visual detection of blemishes in potatoes using minimalist boosted classifiers. *Journal of Food Engineering*, 98(3), 339–346. doi:10.1016/j.jfoodeng.2010.01.010
- Barnes, M., Duckett, T., Cielniak, G., Stroud, G., & Harper, G. (2010b). Visual detection of blemishes in potatoes using minimalist boosted classifiers. *Journal of Food Engineering*, 98(3), 339–346. doi:10.1016/j.jfoodeng.2010.01.010
- Bharati, M. H., & Champagne, M. (2004). Using near-infrared multivariate image regression to predict pulp properties. *Tappi Journal*, 3(5), 8 – 14.
- Brosnan, T., & Sun, D.-W. (2002). Inspection and grading of agricultural and food products by computer vision systems—a review. *Computers and Electronics in Agriculture*, 36(2–3), 193–213. doi:10.1016/S0168-1699(02)00101-1
- Buckley, S. J., Kurz, T. H., Howell, J. A., & Schneider, D. (2013). Terrestrial lidar and hyperspectral data fusion products for geological outcrop analysis. *Computers & Geosciences*, 54(0), 249–258. doi:10.1016/j.cageo.2013.01.018
- Busemeyer, L., Mentrup, D., Möller, K., Wunder, E., Alheit, K., Hahn, V., ... Ruckelshausen, A. (2013). BreedVision — A Multi-Sensor Platform for Non-Destructive Field-Based Phenotyping in Plant Breeding. *Sensors*, 13(3), 2830–2847. doi:10.3390/s130302830

Bibliografía

- Chalidabhongse, T., Yimyam, P., & Sirisomboon, P. (2006). 2D/3D Vision-Based Mango's Feature Extraction and Sorting. In *Control, Automation, Robotics and Vision, 2006. ICARCV '06. 9th International Conference on* (pp. 1–6). doi:10.1109/ICARCV.2006.345248
- Chao, K., Yang, C. C., Chen, Y. R., Kim, M. S., & Chan, D. E. (2007). Hyperspectral-Multispectral Line-Scan Imaging System for Automated Poultry Carcass Inspection Applications for Food Safety. *Poultry Science*, 86(11), 2450–2460.
- Chéné, Y., Rousseau, D., Lucidarme, P., Bertheloot, J., Caffier, V., Morel, P., ... Chapeau-Blondeau, F. (2012). On the use of depth camera for 3D phenotyping of entire plants. *Computers and Electronics in Agriculture*, 82(0), 122 – 127. doi:http://dx.doi.org/10.1016/j.compag.2011.12.007
- Chen, M.-Y., Yang, Y.-H., Ho, C.-J., Wang, S.-H., Liu, S.-M., Chang, E., ... Ouhyoung, M. (2012). Automatic Chinese food identification and quantity estimation (pp. 1–4). ACM Press. doi:10.1145/2407746.2407775
- Chen, P., & Sun, Z. (1991). A review of non-destructive methods for quality evaluation and sorting of agricultural products. *Journal of Agricultural Engineering Research*, 49, 85 – 98. doi: 10.1016/0021-8634(91)80030-I
- Chen, Z.-P., Morris, J., & Martin, E. (2006). Extracting chemical information from spectral data with multiplicative light scattering effects by optical path-length estimation and correction. *Analytical Chemistry*, 78(22), 7674–7681.
- Christy, A. A., Kasemsumran, S., Du, Y., & Ozaki, Y. (2004). The detection and quantification of adulteration in olive oil by near-infrared spectroscopy and chemometrics. *Analytical*

- Sciences : The International Journal of the Japan Society for Analytical Chemistry*, 20(6), 935–940.
- Cláudio Rosito, J. (2007). Unsupervised multiscale segmentation of color images. *Pattern Recognition Letters*, 28(4), 523–533. doi:10.1016/j.patrec.2006.10.001
- Datta, A. K., & Halder, A. (2008). Status of food process modeling and where do we go from here (Synthesis of the outcome from brainstorming). *Comprehensive Reviews in Food Science and Food Safety*, 7(1), 117–120. doi:10.1111/j.1541-4337.2007.00037.x
- Dowlati, M., Mohtasebi, S. S., Omid, M., Razavi, S. H., Jamzad, M., & de la Guardia, M. (2013). Freshness assessment of gilthead sea bream (*Sparus aurata*) by machine vision based on gill and eye color changes. *Journal of Food Engineering*, 119(2), 277–287. doi:10.1016/j.jfoodeng.2013.05.023
- Ellekjaer, M. R., & Isaksson, T. (1992). Assessment of maximum cooking temperatures in previously heat treated beef. Part 1: Near infrared spectroscopy. *J. Sci. Food Agric.*, 59(3), 335 – 343.
- Ellis, D. I., & Goodacre, R. (2001). Rapid and quantitative detection of the microbial spoilage of muscle foods: current status and future trends. *Trends in Food Science & Technology*, 12(11), 414 – 424. doi:DOI: 10.1016/S0924-2244(02)00019-5
- ElMasry, G., & Sun, D.-W. (2010). Principles of Hyperspectral Imaging Technology. In P. D.-W. Sun (Ed.), *Hyperspectral Imaging for Food Quality Analysis and Control* (pp. 3 – 43). San Diego: Academic Press. Retrieved from <http://www.sciencedirect.com/science/article/B6MC2-500RYK3-7/2/a85f6d3ad3ee858d9ecdbc8adf7ee09a>

Bibliografía

- Fabbri, A., Cevoli, C., Romani, S., & Rosa, M. D. (2011). Numerical model of heat and mass transfer during roasting coffee using 3D digitised geometry. *11th International Congress on Engineering and Food (ICEF11)*, 1, 742–746. doi:10.1016/j.profoo.2011.09.112
- FAO, F. and A. D. (2007). *The state of World Fisheries and Aquaculture 2006*. Food and Agriculture Organization of the United Nations, Rome.
- Farcomeni, A., Serranti, S., & Bonifazi, G. (2008). Non-parametric analysis of infrared spectra for recognition of glass and glass ceramic fragments in recycling plants. *Waste Management*, 28(3), 557 – 564. doi:DOI: 10.1016/j.wasman.2007.01.019
- Fernandez-Segovia, I., Escriche, I., & Serra, J. A. (2008). Evolution of Volatile Fraction and ATP Related Compounds During Storage of Desalted Cod (*Gadus morhua*). *Food Science and Technology International*, 14(5 suppl), 37 – 47. doi:10.1177/1082013208094581
- Foix, S., Alenya, G., & Torras, C. (2011). Lock-in Time-of-Flight (ToF) Cameras: A Survey. *Sensors Journal, IEEE*, 11(9), 1917–1926. doi:10.1109/JSEN.2010.2101060
- Fortunato de Carvalho Rocha, W., Sabin, G. P., Marçõ, P. H., & Poppi, R. J. (2011). Quantitative analysis of piroxicam polymorphs pharmaceutical mixtures by hyperspectral imaging and chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 106(2), 198–204.
- Freund, Y., Schapire, R., & Abe, N. (1999). A short introduction to boosting. *Journal-Japanese Society For Artificial Intelligence*, 14(771-780), 1612.
- Fuentes, A., Barat, J. M., Fernández-Segovia, I., & Serra, J. A. (2008). Study of sea bass (*Dicentrarchus labrax* L.) salting process: Kinetic and thermodynamic control. *Food Control*, 19(8), 757 – 763. doi:DOI: 10.1016/j.foodcont.2007.07.014

- Gastaldi, D., Canonico, F., Irico, S., Pellerej, D., & Paganini, M. (2010). Near-infrared spectroscopy investigation on the hydration degree of a cement paste. *Journal of Materials Science*, *45*, 3169–3174.
- Geladi, P., & Kowalski, B. R. (1986). Partial least-squares regression: a tutorial. *Analytica Chimica Acta*, *185*, 1 – 17. doi:DOI: 10.1016/0003-2670(86)80028-9
- Girón J., Ivorra E., Sánchez A.J, Fernández-Segovia I, Barat J.M., & Grau R. (2013). Preliminary study using visible and SW-NIR analysis for evaluating the loss of freshness in commercially packaged cooked ham and turkey ham. *Czech Journal of Food Sciences.*, *370/2013-CJFS*.
- Gonzalez, J. J., Valle, R. C., Bobroff, S., Biasi, W. V., Mitcham, E. J., & McCarthy, M. J. (2001). Detection and monitoring of internal browning development in Fuji apples using MRI. *Postharvest Biology and Technology*, *22*(2), 179 – 188. doi:DOI: 10.1016/S0925-5214(00)00183-6
- Gowen, A. A., O'Donnell, C. P., Cullen, P. J., Downey, G., & Frias, J. M. (2007). Hyperspectral imaging - an emerging process analytical tool for food quality and safety control. *Trends in Food Science & Technology*, *18*(12), 590 – 598. doi:DOI: 10.1016/j.tifs.2007.06.001
- Grau, R., Sanchez, A. J., Giron, J., Iborra, E., Fuentes, A., & Barat, J. M. (2011a). Nondestructive assessment of freshness in packaged sliced chicken breasts using SWNIR spectroscopy. *Food Research International*, *In Press, Corrected Proof*, 0 – 0. doi:DOI: 10.1016/j.foodres.2010.10.011
- Grau, R., Sanchez, A. J., Giron, J., Iborra, E., Fuentes, A., & Barat, J. M. (2011b). Nondestructive assessment of freshness in packaged sliced chicken breasts using SWNIR spectroscopy.

Bibliografía

- Food Research International*, Volume 44, Issue1, 331–337. doi:DOI: 10.1016/j.foodres.2010.10.011
- Hart, J. R., & Norris, K. H. (1963). Direct Spectrophotometric Determination of Moisture Content of Grain and Seeds. In *Proceedings of the 1963 International Symposium on Humidity and Moisture* (Vol. 4, pp. 19–25).
- Harvey, E., Cappo, M., Shortis, M., Robson, S., Buchanan, J., & Speare, P. (2003). The accuracy and precision of underwater measurements of length and maximum body depth of southern bluefin tuna (*Thunnus maccoyii*) with a stereo–video camera system. *Fisheries Research*, 63(3), 315–326.
- Harvey, E., Shortis, M., Stadler, M., & Cappo, M. (2002). A Comparison of the Accuracy and Precision of Measurements from Single and Stereo-Video Systems. *Marine Technology Society Journal*, 36(2), 38–49. doi:10.4031/002533202787914106
- Hatou, K., Morimoto, T., De Jager, J., & Hashimoto, Y. (1996). Measurement and recognition of 3-D body in intelligent plant factory. In *International Conference on Agricultural Engineering (AgEng)*. Madrid (Vol. 2, pp. 861–862).
- Haug, K., & Pritschow, G. (1998). Robust laser-stripe sensor for automated weld-seam-tracking in the shipbuilding industry (Vol. 2, pp. 1236–1241). Presented at the Industrial Electronics Society, 1998. IECON'98. Proceedings of the 24th Annual Conference of the IEEE, IEEE.
- Hernandez, C., Vogiatzis, G., & Cipolla, R. (2008). Multiview Photometric Stereo. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 30(3), 548–554. doi:10.1109/TPAMI.2007.70820

- Herschel, W. P. (1800). Infrared Experiment. *Royal Society London*, 2, 284 – 292.
- Hill, R. F., Tofts, P. S., & Baldock, C. (2010). The Bland–Altman analysis: Does it have a role in assessing radiation dosimeter performance relative to an established standard? *Radiation Measurements*, 45(7), 810–815. doi:10.1016/j.radmeas.2010.02.003
- Hirschmuller, H., & Scharstein, D. (2007). Evaluation of Cost Functions for Stereo Matching. In *Computer Vision and Pattern Recognition, 2007. CVPR '07. IEEE Conference on* (pp. 1–8). doi:10.1109/CVPR.2007.383248
- Hoche, S., Hussein, W. B., Hussein, M. A., & Becker, T. (2011). Time-of-flight prediction for fermentation process monitoring. *Engineering in Life Sciences*, 11(4), 417–428. doi:10.1002/elsc.201000177
- Horváth, K., Seregély, Z., Andrásy, É., Dalmadi, I., & Farkas, J. (2008). A preliminary study using near infrared spectroscopy to evaluate freshness and detect spoilage in sliced pork meat. *Acta Alimentaria (Budapest)*, 37(1), 93 – 102.
- Hubert, M., & Branden, K. V. (2003). Robust methods for partial least squares regression. *Journal of Chemometrics*, 17(10), 537–549. doi:10.1002/cem.822
- ISO, U.-E. (2003). *Microbiología de los alimentos para consumo humano y animal. Método horizontal para el recuento de microorganismos. Técnica de recuento de colonias a 30 °*
C. UNE-EN.
- ISO, U.-E. (2007). (20473:2007) *Optics and photonics: Spectral bands*. UNE-EN ISO.
- Ivorra, E., Amat, S. V., Sánchez, A. J., Barat, J. M., & Grau, R. (2014). Continuous monitoring of bread dough fermentation using a 3D vision Structured Light technique. *Journal of Food Engineering*, 130, 8–13. doi:10.1016/j.jfoodeng.2013.12.031

Bibliografía

- Ivorra, E., Girón, J., Sánchez, A. J., Verdú, S., Barat, J. M., & Grau, R. (2013). Detection of expired vacuum-packed smoked salmon based on PLS-DA method using hyperspectral images. *Journal of Food Engineering*, *117*(3), 342–349. doi:10.1016/j.jfoodeng.2013.02.022
- Ivorra, E., Sánchez, A., Camarasa, J., Diago, M., & Tardaguila, J. (2014). Assessment of grape cluster yield components based on 3D descriptors using stereo vision. *Food Control*.
- Jackman, P., Sun, D.-W., Du, C.-J., & Allen, P. (2009). Prediction of beef eating qualities from colour, marbling and wavelet surface texture features using homogenous carcass treatment. *Pattern Recognition*, *42*(5), 751–763. doi:10.1016/j.patcog.2008.09.009
- Jackson, J. E., & Mudholkar, G. S. (1979). Control procedures for residuals associated with principal component analysis. *Technometrics*, *21*, 341 – 349.
- Jang, W., Je, C., Seo, Y., & Lee, S. W. (2013). Structured-light stereo: Comparative analysis and integration of structured-light and active stereo for measuring dynamic shape. *Optics and Lasers in Engineering*, *51*(11), 1255 – 1264. doi:http://dx.doi.org/10.1016/j.optlaseng.2013.05.001
- Joo Kim, S., Deng, F., & Brown, M. S. (2011). Visual enhancement of old documents with hyperspectral imaging. *Pattern Recognition*, *44*, 1461–1469. doi:10.1016/j.patcog.2010.12.019
- Kam, N. W. S., O’Connell, M., Wisdom, J. A., & Dai, H. (2005). Carbon nanotubes as multifunctional biological transporters and near-infrared agents for selective cancer cell destruction. *PNAS*, *102*(33), 11600–11605. doi:10.1073/pnas.0502680102

- Karube, I., Matsuoka, H., Suzuki, S., Watanabe, E., & Toyama, K. (1984). Determination of fish freshness with an enzyme sensor system. *Journal of Agricultural and Food Chemistry*, 32(2), 314–319. doi:10.1021/jf00122a034
- Kazmi, W., Foix, S., Alenyà, G., & Andersen, H. J. (2014). Indoor and outdoor depth imaging of leaves with time-of-flight and stereo vision sensors: Analysis and comparison. *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, 128–146.
- Kelkar, S., Stella, S., Boushey, C., & Okos, M. (2011). Developing novel 3D measurement techniques and prediction method for food density determination. *11th International Congress on Engineering and Food (ICEF11)*, 1, 483–491. doi:10.1016/j.profoo.2011.09.074
- Kendall, M. (1970). Rank Correlation Methods (4th edn.) Griffin. London, UK.
- Kim, S.-M., Chen, P., McCarthy, M. J., & Zion, B. (1999). Fruit Internal Quality Evaluation using On-line Nuclear Magnetic Resonance Sensors. *Journal of Agricultural Engineering Research*, 74(3), 293 – 301. doi:DOI: 10.1006/jaer.1999.0465
- Klose, R., Penlington, J., & Ruckelshausen, A. (2009). Usability study of 3D Time-of-Flight cameras for automatic plant phenotyping. *Bornimer Agrartechnische Berichte*, 69, 93–105.
- Kurz, T., Buckley, S., Howell, J., & Schneider, D. (2008). Geological outcrop modelling and interpretation using ground based hyperspectral and laser scanning data fusion. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, B5.

Bibliografía

- Larsen, A. B. L., Hviid, M. S., Jørgensen, M. E., Larsen, R., & Dahl, A. L. (2014). Vision-based method for tracking meat cuts in slaughterhouses. *Meat Science*, *96*(1), 366–372.
- Lazaros, N., Sirakoulis, G. C., & Gasteratos, A. (2008). Review of Stereo Vision Algorithms: From Software to Hardware. *International Journal of Optomechatronics*, *2*(4), 435–462.
doi:10.1080/15599610802438680
- Learidi, R. (2000). Application of genetic algorithm PLS for feature selection in spectral data sets. *J. Chemometrics*, *14*(5-6), 643 – 655.
- Lin, M. and A.-H., Mousavi-Hesary, M., Al-Qadiri, H., C., & Rasco, B. (2004). Rapid and quantitative detection of the microbial spoilage in chicken meat by diffuse reflectance spectroscopy (600 a 1100 nm). *Letters in Applied Microbiology*, *39*, 148 – 155.
doi:10.1111/j.1472-765X.2004.01546.x
- Liu, Y., Lyon, B. G., Windham, W. R., Realini, C. E., Pringle, T. D. D., & Duckett, S. (2003). Prediction of color, texture, and sensory characteristics of beef steaks by visible and near infrared reflectance spectroscopy. A feasibility study. *Meat Science*, *65*(3), 1107 – 1115. doi:DOI: 10.1016/S0309-1740(02)00328-5
- Luan, X. (2001). *Experimental investigation of photonic mixer device and development of TOF 3D ranging systems based on PMD technology*. Universitätsbibliothek.
- Magwaza, L. S., Opara, U. L., Nieuwoudt, H., Cronje, P. J., Saeys, W., & Nicolaï, B. (2012). NIR spectroscopy applications for internal and external quality analysis of citrus fruit—a review. *Food and Bioprocess Technology*, *5*(2), 425–444.

- Mallat, S., & Zhong, S. (1992). Characterization of Signals from Multiscale Edges. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, *14*, 710–732. doi:<http://doi.ieeecomputersociety.org/10.1109/34.142909>
- Malle, & Tao. (1987). Rapid quantitative determination of trimethylamine using steam distillation. *Journal of Food Protection*, *50*, 756.
- Mallet, D., & Pelletier, D. (2014). Underwater video techniques for observing coastal marine biodiversity: A review of sixty years of publications (1952–2012). *Fisheries Research*, *154*, 44–62.
- Martin Bland, J., & Altman, D. (1986). Statistical methods for assessing agreement between two methods of clinical measurement. *Originally Published as Volume 1, Issue 8476, 327(8476)*, 307–310. doi:10.1016/S0140-6736(86)90837-8
- Martinez-de Dios, J. R., Serna, C., & Ollero, A. (2003). Computer vision and robotics techniques in fish farms. *Robotica*, *21(03)*, 233–243. doi:10.1017/S0263574702004733
- Mathiassen, J. R., Misimi, E., Toldnes, B., Bondø, M., & Østvik, S. O. (2011). High-Speed Weight Estimation of Whole Herring (*Clupea harengus*) Using 3D Machine Vision. *Journal of Food Science*, *76(6)*, E458–E464. doi:10.1111/j.1750-3841.2011.02226.x
- Mayes, D. M., & Callis, J. B. (1989). A Photodiode-Array-Based Near-Infrared Spectrophotometer for the 600 a 1100 nm Wavelength Region. *Appl. Spectrosc.*, *43(1)*, 27 – 32.
- Mehl, P. M., Chen, Y.-R., Kim, M. S., & Chan, D. E. (2004). Development of hyperspectral imaging technique for the detection of apple surface defects and contaminations. *Applications of*

Bibliografía

- Computer Vision in the Food Industry*, 61(1), 67–81. doi:10.1016/S0260-8774(03)00188-2
- Misimi, E., Erikson, U., Digre, H., Skavhaug, A., & Mathiassen, J. R. (2008). Computer Vision-Based Evaluation of Pre-and Postrigor Changes in Size and Shape of Atlantic Cod (*Gadus morhua*) and Atlantic Salmon (*Salmo salar*) Fillets during Rigor Mortis and Ice Storage: Effects of Perimortem Handling Stress. *Journal of Food Science*, 73(2), E57–E68.
- Monziols, M., Collewet, G., Bonneau, M., Mariette, F., Davenel, A., & Kouba, M. (2006). Quantification of muscle, subcutaneous fat and intermuscular fat in pig carcasses and cuts by magnetic resonance imaging. *Meat Science*, 72(1), 146 – 154. doi:DOI: 10.1016/j.meatsci.2005.06.018
- Mufti, F., & Mahony, R. (2011). Statistical analysis of signal measurement in time-of-flight cameras. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(5), 720–731. doi:10.1016/j.isprsjprs.2011.06.004
- Mundt, J. T., Streutker, D. R., & Glenn, N. F. (2006). Mapping Sagebrush Distribution Using Fusion of Hyperspectral and Lidar Classifications. *Photogrammetric Engineering & Remote Sensing*, 72(1), 47–54. doi:10.14358/PERS.72.1.47
- Musse, M., Challoy, S., Huc, D., Quéllec, S., & Mariette, F. (2014). {MRI} method for investigation of eye growth in semi-hard cheese. *Journal of Food Engineering*, 121(0), 152 – 158. doi:http://dx.doi.org/10.1016/j.jfoodeng.2013.08.010
- Naidoo, L., Cho, M. A., Mathieu, R., & Asner, G. (2012). Classification of savanna tree species, in the Greater Kruger National Park region, by integrating hyperspectral and LiDAR data in

- a Random Forest data mining environment. *ISPRS Journal of Photogrammetry and Remote Sensing*, 69(0), 167–179. doi:10.1016/j.isprsjprs.2012.03.005
- Nayar, S. K., Watanabe, M., & Noguchi, M. (1996). Real-time focus range sensor. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 18(12), 1186–1198.
- Nicolai, B. M., Beullens, K., Bobelyn, E., Peirs, A., Saeys, W., Theron, K. I., & Lammertyn, J. (2007). Nondestructive measurement of fruit and vegetable quality by means of NIR spectroscopy: A review. *Postharvest Biology and Technology*, 46(2), 99 – 118. doi:DOI: 10.1016/j.postharvbio.2007.06.024
- Nielsen, M., Slaughter, D. C., & Gliever, C. (2012). Vision-Based 3D Peach Tree Reconstruction for Automated Blossom Thinning. *Industrial Informatics, IEEE Transactions on*, 8(1), 188–196. doi:10.1109/TII.2011.2166780
- Nobuyuki Otsu. (1979, January 1). A Threshold Selection Method from Gray-Level Histograms. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS*, SMC-9(1). Retrieved from http://web.ics.purdue.edu/~kim497/ece661/OTSU_paper.pdf
- Norgaard, L., Saudland, A., Wagner, J., Nielsen, J. P., Munck, L., & Engelsen, S. B. (2000). Interval Partial Least-Squares Regression (iPLS): A Comparative Chemometric Study with an Example from Near-Infrared Spectroscopy. *Appl. Spectrosc.*, 54(3), 413 – 419.
- Nyström, D. (2007). Colorimetric and Multispectral Image Acquisition Using Model Based and Empirical Device Characterization. In B. Ersball & K. Pedersen (Eds.), *Image Analysis* (Vol. 4522, pp. 798 – 807). Springer Berlin Heidelberg. Retrieved from http://dx.doi.org/10.1007/978-3-540-73040-8_81

Bibliografía

- OIV. (2007). World Vitivinicultural Statistics 2007 - Structure of the World Vitivinicultural Industry 2007. *Online International Organization of Vine and Wine*. Retrieved from http://news.reseauconcept.net/images/oiv_uk/Client/Statistiques_commentaires_annees_2007_EN.pdf
- Paluchowski, L. A., Denstedt, M., Røren, T., Pukstad, B., & Randeberg, L. L. (2013). A combined 3D and hyperspectral method for surface imaging of wounds. In B. J. Tromberg, A. G. Yodh, & E. M. Sevick-Muraca (Eds.), (p. 85780T). doi:10.1117/12.2001248
- Patel, K., Khan, M., & Kar, A. (2013). Recent developments in applications of MRI techniques for foods and agricultural produce—an overview. *Journal of Food Science and Technology*, 1–26. doi:10.1007/s13197-012-0917-3
- Paulus, S., Schumann, H., Kuhlmann, H., & Léon, J. (2014). High-precision laser scanning system for capturing 3D plant architecture and analysing growth of cereal plants. *Biosystems Engineering*, 121(0), 1 – 11. doi:<http://dx.doi.org/10.1016/j.biosystemseng.2014.01.010>
- Paviotti, A., & Poletto, L. (2008). Performance characterization of an imaging spectrograph for the acquisition and analysis of multispectral images. In *16th European Signal Processing Conference (EUSIPCO 2008)*.
- Peiravi, A., & Taabbodi, B. (2010). A reliable 3D laser triangulation-based scanner with a new simple but accurate procedure for finding scanner parameters. *Journal of American Science*, 6(5), 80–85.
- Petrell, R. J., Shi, X., Ward, R. K., Naiberg, A., & Savage, C. R. (1997). Determining fish size and swimming speed in cages and tanks using simple video techniques. *Aquacultural Engineering*, 16(1), 63–84.

- Plaue, M. (2006). Technical Report: Analysis of the PMD Imaging System. *Interdisciplinary Center for Scientific Computing, University of Heidelberg*.
- Poussart, D., & Laurendeau, D. (1988). Advances in Machine Vision. In J. L. C. Sanz (Ed.), (pp. 122–159). New York, NY, USA: Springer-Verlag New York, Inc. Retrieved from <http://dl.acm.org/citation.cfm?id=57360.57363>
- Quevedo, R., & Aguilera, J. M. (2010). Computer Vision and Stereoscopy for Estimating Firmness in the Salmon (Salmon salar) Fillets. *Food and Bioprocess Technology*, 3(4), 561–567. doi:10.1007/s11947-008-0097-3
- Qu, J.-H., Liu, D., Cheng, J.-H., Sun, D.-W., Ma, J., Pu, H., & Zeng, X.-A. (2014). Applications of near infrared spectroscopy in food safety evaluation and control: a review of recent research advances. *Critical Reviews in Food Science and Nutrition*, (just-accepted).
- Roger, J., Palagos, B., Guillaume, S., & Bellon-Maurel, V. (2005). Discriminating from highly multivariate data by focal eigen function discriminant analysis; application to NIR spectra. *Chemometrics and Intelligent Laboratory Systems*, 79(1), 31–41.
- Rönholm, P., Honkavaara, E., Litkey, P., Hyyppä, H., & Hyyppä, J. (2007). Integration of laser scanning and photogrammetry. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39, 355–362.
- Rovira-Más, F., Zhang, Q., & Reid, J. F. (2008). Stereo vision three-dimensional terrain maps for precision agriculture. *Computers and Electronics in Agriculture*, 60(2), 133–143. doi:10.1016/j.compag.2007.07.007

Bibliografía

- Ruff, B. P., Marchant, J. A., & Frost, A. R. (1995). Fish sizing and monitoring using a stereo image analysis system applied to fish farming. *Aquacultural Engineering*, *14*(2), 155–173. doi:10.1016/0144-8609(94)P4433-C
- Rusu, R. B., Blodow, N., & Beetz, M. (2009). Fast Point Feature Histograms (FPFH) for 3D registration. In *Robotics and Automation, 2009. ICRA '09. IEEE International Conference on* (pp. 3212–3217). doi:10.1109/ROBOT.2009.5152473
- Rusu, R. B., & Cousins, S. (2011). 3D is here: Point Cloud Library (PCL). In *IEEE International Conference on Robotics and Automation (ICRA)*. Shanghai, China.
- Salmanizadeh, F., Nassiri, S. M., Jafari, A., & Bagheri, M. H. (2014). Volume Estimation of two Local Pomegranate Fruit (*Punica Granatum L.*) Cultivars and their Components Using Non-Destructive X-Ray Computed Tomography Technique. *International Journal of Food Properties*, *0*(ja), null. doi:10.1080/10942912.2013.833521
- Sánchez, A. J., Albarracin, W., Grau, R., Ricolfe, C., & Barat, J. M. (2008a). Control of ham salting by using image segmentation. *Food Control*, *19*(2), 135–142. doi:10.1016/j.foodcont.2007.02.012
- Sánchez, A. J., Albarracin, W., Grau, R., Ricolfe, C., & Barat, J. M. (2008b). Control of ham salting by using image segmentation. *Food Control*, *19*(2), 135–142. doi:10.1016/j.foodcont.2007.02.012
- Schapire, R., & Singer, Y. (1999). Improved Boosting Algorithms Using Confidence-rated Predictions. *Machine Learning*, *37*(3), 297–336. doi:10.1023/A:1007614523901

- Scheunders, P. (2002). A multivalued image wavelet representation based on multiscale fundamental forms. *Image Processing, IEEE Transactions on*, 11(5), 568 – 575. doi:10.1109/TIP.2002.1006403
- Schölkopf, B., Smola, A. J., Williamson, R. C., & Bartlett, P. L. (2000). New Support Vector Algorithms. *Neural Computation*, 12(5), 1207–1245. doi:10.1162/089976600300015565
- Sijmen de Jong. (1993). SIMPLS: An alternative approach to partial least squares regression. *Chemometrics and Intelligent Laboratory Systems*, 18(3), 251–263. doi:10.1016/0169-7439(93)85002-X
- Sinelli, N., Cerretani, L., Egidio, V. D., Bendini, A., & Casiraghi, E. (2010). Application of near (NIR) infrared and mid (MIR) infrared spectroscopy as a rapid tool to classify extra virgin olive oil on the basis of fruity attribute intensity. *Food Research International*, 43(1), 369 – 375. doi:DOI: 10.1016/j.foodres.2009.10.008
- Stien, L. H., Kiessling, A., & Manne, F. (2007). Rapid estimation of fat content in salmon fillets by colour image analysis. *Journal of Food Composition and Analysis*, 20(2), 73–79. doi:doi: 10.1016/j.jfca.2006.07.007
- Sun, C., Berman, M., Coward, D., & Osborne, B. (2007). Thickness measurement and crease detection of wheat grains using stereo vision. *Pattern Recognition Letters*, 28(12), 1501–1508. doi:10.1016/j.patrec.2007.03.008
- Trobina, M. (1995). Error model of a coded-light range sensor. *Technique Report, Communication Technology Laboratory*.

Bibliografía

- Trujillo, F. J., & Pham, Q. T. (2006). A computational fluid dynamic model of the heat and moisture transfer during beef chilling. *Issue with Special Emphasis on Data and Models on Food Refrigeration*, 29(6), 998–1009. doi:10.1016/j.ijrefrig.2006.05.001
- USDA Nutrient Data Laboratory. (2012). *Food composition*. (Online searchable database of foods.). U.S. Department of Agriculture.
- Uyar, R., & Erdoğan, F. (2009). Potential use of 3-dimensional scanners for food process modeling. *Journal of Food Engineering*, 93(3), 337–343. doi:10.1016/j.jfoodeng.2009.01.034
- Vanaclocha, A. C., & Requena, J. A. (2003). *Procesos de conservación de alimentos*. A. Madrid Vicente : Mundi - Prensa.
- Vapnik, V. (1998). *Statistical learning theory new york*. NY: Wiley.
- Veliyulin, E., Misimi, E., Bondø, M., Veberstad, P. A., & Østvik, S. O. (2011). A Simple Method for Weight Estimation of Whole Herring (*Clupea harengus*) Using Planar X-Ray Imaging. *Journal of Food Science*, 76(3), E328–E331. doi:10.1111/j.1750-3841.2011.02093.x
- Verdú, S., Ivorra, E., Sánchez, A. J., Girón, J., Barat, J. M., & Grau, R. (2013a). Comparison of {TOF} and {SL} techniques for in-line measurement of food item volume using animal and vegetable tissues. *Food Control*, 33(1), 221 – 226. doi:http://dx.doi.org/10.1016/j.foodcont.2013.02.031
- Verdú, S., Ivorra, E., Sánchez, A. J., Girón, J., Barat, J. M., & Grau, R. (2013b). Comparison of TOF and SL techniques for in-line measurement of food item volume using animal and vegetable tissues. *Food Control*, 33(1), 221–226. doi:10.1016/j.foodcont.2013.02.031

- Verdú, S., Ivorra, E., Sánchez, A. J., Barat, J. M., & Grau, R. (2015) Study of high strength wheat flours considering their physicochemical and rheological characterisation as well as fermentation capacity using SW-NIR imaging. *Journal of Cereal Science* (Available online, In Press, Accepted Manuscript). doi:10.1016/j.jcs.2014.11.002
- Verikas, A., Malmqvist, K., & Bergman, L. (1997). Colour image segmentation by modular neural network. *Pattern Recognition Letters*, 18(2), 173–185. doi:10.1016/S0167-8655(97)00004-4
- Wallays, C., Missotten, B., Baerdemaeker, J. D., & Saeys, W. (2009). Hyperspectral waveband selection for on-line measurement of grain cleanness. *Biosystems Engineering*, 104(1), 1 – 7. doi:DOI: 10.1016/j.biosystemseng.2009.05.011
- Wang, W., & Li, C. (2014). Size estimation of sweet onions using consumer-grade RGB-depth sensor. *Journal of Food Engineering*, 142(0), 153 – 162. doi:http://dx.doi.org/10.1016/j.jfoodeng.2014.06.019
- Williams, P. C., & Norris, K. (2001). *Near infrared technology in the agriculture and food industries*. (P. Williams & K. Norris, Eds.). Wisconsin University, Madison, USA: AACC Press.
- Wold, H., & Lyttkens, E. (1969). Nonlinear iterative partial least squares (NIPALS) estimation procedures. *Bulletin of the International Statistical Institute*, 43(1).
- Wold, S., Geladi, P., Esbensen, K., & Jerker. (1987). Multi-way principal components-and PLS-analysis. *J. Chemometrics*, 1(1), 41 – 56.
- Wold, S., & Sjostrom, M. (1977). SIMCA: A Method for Analyzing Chemical Data in Terms of Similarity and Analogy. In B. Kowalski (Ed.), *Chemometrics: Theory and Application* (pp.

Bibliografía

- 243 – 282). AMERICAN CHEMICAL SOCIETY. Retrieved from <http://pubs.acs.org/doi/abs/10.1021/bk-1977-0052.ch012>
- Woodford, O., Pham, M.-T., Maki, A., Perbet, F., & Stenger, B. (2014). Demisting the Hough Transform for 3D Shape Recognition and Registration. *International Journal of Computer Vision*, *106*(3), 332–341. doi:10.1007/s11263-013-0623-2
- Woodham, R. J. (1980). Photometric Method For Determining Surface Orientation From Multiple Images. *Optical Engineering*, *19*(1), 191139. doi:10.1117/12.7972479
- Wu, D., He, Y., & Feng, S. (2008). Short-wave near-infrared spectroscopy analysis of major compounds in milk powder and wavelength assignment. *Analytica Chimica Acta*, *610*(2), 232 – 242. doi:DOI: 10.1016/j.aca.2008.01.056
- Wu, D., He, Y., Feng, S., & Sun, D.-W. (2008). Study on infrared spectroscopy technique for fast measurement of protein content in milk powder based on LS-SVM. *Journal of Food Engineering*, *84*(1), 124 – 131. doi:DOI: 10.1016/j.jfoodeng.2007.04.031
- Wyszecki, G. (2000). *Color science : concepts and methods, quantitative data, and formulae* (Wiley classics library ed.). New York: John Wiley & Sons.
- Xiang, R., Jiang, H., & Ying, Y. (2014). Recognition of clustered tomatoes based on binocular stereo vision. *Computers and Electronics in Agriculture*, *106*, 75–90.
- Xiaohan, Y., Ylä-Jääski, J., & Baozong, Y. (1991). A new algorithm for texture segmentation based on edge detection. *Pattern Recognition*, *24*(11), 1105–1112. doi:10.1016/0031-3203(91)90125-O

- Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., & Liu, C. (2014). Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International*, *62*, 326–343.
- Zhang, S. (2010). Recent progresses on real-time 3D shape measurement using digital fringe projection techniques. *Optics and Lasers in Engineering*, *48*(2), 149 – 158.
doi:<http://dx.doi.org/10.1016/j.optlaseng.2009.03.008>
- Zhang, Z. (2000). A Flexible New Technique for Camera Calibration. *IEEE Trans. Pattern Anal. Mach. Intell.*, *22*(11), 1330–1334.