

FACULTAD DE INGENIERIA

CARRERA DE INGENIERIA INDUSTRIAL

“COMPARACIÓN DE TRES SISTEMAS EXPERTOS Y
DIFERENTES ESPACIOS DE COLOR EN LA
CLASIFICACIÓN DEL GRADO DE MADUREZ DE FRUTOS
DE AGUAYMANTO (*PHYSALIS PERUVIANA L.*)”

Tesis para optar el título profesional de:

Ingeniero Industrial

Autores:

Bach. Bazán Soriano Karen Stefany
Bach. Cotrina Bazán Carlos Adrián

Asesor:

Dr. Wilson Manuel Castro Silupu

Cajamarca – Perú
2018

ÍNDICE DE CONTENIDOS

CAPITULO 1. INTRODUCCIÓN	13
1.1. Realidad problemática.....	13
1.2. Formulación del problema	17
1.3. Justificación	17
1.4. Limitaciones.....	17
1.5. Objetivos.....	17
1.5.1. <i>Objetivo general</i>	17
1.5.2. <i>Objetivos específicos</i>	17
CAPITULO 2. MARCO TEÓRICO.....	18
2.1. Antecedentes	18
2.2. Bases teóricas	20
2.2.1. <i>Aguaymanto (Physalis Peruaviana L.)</i>	20
2.2.2. <i>Visión tradicional por computadora</i>	21
2.2.3. <i>Construcción básica de un Sistema de Visión Computarizada</i>	22
2.2.4. <i>Técnicas de inteligencia artificial</i>	24
2.3. Hipótesis.....	26
2.3.1. <i>Formulación de hipótesis</i>	27
2.3.2. <i>Variables</i>	27
CAPITULO 3. METODOLOGÍA	28
3.1. Diseño de investigación.....	28
3.2. Materiales y métodos	28
3.2.1. <i>Muestras de aguaymanto</i>	28
3.2.2. <i>Sistema de visión computarizada para la clasificación de frutos de aguaymanto</i>	29
3.3. Unidad de estudio	32
3.4. Población.....	32
3.5. Muestra (muestreo o selección).....	32
3.6. Técnicas, instrumentos y procedimientos de recolección de datos.....	33
a) Clasificación visual por color	33
b) Obtención y procesamiento de imágenes RGB	33
c) Obtención de parámetros de color y estadísticos	35
d) Determinación de parámetros de interés.....	37
e) Generación de clasificadores.....	38

f) Evaluación de eficacia de clasificadores.....	38
CAPITULO 4. RESULTADOS.....	39
4.1. Implementación de un sistema de visión computarizada para la adquisición de imágenes RGB.....	39
4.2. Clasificación Visual por color.....	39
4.3. Obtención y procesamiento de imágenes RGB.....	41
4.4. Obtención de parámetros de color.....	41
4.5. Determinación de parámetros de interés	43
4.6. Generación y evaluación de clasificadores	43
CAPITULO 5. DISCUSIÓN	47
5.1. Color de frutos de aguaymanto durante la maduración	47
5.2. Construcción del modelo	49
5.3. Evaluación del modelo	55
CONCLUSIONES	57
RECOMENDACIONES.....	58
REFERENCIAS	59
ANEXOS	66

ÍNDICE DE TABLAS

Tabla 1. Parámetros de color utilizados para la clasificación	15
Tabla 2. Evaluación de la maduración de vegetales utilizando sistemas expertos en diferentes espacios de color.	16
Tabla 3. Principales ecotipos de aguaymanto	21
Tabla 4. Ejemplo de conjunto de datos	25
Tabla 5. Muestras de aguaymanto por nivel de madurez.....	40
Tabla 6. Matrices de confusión para las técnicas de clasificación con 18 parámetros. *ACC: accuracy; ERR: Error; PRC: Precision.....	43
Tabla 7. Matrices de confusión para las técnicas de clasificación con 6 parámetros de interés. *ACC: accuracy; ERR: Error; PRC: Precisión.	44
Tabla 8. Parámetros de color en el espacio $L^* a^* b^*$ en la etapa de maduración de los frutos de aguaymanto.	49

ÍNDICE DE FIGURAS

Figura 1. Imagen RGB a color de un durazno y sus imágenes componentes	22
Figura 2. Esquema de un Sistema tradicional de visión computarizada.....	23
Figura 3. Ejemplo de un árbol de decisión	24
Figura 4. Ejemplo de la arquitectura de una Red Neuronal Artificial..	26
Figura 5. Metodología Experimental.	28
Figura 6. Estados de maduración del aguaymanto	29
Figura 7. Aguaymanto en diferentes etapas de maduración.....	29
Figura 8. Esquema del sistema de visión computarizada.	30
Figura 9. Vista interna del sistema de visión computarizada.	30
Figura 10. GUI para captura de imágenes.	31
Figura 11. Sistema de clasificación automatizado para la clasificación de frutos de aguaymanto.	32
Figura 12. Diseño de un sistema para procesamiento de imágenes.....	33
Figura 13. Construcción de Sistema para la adquisición de imágenes RGB.....	39
Figura 14. Niveles de madurez del aguaymanto. (a) Nivel 1. (b) Nivel 2. (c) Nivel 3. (d) Nivel 4. (e) Nivel 5. (f) Nivel 6. (g) Nivel 7	40
Figura 15. Etapas del procesamiento de imágenes. (a) RGB original. (b) Escala de grises. (c) Binarización. (d) Final	41

Figura 16. Histogramas de valores de parámetros por clases. (a) L*. (b) a*. (c) b*. (d) R. (e) G. (f) B, (g) H, (h) S, (i) V. (j) GR. (k) NDGRI. (l) NDGBI. (m) Hue. (n) Sat, (o) Int	42
Figura 17. (a) ACC y (b) ERR para la clasificación por color con 18 parámetros	46
Figura 18. (a) ACC y (b) ERR para clasificación por color con 6 parámetros de interés.....	46
Figura 19. Espacio de color en RGB para los frutos de aguaymanto en diferentes niveles de madurez.....	47
Figura 20. Espacio de color en HSV para los frutos de aguaymanto en diferentes niveles de madurez.....	48
Figura 21. Espacio de color en L*a*b para los frutos de aguaymanto en diferentes niveles de madurez.....	48
Figura 22. Análisis de F-medida	56

PRINCIPALES NOMENCLATURAS

Sigla	Descripción
ANN	Redes neuronales artificiales
CMYK	Espacios de color Cyan, magenta, amarillo y negro
CVS	Sistema de visión computarizada
DT	Árboles de decisión
HSB	Espacios de color Matiz, saturación y brillo
HSI	Espacios de color Matiz, saturación e intensidad
HSL	Espacios de color Matiz, saturación y luminosidad
HSV	Espacios de color Matiz, saturación y brillo
KNN	K vecinos más próximos
L*a*b	Espacio de color CIELab
LDA	Análisis discriminante lineal
LR	Regresión lineal
LS-SVM	Máquina de soporte vectorial de mínimos cuadrados
MDA	Análisis multivariado discriminativo
MLR	Regresión lineal múltiple
NBC	Clasificación bayesiana ingenua
NIR	Infrarrojo cercano
PRC	Precisión
QDA	Análisis discriminante cuadrático
RGB	Espacio de color rojo, verde y azul
SKA-Means	k-medios supervisados
sRGB	Espacio estándar de color RGB
SVM	Máquinas de soporte vectorial
YCbCr	Luminancia, Crominancia - azul, Crominancia - rojo

RESUMEN

La clasificación de frutas frescas según su madurez es un trabajo comúnmente subjetivo y tedioso; en consecuencia, existe un creciente interés en el uso de técnicas no invasivas como las basadas en la visión computarizada y en técnicas de aprendizaje automatizado. En esta investigación, proponemos el uso de técnicas no invasivas para la clasificación de frutos de aguaymanto. La propuesta se basa en el uso de técnicas de aprendizaje automático combinadas con diferentes espacios de color. Dado el éxito que han tenido las técnicas automatizadas como las *redes neuronales artificiales*, *máquinas de soporte vectorial*, *árboles de decisiones* y el método de los *K vecinos más próximos*, en los problemas de clasificación, decidimos utilizar estos alcances en el presente trabajo de investigación. Se obtuvo una muestra de 819 frutos de aguaymanto, los cuales fueron clasificados manualmente según su nivel de madurez en siete clases diferentes. Las imágenes de cada fruta fueron obtenidas en formato *RGB* a través de un sistema desarrollado para este fin. Estas imágenes fueron pre-procesadas, filtradas y segmentadas hasta la identificación de los frutos. Para cada una de las frutas, se obtuvieron los valores medianos de sus parámetros de color en el espacio *RGB*, y subsecuentemente se transformaron los resultados en los espacios de color *HSV* y *L*a*b**. Los valores de cada fruto en los tres espacios de color y sus correspondientes grados de madurez fueron utilizados para la creación, validación y comparación de los modelos de clasificación desarrollados. Se halló que la elección de uno u otro espacio de color, afecta la calidad del clasificador. Los sistemas basados en árboles de decisiones ofrecen los mejores resultados, estos fueron mayores a 97% de precisión con 18 y con 6 parámetros de interés y mayores a 72% al combinarlos con los espacios de color *RGB*, *HSV* y *L*a*b**. Los modelos basados en el método de las redes neuronales artificiales obtienen resultados más variables. Los modelos basados en el espacio de color *L*a*b** ofrecen los mejores resultados, estos fueron superiores a 72% de precisión. Finalmente, el modelo que mejor clasifica los frutos de aguaymanto de acuerdo con su nivel de madurez es el que resultó de la combinación de la técnica *SVM* y el espacio de color *RGB*, obteniendo una medida *F* de 79,47% y una precisión de 79,79%.

Palabras clave: Aguaymanto; espacios de color; redes neuronales artificiales; máquinas de soporte vectorial; árboles de decisiones, K-vecinos más próximos.

ABSTRACT

The classification of fresh fruits according to their ripeness is commonly a subjective and tedious task; consequently, there is growing interest in the use of non-contact techniques as such those based on computer vision and machine learning. In this paper, we propose the use of non-intrusive techniques for the classification of Cape gooseberry fruits. The proposal is based on the use of machine learning techniques combined with different color spaces. Given the success of techniques such as artificial neural networks, support vector machines, decision trees, and *K-nearest neighbors* in classification problems, we decided to use these approaches in this research work. A sample of 819 Cape gooseberry fruits was obtained, and fruits were classified manually according to their level of ripeness in seven different classes. Images of each fruit were acquired in the *RGB* format through a system developed for this purpose. These images were preprocessed, filtered and segmented until the fruits were identified. For each piece of fruit, the median color parameter values in the *RGB* space were obtained, and these results were subsequently transformed into the *HSV* and *L*a*b** color spaces. The values of each piece of fruit in the three color spaces and their corresponding degrees of ripeness were arranged for use in the creation, validation, and comparison of the developed classification models. The choice of color space was found to affect the quality of the classifier. Decision trees based systems offer the best results, the precision of these where higher than 97% when using 18 parameters and 6 parameters of interest, and higher than 72% when combined with *RGB*, *HSV* and *L*a*b** color spaces. The artificial neural network-based models obtain more variable results. The models based on the *L*a*b** color space offer the best results, the precision of these where superior than 72%. Finally, the model that best classifies the cape gooseberry fruits based on ripeness level is that resulting from the combination of the SVM technique and the *RGB* color space, obtaining an F measure of 79,47% and accuracy of 79,79%.

Keywords: Golden Berry; color spaces; artificial neural networks; support vector machines; decision trees, K-nearest neighbors.

NOTA DE ACCESO

No se puede acceder al texto completo pues contiene datos confidenciales

REFERENCIAS

- Acuña, G., Curilem, M., & Cubillos, F. (2014). Desarrollo de un Sensor Virtual basado en Modelo NARMAX y Máquina de Vectores de Soporte para Molíenda Semiautógena. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 11(1), 109–116.
- Arabasadi, Z., Khorasani, M., Akhlaghi, S., Fazilat, H., Gedde, U. W., Hedenqvist, M. S., & Shiri, M. E. (2013). Prediction and optimization of fireproofing properties of intumescent flame retardant coatings using artificial intelligence techniques. *Fire Safety Journal*, 61, 193–199.
- Arakeri, M. P., & Lakshmana. (2016). Computer Vision Based Fruit Grading System for Quality Evaluation of Tomato in Agriculture industry. *Procedia Computer Science*, 79, 426–433.
- Avila, F., Mora, M., Oyarce, M., Zuñiga, A., & Fredes, C. (2015). A method to construct fruit maturity color scales based on support machines for regression: Application to olives and grape seeds. *Journal of Food Engineering*, 162(Supplement C), 9–17.
- Benedito, J., Simal, S., Clemente, G., & Mulet, A. (2006). Manchego cheese texture evaluation by ultrasonics and surface probes. *International Dairy Journal*, 16(5), 431–438.
- Blasco, J., Aleixos, N., & Moltó, E. (2007). Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm. *Journal of Food Engineering*, 81(3), 535–543.
- Brosnan, T., & Sun, D.-W. (2004). Improving quality inspection of food products by computer vision—a review. *Journal of Food Engineering*, 61(1), 3–16.
- Cárdenas-Pérez, S., Chanona-Pérez, J., Méndez-Méndez, J., Calderón-Domínguez, G., López-Santiago, R., Perea-Flores, M. J., & Arzate-Vázquez, I. (2017). Evaluation of the ripening stages of apple (Golden Delicious) by means of computer vision system. *ScienceDirect*, 159, 46–58.
- Castro, W., Oblitas, J., Chuquizuta, T., & Avila-George, H. (2017). Application of image analysis to optimization of the bread-making process based on the acceptability of the crust color. *Journal of Cereal Science*, 74(Supplement C), 194–199.
- Chang, T.-S. (2011). A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction. *Expert Systems with Applications*, 38(12), 14846–14851.
- Chen, K., Sun, X., Qin, C., & Tang, X. (2010). Color grading of beef fat by using computer vision and support vector machine. *Computers and Electronics in Agriculture*, 70(1), 27–32.

- Coria, S. R., Mondragón-Becerra, R., Pérez-Meza, M., Ramírez-Vásquez, S. K., Martínez-Peláez, R., Barragán-López, D., & Ávila-Barrón, O. R. (2013a). CT4RDD: Classification trees for research on digital divide. *Expert Systems with Applications*, 40(14), 5779–5786.
- Coria, S. R., Mondragón-Becerra, R., Pérez-Meza, M., Ramírez-Vásquez, S. K., Martínez-Peláez, R., Barragán-López, D., & Ávila-Barrón, O. R. (2013b). CT4RDD: Classification trees for research on digital divide. *Expert Systems with Applications*, 40(14), 5779–5786.
- Dostert, N., Torre, L., I, M., Luebert, F., Cano, A., Roque, J., & Roque, J. (2012). Hoja botánica: Aguaymanto. *Physalis peruviana L.* Recuperado a partir de <http://bibliotecavirtual.minam.gob.pe/biam/handle/minam/1424>
- Du, C.-J., & Sun, D.-W. (2004). Recent developments in the applications of image processing techniques for food quality evaluation. *Trends in Food Science & Technology*, 15(5), 230–249.
- Du, C.-J., & Sun, D.-W. (2008). Multi-classification of pizza using computer vision and support vector machine. *Journal of Food Engineering*, 86(2), 234–242.
- Dutta, M. K., Sengar, N., Minhas, N., Sarkar, B., Goon, A., & Banerjee, K. (2016). Image processing based classification of grapes after pesticide exposure. *LWT - Food Science and Technology*, 72, 368–376.
- El-Bendary, N., El Hariri, E., Hassanien, A. E., & Badr, A. (2015). Using machine learning techniques for evaluating tomato ripeness. *Expert Systems with Applications*, 42(4), 1892–1905. Elhariri, E., El-Bendary, N., Hussein, A. M. M., Hassanien, A. E., & Badr, A. (2014). Bell pepper ripeness classification based on support vector machine. En 2014 International Conference on Engineering and Technology (ICET) (pp. 1–6).
- Erkaya, T., Dağdemir, E., & Şengül, M. (2012). Influence of Cape gooseberry (*Physalis peruviana L.*) addition on the chemical and sensory characteristics and mineral concentrations of ice cream. *Food Research International*, 45(1), 331–335.
- F. Oliveira, S., J. A. Gonçalves, F., Correia, P., & Guiné, R. (2016). Physical properties of *Physalis peruviana L.*: *Open Agriculture*, 1. <https://doi.org/10.1515/opag-2016-0007>
- Fadilah, N., Mohamad-Saleh, J., Abdul Halim, Z., Ibrahim, H., & Syed Ali, S. S. (2012). Intelligent Color Vision System for Ripeness Classification of Oil Palm Fresh Fruit Bunch. *Sensors*, 12(10), 14179–14195.
- Fischer, G., Miranda, D., Piedrahita, W., & Romero, J. (2005). *Avances en cultivo, poscosecha y exportación de la uchuva (*Physalis peruviana L.*) en Colombia*. Universidad Nacional de

Colombia, Facultad de Agronomía. Recuperado a partir de <http://www.sidalc.net/cgi-bin/wxis.exe/?IsisScript=catalco.xis&method=post&formato=2&cantidad=1&expresion=mfn=075389>

Flórez, R., & Fernández, J. M. F. (2008). *Las Redes Neuronales Artificiales*. Netbiblo.

García Nieto, P. J., García-Gonzalo, E., Alonso Fernández, J. R., & Díaz Muñiz, C. (2014). Hybrid PSO–SVM-based method for long-term forecasting of turbidity in the Nalón river basin: A case study in Northern Spain. *Ecological Engineering*, 73, 192–200.

Goel, N., & Sehgal, P. (2015). Fuzzy classification of pre-harvest tomatoes for ripeness estimation – An approach based on automatic rule learning using decision tree. *Applied Soft Computing*, 36, 45–56.

Gonzalez, R. C., Woods, R. E., & Eddins, S. L. (2009). *Digital Image Processing Using MATLAB*, 2nd ed. (2nd edition). S.I.: Gatesmark Publishing.

Haribabu, M., Bindu, C. H., & Swamy, K. V. (2016). A Secure & Invisible Image Watermarking Scheme Based on Wavelet Transform in HSI Color Space. *Procedia Computer Science*, 93, 462–468.

Irtle, R. A., & Kabelka, E. A. (2009). Correlation Between L*a*b* Color Space Values and Carotenoid Content in Pumpkins and Squash (*Cucurbita spp.*). *HortScience*, 44(3), 633–637.

Johar Damiri, D., & Slamet, C. (2012). Application of Image Processing and Artificial Neural Networks to Identify Ripeness and Maturity of the Lime (*citrus medica*). *International Journal of Basic and Applied Science*, 1, 171–179.

León, K., Mery, D., Pedreschi, F., & León, J. (2006). Color measurement in L*a*b* units from RGB digital images. *Food Research International*, 39(10), 1084–1091.

Li, H., Lee, W. S., & Wang, K. (2014). Identifying blueberry fruit of different growth stages using natural outdoor color images. *Computers and Electronics in Agriculture*, 106, 91–101.

Li, W., Wu, X., Jiao, W., Qi, G., & Liu, Y. (2017). Modelling of dust removal in rotating packed bed using artificial neural networks (ANN). *Applied Thermal Engineering*, 112, 208–213.

Lorente, D., Aleixos, N., Gómez-Sanchis, J., Cubero, S., García-Navarrete, O. L., & Blasco, J. (2012). Recent Advances and Applications of Hyperspectral Imaging for Fruit and Vegetable Quality Assessment. *Food and Bioprocess Technology*, 5(4), 1121–1142.

- Luchese, C. L., Gurak, P. D., & Marczak, L. D. F. (2015). Osmotic dehydration of physalis (*Physalis peruviana L.*): Evaluation of water loss and sucrose incorporation and the quantification of carotenoids. *LWT - Food Science and Technology*, 63(2), 1128–1136.
- Mizushima, A., & Lu, R. (2013). An image segmentation method for apple sorting and grading using support vector machine and Otsu's method. *Computers and Electronics in Agriculture*, 94,
- Mohammadi, V., Kheiralipour, K., & Ghasemi-Varnamkhasti, M. (2015). Detecting maturity of persimmon fruit based on image processing technique. *Scientia Horticulturae*, 184(Supplement C), 123–128.
- Montoya Holguin, C., Osorio, C., Alexander, J., Osorio, C., & Andrés, J. (2014). Sistema automático de reconocimiento de frutas basado en visión por computador. *Ingeniare. Revista chilena de ingeniería*, 22(4), 504–516.
- Morcillo, L. G., Poyo, F. J. C., & Maldonado, G. L. (2014). Using Decision Trees for Comparing Different Consistency Models. *Procedia - Social and Behavioral Sciences*, 160, 332–341.
- Nandi, C. S., Tudu, B., & Koley, C. (2014). A Machine Vision-Based Maturity Prediction System for Sorting of Harvested Mangoes. *IEEE Transactions on Instrumentation and Measurement*, 63(7), 1722–1730.
- Páez-Logreira, H. D., Zamora-Musa, R., & Bohórquez-Pérez, J. (2015). Programación de Controladores Lógicos (PLC) mediante Ladder y Lenguaje de Control Estructurado (SCL) en MATLAB. *Facultad de Ingeniería*, 24(39), 109–119.
- Paulraj, M., Hema, C., Pranesh, K., & Siti Sofia, M. R. (2009). Color Recognition Algorithm.pdf. Recuperado a partir de <http://dspace.unimap.edu.my/xmlui/bitstream/handle/123456789/7305/Color%20Recognition%20Algorithm.pdf?sequence=1>
- Paulraj, M. P., Hema, C. R., Krishnan, P., & Radzi, S. (2009). Color recognition algorithm using a neural network model in determining the ripeness of a Banana.
- Pedreschi, F., León, J., Mery, D., & Moyano, P. (2006). Development of a computer vision system to measure the color of potato chips. *Food Research International*, 39(10), 1092–1098.
- Polder, G., van der Heijden, G., & Young, I. (2002). Spectral image analysis for measuring ripeness of tomatoes. *Transactions of the American Society of Agricultural Engineers*, 45.

- Pourdarbani, R., Ghassemzadeh, H. R., Seyedarabi, H., Nahandi, F. Z., & Vahed, M. M. (2015). Study on an automatic sorting system for Date fruits. *Journal of the Saudi Society of Agricultural Sciences*, 14(1), 83–90.
- Puente, L. A., Pinto-Muñoz, C. A., Castro, E. S., & Cortés, M. (2011). *Physalis peruviana Linnaeus*, the multiple properties of a highly functional fruit: A review. *Food Research International*, 44(7), 1733–1740.
- Rafiq, A., Makroo, H. A., & Hazarika, M. K. (2016). Artificial Neural Network-Based Image Analysis for Evaluation of Quality Attributes of Agricultural Produce. *Journal of Food Processing and Preservation*, 40(5), 1010–1019.
- Ramírez, F., Fischer, G., Davenport, T. L., Pinzón, J. C. A., & Ulrichs, C. (2013). Cape gooseberry (*Physalis peruviana L.*) phenology according to the BBCH phenological scale. *Scientia Horticulturae*, 162(Supplement C), 39–42.
- Rizam, M. S. B. S., Yasmin, A. R. F., Ihsan, M. Y. A., & Shazana, K. (2009). Non-destructive watermelon ripeness determination using image processing and artificial neural network (ANN). *World Academy of Science, Engineering and Technology*, 38, 542–546.
- Romano, G., Argyropoulos, D., Nagle, M., Khan, M. T., & Müller, J. (2012). Combination of digital images and laser light to predict moisture content and color of bell pepper simultaneously during drying. *Journal of Food Engineering*, 109(3), 438–448.
- Romero-Acero, A., Marín-Cano, A., & Jiménez-Builes, J. A. (2015). Sistema de clasificación por visión artificial de mangos tipo Tommy. *Classification system for artificial vision type Tommy mango.*, 14(1), 21–31.
- Salazar, M. R., Jones, J. W., Chaves, B., & Cooman, A. (2008). A model for the potential production and dry matter distribution of Cape gooseberry (*Physalis peruviana L.*). *Scientia Horticulturae*, 115(2), 142–148.
- Saldaña, E., Siche, R., Castro, W., Huamán, R., & Quevedo, R. (2014). Measurement parameter of color on yacon (*Smallanthus sonchifolius*) slices using a computer vision system. *LWT - Food Science and Technology*, 59(2, Part 2), 1220–1226. <https://doi.org/10.1016/j.lwt.2014.06.037>
- Sozer. (2016). *Imaging Technologies and Data Processing for Food Engineers* | Nesli Sozer | Springer. Recuperado a partir de //www.springer.com/us/book/9783319247335
- Tan, A., & Toro, R. (2016). Producción y Comercialización de Aguaymanto (*Physalis Peruviana L*) en la Asociación de Productores Agropecuarios, Forestal, Acuícola (Apafavel - Incahuasi -

Ferreñafe – Lambayeque) Como Impulso al Desarrollo Económico Local, 2015. Recuperado a partir de <https://es.scribd.com/document/322872390/Prod-y-comerc-de-aguaymanto-pdf>

Todo Aguaymanto. (s/f). Recuperado a partir de <http://aguaymanto.blog.galeon.com/>

Unay, D., & Gosselin, B. (2007). Stem and calyx recognition on 'Jonagold' apples by pattern recognition. *Journal of Food Engineering*, 78(2), 597–605.

Vásquez-Parra, J. E., Ochoa-Martínez, C. I., & Bustos-Parra, M. (2013). Effect of chemical and physical pretreatments on the convective drying of cape gooseberry fruits (*Physalis peruviana*). *Journal of Food Engineering*, 119(3), 648–654.

Vélez-Rivera, N., Blasco, J., Chanona-Pérez, J., Calderón-Domínguez, G., Perea-Flores, M. de J., Arzate-Vázquez, I., ... Farrera-Rebollo, R. (2014). Computer Vision System Applied to Classification of "Manila" Mangoes During Ripening Process. *Food and Bioprocess Technology*, 7(4), 1183–1194.

Vithu, P., & Moses, J. A. (2016). Machine vision system for food grain quality evaluation: A review. *Trends in Food Science & Technology*, 56(Supplement C), 13–20.

Wu, D., & Sun, D.-W. (2013). Colour measurements by computer vision for food quality control – A review. *Trends in Food Science & Technology*, 29(1), 5–20.

Xiaobo, Z., Jiewen, Z., & Yanxiao, L. (2007). Apple color grading based on organization feature parameters. *Pattern Recognition Letters*, 28(15), 2046–2053.

Zakaluk, R., & Ranjan, R. S. (2006). Artificial Neural Network Modelling of Leaf Water Potential for Potatoes Using RGB Digital Images: A Greenhouse Study. *Potato Research*, 49(4), 255–272.

Zhang, B., Huang, W., Gong, L., Li, J., Zhao, C., Liu, C., & Huang, D. (2015). Computer vision detection of defective apples using automatic lightness correction and weighted RVM classifier. *Journal of Food Engineering*, 146, 143–151.

Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., & Liu, C. (2014a). Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International*, 62, 326–343.

Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., & Liu, C. (2014b). Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Research International*, 62(Supplement C), 326–343.

Zheng, H., & Lu, H. (2012). A least-squares support vector machine (LS-SVM) based on fractal analysis and CIELab parameters for the detection of browning degree on mango (*Mangifera indica L.*). *Computers and Electronics in Agriculture*, 83(Supplement C), 47–51.

Zou, J., Lu, G.-F., Zhang, Y., & Liu, C. (2016). Generalizing intersection kernel support vector machines for color texture based recognition. *Journal of Visual Communication and Image Representation*, 41, 1–14.