

**UNIVERSIDAD NACIONAL
TORIBIO RODRÍGUEZ DE MENDOZA DE AMAZONAS**



7 3 MAY 2013

01 CD

**FACULTAD DE INGENIERÍA Y CIENCIAS AGRARIAS
ESCUELA ACADÉMICO PROFESIONAL DE
INGENIERÍA AGROINDUSTRIAL**

**"DETERMINACIÓN PREDICTIVA DEL pH Y °BRIX A PARTIR DE
PARÁMETROS DE COLOR DEL TOMATE DE ÁRBOL (*Cyphomandra
betacea*) USANDO UN SISTEMA DE VISIÓN E INTELIGENCIA ARTIFICIAL"**

**TESIS PARA OBTENER EL TÍTULO PROFESIONAL DE
INGENIERO AGROINDUSTRIAL**

AUTORES:

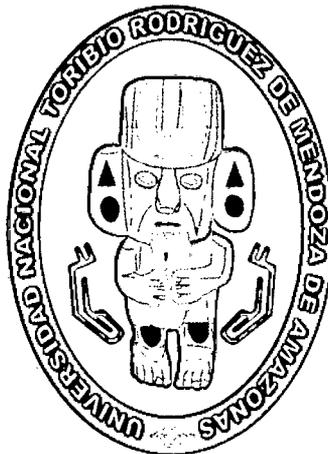
**Bach. Hugo Wulter Díaz Dávila
Bach. Milton Alfonso Zumaeta Silva**

ASESOR: Ing. Wilson Manuel Castro Silupu

AMAZONAS – PERÚ

2013

**UNIVERSIDAD NACIONAL TORIBIO RODRÍGUEZ DE
MENDOZA DE AMAZONAS**



**FACULTAD DE INGENIERÍA Y CIENCIAS AGRARIAS
ESCUELA ACADÉMICO PROFESIONAL DE INGENIERÍA AGROINDUSTRIAL**

**“DETERMINACIÓN PREDICTIVA DEL pH Y °BRIX A PARTIR DE PARÁMETROS
DE COLOR DEL TOMATE DE ÁRBOL (*Cyphomandra betacea*) USANDO UN
SISTEMA DE VISIÓN E INTELIGENCIA ARTIFICIAL”**

Tesis para obtener el título profesional de

INGENIERO AGROINDUSTRIAL

AUTORES:

Bach. Hugo Wuilter Díaz Dávila

Bach. Milton Alfonso Zumaeta Silva

ASESOR:

Ing. Wilson Manuel Castro Silupu

CHACHAPOYAS - PERÚ

2013

DEDICATORIA

A mi señora madre por su innegable apoyo en todos estos años, por su infinito amor, comprensión y por apoyarme a que este momento llegara. ¡Gracias Mamá...!

A mis hermanos: por todo su apoyo; MILTON

A mi familia, fuente de inspiración para cumplir las metas propuestas en beneficio de mis semejantes; HUGO.

AGRADECIMIENTO

A DIOS por habernos permitido llegar hasta esta etapa con salud y sabiduría para lograr nuestros objetivos, además de su infinita bondad y amor.

Queremos manifestar nuestro agradecimiento a los Maestros Unatinos, quienes intervinieron durante el proceso de nuestra formación universitaria brindándonos sus conocimientos e inculcándonos los buenos modales y valores, y a aquellos que gustosamente colaboraron en la elaboración de este trabajo; como también muy en especial a nuestra familia gracias a ellos somos lo que ahora somos. En especial:

Ing. Wilson Manuel Castro Silupu.

Asesor del presente trabajo

A nuestros Padres:

- MARÍA DEL CARMEN SILVA LA TORRE – (Milton)
- ÁNTERO DÍAZ – (Hugo)

Por todo su apoyo infinito

A una amiga especial:

- MARÍA DEL CARMEN CORREA DUIRE

Por las facilidades brindadas y los buenos momentos compartidos.

**AUTORIDADES DE LA UNIVERSIDAD NACIONAL
TORIBIO RODRÍGUEZ DE MENDOZA DE AMAZONAS**

Ph. D. Dr. Hab. VICENTE MARINO CASTAÑEDA CHÁVEZ

Rector

Dr. ROBERTO JOSÉ NERVI CHACÓN

Vicerrector Académico (e)

Dr. EVER SALOMÉ LAZARO BAZÁN

Vicerrector Administrativo (e)

Dr. MIGUEL ÁNGEL BARRENA GURBILLÓN

Decano de la Facultad de Ingeniería y Ciencias Agrarias

VISTO BUENO DEL ASESOR DE TESIS

El Docente de la UNTRM-A que suscribe, hace constar que ha asesorado la realización de la Tesis titulada “**DETERMINACIÓN PREDICTIVA DEL pH Y °BRIX A PARTIR DE PARÁMETROS DE COLOR DEL TOMATE DE ÁRBOL (*Cyphomandra betacea*) USANDO UN SISTEMA DE VISIÓN E INTELIGENCIA ARTIFICIAL**” de los Tesistas egresados de la Escuela Académico Profesional de Ingeniería Agroindustrial de la UNTRM-A:

- **Br. MILTON ALFONSO ZUMAETA SILVA**

- **Br. HUGO WILTER DÍAZ DÁVILA**

El Docente de la UNTRM-A que suscribe, da el **Visto Bueno** al Informe Final de la Tesis mencionada, dándole pase para que sea sometida a la revisión por el Jurado Evaluador, comprometiéndose a supervisar el levantamiento de observaciones para su posterior Sustentación.

Chachapoyas, 10 de enero del 2013


Ing Wilson Manuel Castro Silupu
Profesor Asociado DE.
Facultad de Ingeniería y Ciencias Agrarias

JURADO EVALUADOR



Dr. MIGUEL ÁNGEL BARRENA GURBILLÓN

Presidente



Ing. HELÍ HUMBERTO AGUIRRE ZAQUINAULA

Secretario



Ing. MEREGILDO SILVA RAMÍREZ

Vocal

ÍNDICE

	Pág
RESUMEN	xi
ABSTRACT	xii
I. INTRODUCCIÓN	1
I.1. Tomate de árbol	4
I.2. Luz, percepción visual y el color	6
I.3. Espacios de color	6
I.4. Sistema de visión computacional	8
I.4.1. Visión computacional	8
I.4.2. Adquisición de imágenes	9
I.4.3. Procesamiento de imágenes	12
I.4.4. Técnicas de segmentación en umbralización	14
I.5. Inteligencia artificial y aplicaciones en la agroindustria	16
I.5.1. Redes neuronales artificiales (RNA)	17
I.6. Software: Algoritmos de análisis de imagen	18
I.6.1. Algoritmo	18
I.6.2. Matlab	19
II. MATERIALES Y MÉTODOS	20
II.1. Lugar de ejecución	20
II.2. Material biológico	20
II.3. Equipos	20
II.4. Métodos	20
III.1. Parámetros de color tomate de árbol	27
III.2. Determinación del pH y °Brix en tomate de árbol	30
III.3. Determinación predictiva de pH y °Brix a partir de parámetros de color.	32
IV. DISCUSION	35
V. CONCLUSIONES	38
VI. RECOMENDACIONES	39
VII. REFERENCIAS BIBLIOGRAFICAS	40
ANEXOS	42

ÍNDICE DE FIGURAS

	<u>Pág</u>
Figura 1. Modelo del espacio color de CIELAB.....	8
Figura 2. Esquema de un proceso de análisis de imágenes: adquisición de la imagen, pre-procesamiento, segmentación, conversión de color y valores $L^*a^*b^*$	9
Figura 3. Imagen generada por resonancia magnética y simulación computacional	11
Figura 4. Elementos esenciales de un sistema de visión Computacional.....	12
Figura 5. Imágenes de ingredientes superiores para pizzas.....	14
Figura 6. Umbral del histograma de una imagen de carne de vacuno.....	15
Figura 7. Configuración general de maquinas de sistemas inteligentes.....	16
Figura 8. Topología general de una RNA	17
Figura 9. Extremos en los estados de madurez de acuerdo al color de la corteza.....	21
Figura 10. Sistema de visión por computadora utilizado la labor experimental	22
Figura 11. Adquisición y guardado de imágenes mediante el guide Video1	22
Figura 12. Resultado de la aplicación del algoritmo de segmentación	24
Figura 13. Matriz tridimensional.....	25
Figura 14. Resultados de la aplicación de función Lab.....	25
Figura 15. Parámetro L de las muestras analizadas.....	28
Figura 16. Parámetro a^* de las muestras analizadas	28
Figura 17. Parámetro b^* de las muestras analizadas	29
Figura 18. Parámetros de color en diferentes estadios de madurez tomate de árbol.....	29
Figura 19. Valores de pH de muestras analizadas.....	31
Figura 20. Valores de °Brix de muestras analizadas	31
Figura 21. Arquitectura de la red neuronal utilizada para la predicción del °Brix	32
Figura 22. Arquitectura de la red neuronal utilizada para la predicción del pH.....	32
Figura 23. Porcentajes de error en la predicción de pH y °Brix de las muestras.....	34

ÍNDICE DE TABLAS

	Pág
Tabla 1. Resultados de los parámetros de color en las muestras analizadas	27
Tabla 2. Resultados de los parámetros de color en las muestras analizadas	30
Tabla 3. Valores mínimos y máximos de pH y °Brix de las muestras	30
Tabla 4. Errores cuadrados de la aplicación de redes neuronales a la predicción de °pH y Brix	33
Tabla 5. Resumen de aplicaciones de redes neuronales para clasificación de productos alimentarios	37
Tabla 6 Tabla de errores de las combinaciones de redes neuronales en la predicción del °Brix.....	55
Tabla 7 Tabla de errores de las combinaciones de redes neuronales en la predicción del pH	56

INDICE DE FOTOGRAFIAS

	<u>Pág</u>
Fotografía 1. Muestras adquiridas de tomate de árbol	43
Fotografía 2. Adecuación del sistema de adquisición de imágenes	43
Fotografía 3. Colocación de muestras y adquisición de imágenes en el sistema de adquisición de imágenes.....	44
Fotografía 4. Acondicionamiento de las muestras para la determinación de pH y °Brix	44
Fotografía 5. Determinación de pH y °Brix.....	44

RESUMEN

La presente tesis tubo como objetivo estudiar modelos de caja negra, basados en redes neuronales, para determinar predictivamente el pH y °Brix a partir de parámetros de color del tomate de árbol (*Cyphomandra betacea*) usando un sistema de visión e inteligencia artificial. Las muestra de tomate de arbol fueron adquiridas en el mercado local de la ciudad; clasificando estas visualmente en verde, maduro y sazón de acuerdo al color de la piel. Posteriormente se procedió a determinar los parámetros de color en diferentes estados de madurez, expresándolos en el espacio de color CIELa*b*, para este fin se hizo uso de un sistema de visión artificial. A continuación fueron determinadas el pH y °Brix en las muestras y finalmente se procedió al desarrollo de una secuencia de calculo, transcrita en lenguaje *.m de matlab versión 2011a, para, mediante redes neuronales, determinar el valor de pH y °Brix, en función de los parámetros de color (L, a* y b*). Como resultado se determinó que la mejor red aplicable al caso de estudio es del tipo back-propagation multicapa (dos capas ocultas) con funciones de activaciones tangente sigmoidea, las cuales generaron valores de pH y °Brix que se aproximan en 98.25 y 97.26 % respectivamente a los valores reales de las muestras analizadas. Asimismo se concluyó que los parámetros de color, en el espacio CIELa*b*, pueden utilizarse como índices indirectos de la composición de tomate de árbol y que el parámetro de color de mayor relevancia para este sistema de predicción es a*.

Palabras clave: CIELa*b*, redes neuronales, vision artificial

ABSTRACT

This thesis aimed to study black box models, based on neural networks, to predict pH and Brix using color parameters of tree tomato (*Cyphomandra betacea*) applying a vision system and artificial intelligence. The tree tomato samples were acquired in the local market and classified visually in green, mature and season according to the color of the skin. Then it's proceeded to determine the parameters of color in different stages of maturity, expressed it in the color space CIELa*b*, for this purpose, was used a machine vision system. Then was determined the pH and °Brix in the samples and proceeded to develop a sequence of calculation, transcribed in language *.m of matlab version 2011a, using neural networks, to determine the pH and °Brix, from color parameters (L, a* and b*). As a result the best applicable network was of the type back-propagation multilayer (two hidden layers) with functions of activations tangent sigmoid, which generated values of pH and °Brix fixing it 98.25 and 97.26% respectively to the actual values of samples analyzed. Likewise it was demonstrated that color parameters in the CIELa*b* space can be used as indirect indices of tree tomato composition and color parameter most relevant to this prediction system is a*.

Palabras clave: Artificial vision, CIELa*b*, neuronal network,

I. INTRODUCCIÓN

El ser humano, en su búsqueda de entender la complejidad del funcionamiento del universo, ha emprendido el estudio y la simulación de sistemas biológicos. Es en este contexto que hace algún tiempo se vienen desarrollando esfuerzos por modelar las propiedades sensoriales de los alimentos como el aspecto y el color de la superficie, así como relacionar estas con sus propiedades químicas, bioquímicas, sensoriales, mecánicas etc., y es con especial cuidado en los primeros debido a que estos son evaluados visualmente por el consumidor y por ende tienen relación directa en la aceptación o rechazo del producto, incluso antes de que entre en la boca (Du y Sun, 2004; Pedreschi, 2006).

En este sentido el paso siguiente, para la correlación de estos parámetros, es el diseño y fabricación de instrumentos o sistemas artificiales capaces de reproducir las respuestas humanas frente a estímulos visuales. Debido a esto, se están utilizando nuevas herramientas para medir los cambios en las características de color en alimentos, surgiendo como poderosas herramientas la visión por computadora o visión artificial e inteligencia artificial; proyectándose como métodos alternativos a la evaluación sensorial, debido a su capacidad de adquirir y analizar imágenes, obtener información a partir de estas y controlar procesos (León, 2006).

La visión computacional, procesamiento y análisis de imagen, aunado a la inteligencia artificial posibilitan la segmentación, cuantificación de color y clasificación de elementos de interés dentro de las imágenes. Esto viene siempre reportado por investigadores como Brosnan y Sun (2004), quienes los han utilizado como herramientas para estimar los cambios en las características de color de alimentos, mostrando que son sumamente ventajosas al reemplazar las respuestas de los panelistas

por imágenes tomadas a partir de una cámara de video y procesadas mediante algoritmos computacionales, disminuyendo costo, tiempo y subjetividad de las medidas de color haciéndolas más confiables y por lo tanto estimando los cambios de color de forma científica.

Es así que, actualmente, existe interés en la utilización de imágenes, adquiridas mediante cámaras de video, para la cuantificación del color, al ofrecer ventajas como: resolución ajustable y menor costo económico, en comparación con los instrumentos convencionales. Además el proceso de toma de imágenes mediante visión computacional, emulando a un colorímetro, proporciona algunas ventajas evidentes sobre un colorímetro convencional, a saber, posibilidad de analizar cada pixel de la superficie entera del alimento, y cuantificación de las características y defectos superficiales (Abdullah, 2005).

Por todo lo anterior y acercando esta situación problemática a nuestra realidad, se ha propuesto en esta investigación el estimar y analizar mediante visión computacional los cambios de los parámetros de color, en el espacio CIElab, durante el proceso de maduración y relacionarlas, mediante inteligencia artificial, con el pH y °Brix de tomate de árbol. De esta manera se estarían dando los primeros pasos en el desarrollo de un sistema de estimación predictivo de la composición, posibilitando dejar de lado a las técnicas de análisis de la composición basadas en métodos destructivos.

Para lo cual se planteó el siguiente problema de investigación ¿Se podrá determinar predictivamente el pH y °Brix a partir de parámetros de color del tomate de árbol (*Cyphomandra betacea*) usando un sistema de visión e inteligencia artificial?

Teniendo como objetivo general

Estudiar modelos de caja negra, basados en redes neuronales, para determinar predictivamente el pH y °Brix a partir de parámetros de color del tomate de árbol (*Cyphomandra betacea*) usando un sistema de visión e inteligencia artificial

Así mismo los objetivos específicos fueron:

- a) Determinar parámetros de color en diferentes estados de madurez de tomate de árbol (*Cyphomandra betacea*), utilizando un sistema de visión por computadora.
- b) Determinar pH y °Brix en diferentes estados de madurez de tomate de árbol (*Cyphomandra betacea*).
- c) Relacionar el pH y °Brix con parámetros de datos de color del tomate de árbol (*Cyphomandra betacea*) mediante sistema de inteligencia artificial.

I.1. Tomate de árbol

Características generales

A continuación se muestran las principales características de la planta de tomate de árbol.

Nombre Común:	Tomate de árbol, Tamarillo
Nombre científico:	Cyphomandra betacea
Familia:	Solanacea
Género:	Cyphomandra

Es una planta arbustiva de tallos semileñosos, de forma erecta y se ramifica a una altura que varía entre 1.5 m y 2m con la copa alcanza 3 m de altura. El tomate de árbol es propio de clima medio a frío, crece bien entre los 1600 y 2600 metros sobre el nivel de mar, con temperaturas promedio entre los 16 y 22°C y alta nubosidad o ambiente sombreado. Puede resistir temperaturas de 0°C sin sufrir daños graves, siempre que sea por corto tiempo.

Descripción: Las raíces son profundas y ramificadas cuando la reproducción se hace por semillas; cuando se hace por estaca son superficiales y bastante ramificadas. Los procedentes de semilla tardan de 12 a 14 meses, a partir del trasplante, para iniciar la producción, mientras que los de estaca entre 8 y 10 meses, pero son más pequeños y de menor duración.

Las flores se ubican en la terminación de las ramas y son de color blanco, con franjas de color rosado tenue.

Las semillas son pequeñas, planas, circulares y lisas, de color amarillento o a veces pardo.

El fruto:

Baya de forma ovoide – apiculada que presenta una coloración verde cuando esta inmaduro. La longitud varía entre 6 y 9 cm, midiendo en su parte más ancha entre 4 y 6 cm. El peso promedio puede variar entre 70 y 80 g. Tiene una piel fina lisa y resistente al transporte y una cutícula de sabor amargo, razón por la cual hay necesidad quitarla de la corteza para poder hacer uso del fruto. La pulpa es muy jugosa, de color anaranjado, de sabor agridulce, agradable y muy particular. En el fruto se encuentran entre 300 y 500 semillas.

Origen y
Localización:

Originaria de la vertiente oriental de los Andes, específicamente Perú, Ecuador y Colombia. Perteneciente al grupo de las frutas semiácidas, se la ha conocido con diversos nombres en distintas regiones. En 1970 en Nueva Zelanda se le asignó el nombre “tamarillo”, posicionándose esta designación comercial, que se generalizo para el tomate de árbol en el mercado mundial.

El tomate de árbol es una fuente de Vitamina A, B6, C y E, rico en el hierro y el potasio. También bajo en calorías y alto en la fibra. Los datos de la composición nutricional se deben interpretar por 100 g de la porción comestible.

Composición
Nutricional:

COMPUESTO	CANTIDAD
Calorías	80 Ca
Agua	87.9 g
Proteína	1.9 g
Grasa	0.16 g
Cenizas	0.7g
Carbohidratos	11.6 mg
Fibra	1.1 g
Calcio	2.0 mg
Hierro	2.0 mg
Fósforo	36.0 mg
Vitamina C	20%

Fuente: FAO, 2006

I.2. Luz, percepción visual y el color

La luz (del latín lux, lucis) es una onda electromagnética, compuesta por partículas energizadas llamadas fotones, capaz de ser percibida por el ojo humano y cuya frecuencia determina su color.

En *la percepción visual*, el hombre distingue al mundo, organizado en 3 dimensiones, mediante imágenes 2D y construyendo una representación mental, visión estereoscópica. Estas imágenes 2D obtenidas en la retina es una conjunto de puntos (aproximadamente un millón de elementos de imagen o píxeles).

El color proporciona la información básica para la percepción humana. Además de esto, el color proporciona información elemental que se almacena en píxeles para constituir una imagen digital. El color por lo tanto se puede clasificar como una de las mediciones de objetos más importantes para la comprensión de la imagen y descripción del objeto. Por otro lado y de acuerdo con la teoría tri-cromática, el color puede ser discriminado por la combinación de tres componentes de color elementales; siendo así que en nuestra imagen tres valores digitales son asignados a cada píxel de una imagen en color.

I.3. Espacios de color

Tal como se ha mencionado anteriormente el color en una imagen se puede representar mediante la combinación de tres parámetros. Es decir que el color es una representación tridimensional y, por tanto, se puede expresar en espacios de color. Los espacios más utilizados se comentan a continuación.

Espacios de color XYZ (RGB)

Según Navarrete y Gemma (2003), la medida del color psicofísico tiene por objeto, cuantificar la sensación llegada al cerebro, desde las células fotorreceptoras, provocada

por un determinado estímulo luminoso, en términos de la cantidad de rojo, verde y azul de dicho estímulo.

Dicha cuantificación se realiza a través de coordenadas de color y representan la respuesta de cada uno al estímulo recibido y, de forma general, podemos decir que la coordenada X representa la cantidad de rojo, la Y la cantidad de verde y la Z la cantidad de azul. Estas respuestas dependerán del estímulo luminoso exterior y del propio observador. El estímulo exterior dependerá a su vez de la interacción física del objeto con la luz (espectro visible) y de la distribución espectral del iluminante con que se realice la observación. Es decir, la radiación transmitida por el objeto, es función de la radiación que llegue del iluminante. A partir de las coordenadas XYZ se obtienen tres coordenadas colorimétricas L, a*, b*, las cuales permiten la construcción del espacio de color CIE Lab.

Espacio CIE Lab

La necesidad de un espacio de color uniforme, condujo a la transformación de una serie de espacios no lineales CIE XYZ 1931 que concluyeron en la especificación concreta de una de estas transformaciones en lo que se conoce como espacio de color CIE 1976 (L,a*,b*). El eje L es el de luminosidad y va de 0 (negro) a 100 (blanco). Los otros dos ejes de coordenadas son a* y b*, y representan variación entre rojo-verdoso, y amarillento-azulado, respectivamente (Figura 1). Aquellos casos en los que a* = b* = 0 son acromáticos; por eso el eje *L representa la escala acromática de grises que va de blanco al negro. Las proporciones de L*, a* y b* se obtienen de los valores triestímulos de acuerdo con las siguientes transformaciones:

$$L^* = 116(Y/Y_n)^{1/3} - 16, Y_n^{1/3}]$$

$$a^* = 500[(X/X_n)^{1/3} - (Y/Y_n)^{1/3}]$$

$$b^* = 200[(Y/Y_n)^{1/3} - (Z/Z_n)^{1/3}]$$

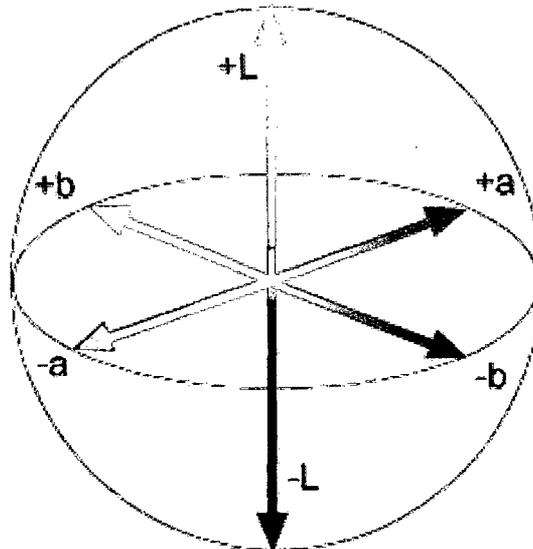


Figura 1. Modelo del espacio color de CIELAB
Fuente: Westland (2001).

Donde X_n , Y_n , Z_n son los respectivos valores de X , Y y Z con el iluminante que se haya usado para obtener los valores X , Y y Z de la muestra; y los cocientes de X/X_n , Y/Y_n y Z/Z_n son todos superiores a 0,008856 (cuando alguno de ellos es menor a esa cifra, se usa un conjunto de ecuaciones levemente distinto).

I.4. Sistema de visión computacional

I.4.1. Visión computacional

La visión computacional es una rama de la inteligencia artificial que tiene por objetivo modelar matemáticamente los procesos de percepción visual en los seres vivos y generar programas que permitan simular estas capacidades visuales por computadora.

En los años recientes la visión por computador ha llamado mucho la atención de las ciencias agroindustriales y de alimentos y desarrollándose rápidamente hasta tomar un lugar de privilegio en la inspección de calidad, clasificación y evaluación para un amplio rango de productos, como son los productos de panadería, carnes y pescados, frutos, alimentos listos para consumo, granos, entre otros. El amplio espectro de aplicaciones cubierto por la visión por computadora, se debe a que permite extraer y

analizar información espectral, espacial y temporal de los distintos objetos (Brosnan, 2004).

Como puede verse en la Figura 2, los pasos que involucra el análisis de imágenes son los siguientes:

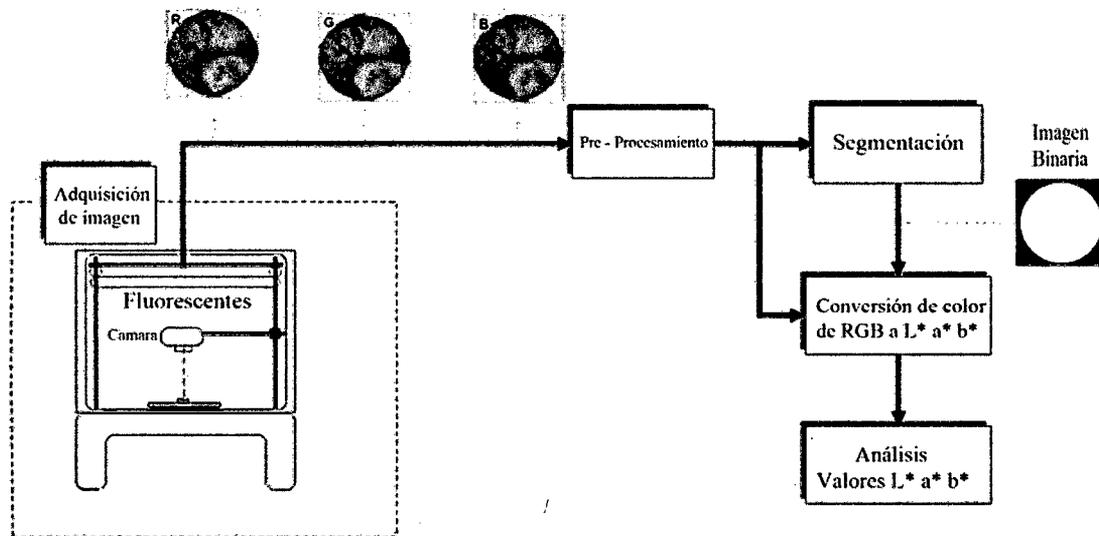


Figura 2. Esquema de un proceso de análisis de imágenes: adquisición de la imagen, pre-procesamiento, segmentación, conversión de color y valores L*a*b*.

Fuente: Brosnan (2004).

I.4.2. Adquisición de imágenes

En la realización de evaluaciones físicas de los materiales agrícolas y alimenticios, las imágenes son, sin duda, el método preferido en la representación de conceptos en el cerebro humano. Muchos de los factores que afectan a la calidad de los productos alimenticios pueden determinarse por inspección visual y análisis de imágenes. Estas inspecciones determinan el precio en el mercado. Tradicionalmente, la inspección de calidad se lleva a cabo por los inspectores humanos, que se acercan al problema de la evaluación de la calidad de dos maneras: viendo y sintiendo. Además de ser costoso, este método es muy variable y las decisiones no siempre son coherentes entre los mismos inspectores o de un día para otro. Esto, sin embargo, está cambiando con la

llegada de los sistemas de formación de imágenes electrónicas y con el rápido descenso en el coste de los ordenadores y otros dispositivos digitales. Por otra parte, la inspección de productos evaluando diversos factores de calidad es una tarea repetitiva que es de naturaleza subjetiva. En este tipo de entorno, los sistemas de visión artificial son ideales para la inspección de rutina y las tareas de control de calidad. Con el respaldo de poderosos sistemas de inteligencia artificial y de las tecnologías electrónicas, la visión computacional proporciona un mecanismo en el que el proceso de pensamiento humano se simula artificialmente. Hasta la fecha, la visión computacional ha sido ampliamente aplicado para solucionar diversos problemas de Ingeniería de Alimentos, que van desde simples evaluaciones de calidad de los productos alimenticios hasta complicadas aplicaciones robóticas (Tao et al., 1995; Pearson, 1996; Abdullah et al., 2000).

Sistema de adquisición de imagen

Las imágenes se forman por la luz incidente en el espectro visible al incidir en una superficie parcialmente reflectante, la superficie de absorción con los fotones dispersos es recogida en la lente de la cámara y se convierte en señales eléctricas, ya sea por tubo de vacío o por cámara CCD¹.

Sin embargo, en la práctica, esto es sólo una de las muchas formas en que una imagen puede ser generada. En general, hay muchas maneras de formar una imagen algunas de ellas son las siguientes: los métodos térmicos, por ultrasonidos, rayos X, ondas de radio, etc. véase Figura 3.

¹ Un charge-coupled device o CCD (en español «dispositivo de carga acoplada») es un circuito integrado que contiene un número determinado de condensadores enlazados o acoplados

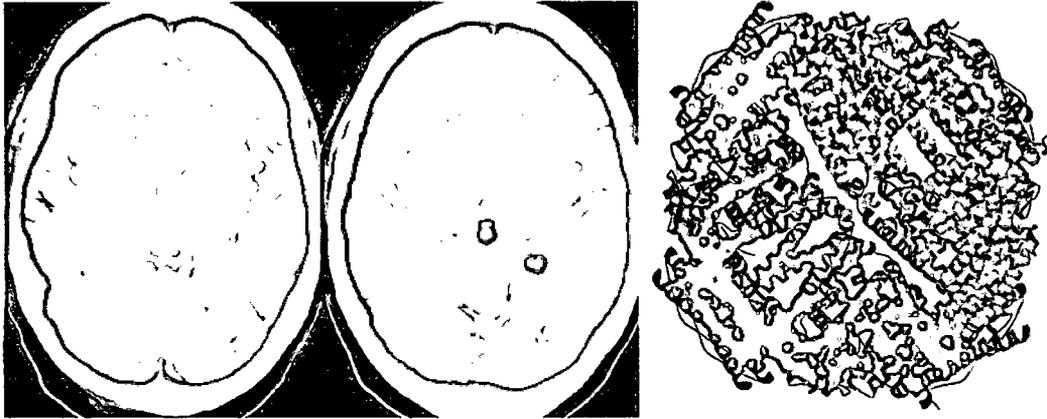


Figura 3. Imagen generada por resonancia magnética y simulación computacional

Fuente: Tao (1995).

Visión por computador

La configuración del sistema de visión artificial es relativamente estándar y se compone de:

- Dispositivo de iluminación.
- Cámara de estado sólido CCD.
- Interface para realizar la conversión A/D (analógico-digital) de la imagen a matrices tridimensionales de N filas por M columnas.
- Computadora personal o un sistema de microprocesador, para proporcionar el almacenamiento de las imágenes en el disco duro y soportar el software.
- Monitor con alta resolución de color para la visualización de imágenes y la percepción de las diversas rutinas de análisis de imagen.

La Figura 4 muestra una típica configuración en visión computacional, por ejemplo un investigador tiene que empezar a experimentar con aplicaciones de visión artificial con los componentes esenciales, ellos están disponibles comercialmente.

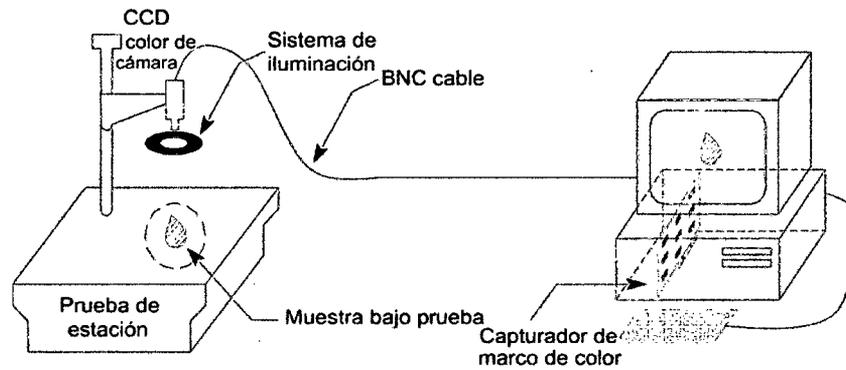


Figura 4. Elementos esenciales de un sistema de visión Computacional.

Fuente: Du y Sun (2004).

Aunque los sistemas de visión computacional se han vuelto cada vez más sencillos de utilizar, las propias aplicaciones todavía pueden ser extremadamente complicadas. Un investigador necesita saber con precisión lo que debe lograrse con el fin de asegurar la implementación exitosa de una aplicación de visión computacional. Es así que las características esenciales incluyen no sólo la parte específica de dimensiones y tolerancias de las piezas, sino también el nivel de precisión de la medida requerida y la velocidad de la línea de producción.

I.4.3. Procesamiento de imágenes

En los sistemas de adquisición de imágenes, las imágenes adquiridas están sujetas a diversos factores que afectan el procesamiento posterior. Aunque a veces estos factores se pueden corregir mediante el ajuste del hardware de adquisición, por ejemplo aumentando el número de imágenes capturadas de misma escena y la adopción de instrumentos de calidad superior, tales soluciones basadas en hardware requieren mucho tiempo y el costo es elevado.

Por lo tanto es preferible corregir las imágenes, después de que hayan sido adquiridas y digitalizadas, mediante el uso de programas informáticos, que son rápidos y relativamente de bajo costo. Por ejemplo, para eliminar el ruido, se puede aplicar filtros suaves (incluidos los filtros lineales y mediana), para mejorar el contraste en las

imágenes de bajo contraste, los histogramas de las imágenes se pueden ampliar o igualar. Estas correcciones de defectos en las imágenes son generalmente llamados "pre-procesamiento de imágenes."

Después del pre-procesamiento, las imágenes se segmentan a fin de separar los elementos de interés y analizarlos individualmente. La segmentación de imágenes de alimentos, se refiere al reconocimiento automático de los productos alimenticios con respecto al fondo de las imágenes, ello se realiza, por supuesto, después de la adquisición de las imágenes, porque la evaluación de calidad en alimentos es total y se lleva a cabo automáticamente en programas informáticos, sin ninguna participación humana, Figura 5. Aunque el proceso de segmentación de imagen está mal definido, por lo general se puede describir como la separación de las imágenes en diversas regiones en las que los píxeles de la imagen tienen características similares. Puesto que la segmentación es una tarea importante, en que los procesos de interpretación se completan posteriormente (es decir, la medición de objetos y clasificación de los mismos) se basan en gran medida de los resultados de a partir de la segmentación, enormes esfuerzos se están realizando para desarrollar una técnica de segmentación óptima, aunque esta técnica no está disponible todavía.

Un gran número de técnicas de segmentación se han desarrollado, la segmentación basada en umbralización, la segmentación basada en normas, basada en gradiente, y en una clasificación, son las cuatro técnicas más populares en la industria de alimentos, pero ninguno de ellos puede realizar una segmentación con precisión y eficacia a través de la amplia gama de productos alimenticios. En consecuencia, también se está desarrollando la combinación de otras técnicas, con un compromiso en la precisión y eficiencia. Aun así, no son lo suficientemente adaptables para su uso en toda la diversidad de los productos alimenticios.

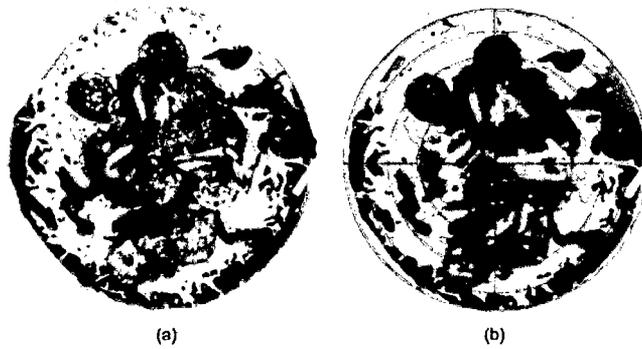


Figura 5. Imágenes de ingredientes superiores para pizzas
(a) Imagen original; (b) Imagen segmentada de (a).
Fuente: Sun (2000).

I.4.4. Técnicas de segmentación en umbralización

La segmentación basada en la umbralización de imágenes se divide en dos clases con un solo valor, llamado umbral de doble nivel (Figura 6), o en varias clases con varios valores, llamado umbralización multinivel, basado en las características del histograma. En umbral de dos niveles, los píxeles con valores de intensidad menores que el umbral, se establecen como fondo, mientras que otros se establecen como objeto. En el umbral de nivel múltiple, los píxeles con valores de intensidad entre los dos umbrales sucesivos son asignados como una clase. Sin embargo, umbrales de tres niveles, se definen normalmente sólo dos clases, es decir, con valores de intensidad entre los dos umbrales, y con valores de intensidad fuera de los dos umbrales.

Teóricamente, los niveles del umbral se pueden aumentar sin límites de acuerdo con el número de objetos presentes en las imágenes, sin embargo, el número de cálculos a realizar se incrementará de manera exponencial. Por ejemplo, para buscar el umbral de cuatro niveles en una imagen gris, el cálculo sería tan grande como (L^3) , donde L es el nivel de gris de la imagen (típicamente 256 para una imagen de gris). El cálculo grande significa que múltiples niveles (más de tres) del umbral no son factibles, y por lo tanto sólo el umbral de dos niveles y de tres niveles se utiliza en la práctica.

Es obvio que el umbral descrito para la segmentación anterior es un valor fijo (llamado umbral global) a través de toda la imagen. Existe otro tipo de umbral, llamado umbral local, que es un valor de adaptación determinada por las características locales de los pixeles. Sin embargo, sólo el umbral global es utilizado en la industria alimentaria, debido a que el umbral global se selecciona a partir del histograma de la imagen. Por lo tanto la velocidad de la computadora no se ve afectada por el tamaño de imagen, como podría ser el caso en los métodos de umbralización. Como el umbral adaptativo prácticamente no se utiliza en la industria alimentaria, no se trata detalladamente aquí. Sin embargo, para la segmentación de imágenes de alimentos complejos, como los ingredientes de las pizzas (véase la Figura 9; Sun, 2000), el umbral global no es competente. Una explicación de esto es que el número de clases definidas por el umbral global se limita a dos (objeto y fondo), que es mucho menor que las requeridas para segmentar las imágenes complejas en alimentos, ya que hay muchos productos alimentarios con valores de nivel de intensidad diferentes para ser segmentados.

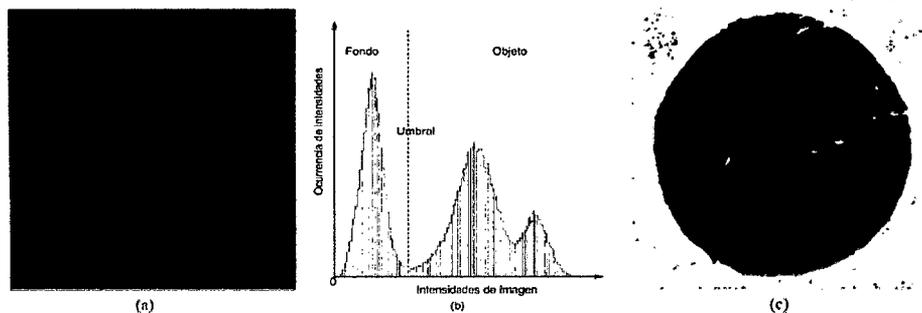


Figura 6. Umbral del histograma de una imagen de carne de vacuno
(a) imagen de la carne, (b) umbralización del histograma, (c) binarizada (a) por el umbral.

Fuente: Sun (2000).

I.5. Inteligencia artificial y aplicaciones en la agroindustria

La naturaleza intrínsecamente compleja, dinámica, y no lineal de los sistemas agropecuarios ha requerido siempre las soluciones basadas en técnicas y tecnologías avanzadas, para proporcionar mayor exactitud, una mayor comprensión y soluciones apropiadas. El uso de la inteligencia artificial (visión computacional, robótica y control, sistemas expertos, sistemas de ayuda de decisión, etc.) y otras técnicas prometedoras de la inteligencia artificial (redes neuronales, lógica difusa, algoritmos genéticos, y bioinformática) de proporcionar soluciones a los problemas en sistemas agrícolas complejos de manera eficaz. Adicionalmente la promoción de estas tecnologías, así como una disminución de costos está promoviendo las investigaciones en el uso de la IA (Inteligencia Artificial) de diversas formas en el sector agropecuario (Bustos, 2004).

Uno de los campos en que estas técnicas están encontrando gran acogida es la evaluación sensorial de alimentos; teniendo como buenos ejemplos los trabajos revisados y comentados por Cheng y Sun (2006) o Bustos (2004). Un buen aporte lo dan Cheng y Sun (2006) al proponer una configuración general de los sistemas de evaluación de alimentos por visión artificial e inteligencia artificial, Figura 1.

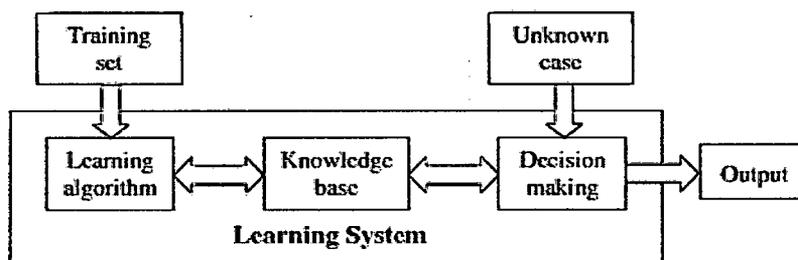


Figura 7. Configuración general de máquinas de sistemas inteligentes
Fuente: Cheng y Sun (2006)

En este sistema, al utilizar técnicas de análisis de imágenes, la imagen de un alimento es caracterizada cuantitativamente por un grupo de parámetros, tales como el tamaño,

forma, color y textura. Estas características son la data con la cual será entrenado el sistema, una vez que se ha logrado el entrenamiento el sistema extrae el la base conocimiento necesario para tomar una decisión en un caso desconocido.

Basado en el conocimiento, la decisión inteligente es tomada como u output y realimentada a la base de entrenamiento, generalizando de esta manera la forma en que los evaluadores complementan sus capacidades. Las técnicas más utilizadas para la construcción de la base de conocimiento son redes neuronales artificiales (RNA) y aprendizaje estadístico (AE).

I.5.1. Redes neuronales artificiales (RNA)

Inicialmente inspiradas en sistema nervioso humano, las simulaciones de RNA combinan la complejidad de algunas de las técnicas estadísticas con el objetivo de lograr sistemas inteligentes que simulen el aprendizaje humano, el cual se caracteriza por su capacidad de autoaprendizaje. La Figura 8 ilustra la topología general de una RNA.

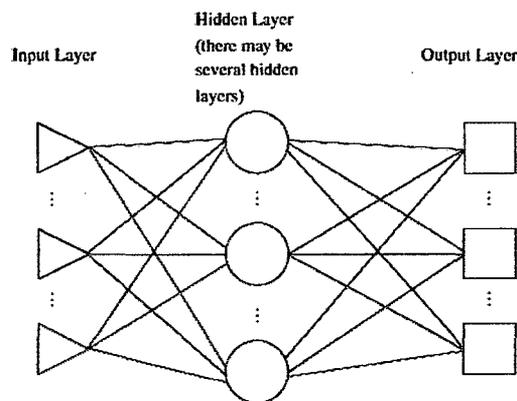


Figura 8. Topología general de una RNA
Fuente: Cheng y Sun (2006)

La red neuronal, completa, representa un muy complejo grupo de interdependencias y en teoría puede incorporar algún grado de no linealidad. Para evaluación de la calidad, funciones muy generales pueden ser modeladas para transformar propiedades físicas en

factores de calidad. La tecnología de RNA permite la extensión de la tecnología de visión por computadora en las áreas de inspección del color, contenido, forma y textura a niveles de rendimiento cercanas a las humanas y puede proveer las capacidades de decisión basadas en tareas de inspección. Recientemente las RNA han sido aplicadas en clasificación, predicción y segmentación en evaluación de la calidad de productos alimenticios usando visión artificial (Cheng y Sun, 2006).

I.6. Software: Algoritmos de análisis de imagen

El software está integrado por una lógica de control, análisis y una interface hombre-máquina. Para el funcionamiento del sistema, el software requiere de la determinación de varios parámetros.

I.6.1. Algoritmo

El concepto intuitivo de algoritmo, lo tenemos prácticamente todos: Un algoritmo es una serie finita de pasos para resolver un problema.

Hay que hacer énfasis en dos aspectos para que un algoritmo exista:

1. El número de pasos debe ser finito. De esta manera el algoritmo debe terminar en un tiempo finito con la solución del problema,
2. El algoritmo debe ser capaz de determinar la solución del problema.

De este modo, podemos definir algoritmo como un "conjunto de reglas operacionales inherentes a un cómputo". Se trata de un método sistemático, susceptible de ser realizado mecánicamente, para resolver un problema dado.

Sería un error creer que los algoritmos son exclusivos de la informática.

También son algoritmos los que aprendemos en la escuela para multiplicar y dividir números de varias cifras. De hecho, el algoritmo más famoso de la historia se remonta a la antigüedad: se trata del algoritmo de Euclides para calcular el máximo común divisor.

Siempre que se desee resolver un problema hay que plantearse qué algoritmo utilizar. La respuesta a esta cuestión puede depender de numerosos factores, a saber, el tamaño del problema, el modo en que está planteado y el tipo y la potencia del equipo disponible para su resolución.

I.6.2. Matlab

MATLAB (abreviatura de MATrix LABoratory, "laboratorio de matrices") es un software matemático que ofrece un entorno de desarrollo integrado (IDE) con un lenguaje de programación propio (lenguaje M). Está disponible para las plataformas Unix, Windows y Apple Mac OS X.

Entre sus prestaciones básicas se hallan: la manipulación de matrices, la representación de datos y funciones, la implementación de algoritmos, la creación de interfaces de usuario (GUI) y la comunicación con programas en otros lenguajes y con otros dispositivos hardware. El paquete MATLAB dispone de dos herramientas adicionales que expanden sus prestaciones, a saber, Simulink (plataforma de simulación multidominio) y GUIDE (editor de interfaces de usuario - GUI). Además, se pueden ampliar las capacidades de MATLAB con las cajas de herramientas (toolboxes); y las de Simulink con los paquetes de bloques (blocksets).

II. MATERIALES Y MÉTODOS

II.1. Lugar de ejecución

Laboratorio de Ingeniería de la Escuela Académico Profesional de Ingeniería Agroindustrial de la Facultad de Ingeniería y Ciencias Agrarias – Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas

II.2. Material biológico

- Muestras de tomate de árbol (*Cyphomandra betacea*), Fotografía 1 de los anexos.

II.3. Equipos

- Computadora core i3 - 380M - 4 RAM - 500 GB de disco duro.
- Equipo de sistema de visión computacional.
- Luxómetro digital, modelo LX 1330B
- Memoria USB 4GB.
- pH metro (potenciómetro) e $\pm 0,01$
- Refractómetro

II.4. Métodos

La metodología empleada para lograr el objetivo principal se dividió en tres fases, mismas que a continuación se detallan.

Determinación de parámetros de color en diferentes estados de madurez de tomate de árbol (*Cyphomandra betacea*); esta fase requirió el uso de un sistema de visión por computadora, desarrollado y aplicado a trabajos de tesis anteriores.

Los pasos seguidos se detallan a continuación:

1- Recolección de muestras; las muestras de tomate de árbol fueron adquiridas en el mercado local, cuidando que estas se encontraran en diferentes estados de madurez; tomando como indicador de madurez el color de la cáscara.

En este sentido las muestras se clasificaron, en verdes y maduras, de acuerdo al color tal como se muestra en la Figura 9; la consideración base de esta clasificación fue que muestras con coloraciones intermedias, entre los máximos indicados como verde y maduro, corresponderían a estadios intermedios de madurez.

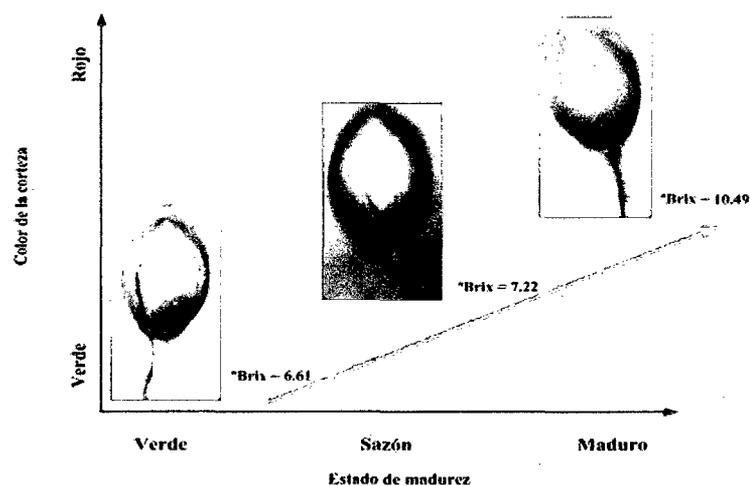


Figura 9. Extremos en los estados de madurez de acuerdo al color de la corteza

Adquisición de imágenes; posteriormente al proceso de clasificación se procedió a la adquisición de las imágenes. Para este fin se hizo uso del sistema de adquisición de imágenes detallado cuyo esquema se muestra en la Figura 10.

En esta investigación aunque se contó con el hardware y el software; sin embargo, fue necesario realizar ajustes a ambas partes del sistema a fin de

adecuar las condiciones de iluminación y exposición de la imagen y reducir de esta manera los “artefactos²” generados en las imágenes captadas por el mismo.

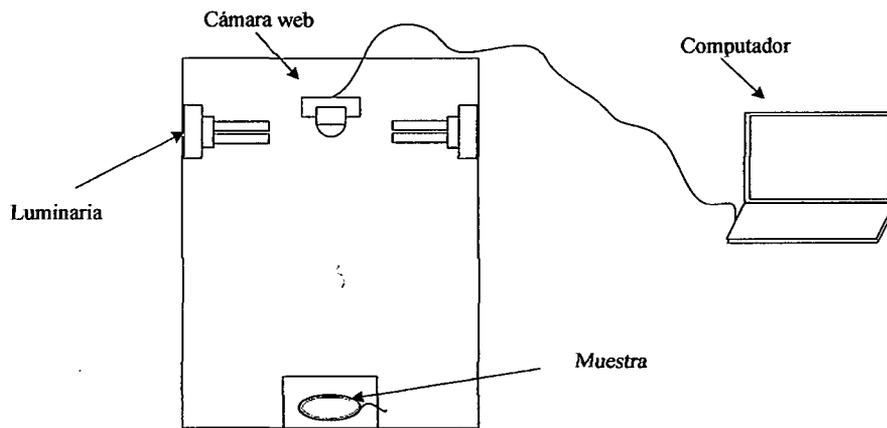


Figura 10. Sistema de visión por computadora utilizado la labor experimental. Al finalizar la calibración del sistema fueron dispuestas las muestras y se procedió a adquirir las imágenes, en formato RGB, mediante el guide Video1 implementado en el software matemático Matlab versión 2011a, tal como se muestra en la Figura 11 .

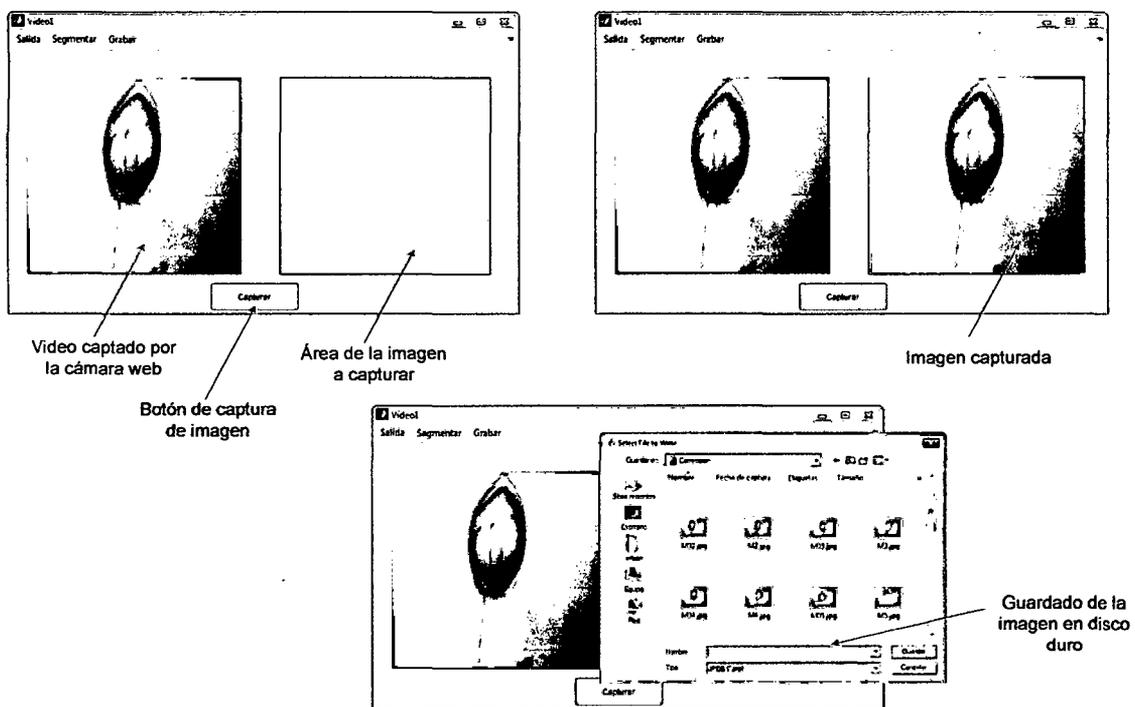


Figura 11. Adquisición y guardado de imágenes mediante el guide Video1

² El termino artefacto engloba diversos elementos indeseables en una imagen, incrementando el tiempo de pre-procesamiento, debidos estos a mal enfoque, excesiva o poca iluminación, geometría de la muestra, etc.

2- Procesamiento de imágenes- las imágenes adquiridas fueron pre-procesadas, a fin de eliminar el fondo de la imagen y permitir una adecuada segmentación, aislamiento de elementos de interés. Los algoritmos para este fin fueron proporcionados por Huamán y Saldaña (2012) en su tesis “Cambios en los parámetros de color de rodajas de yacón (*Smallantus sonchifolius*) mínimamente procesadas obtenidas mediante visión computacional”, a fin de aislar los elementos de interés en su trabajo de investigación, rodajas de yacón.

Anexo 1 Aquí apreciamos el algoritmo en detalle y su resultado al aplicarse en el presente trabajo de investigación se pueden apreciar en la Figura 12.

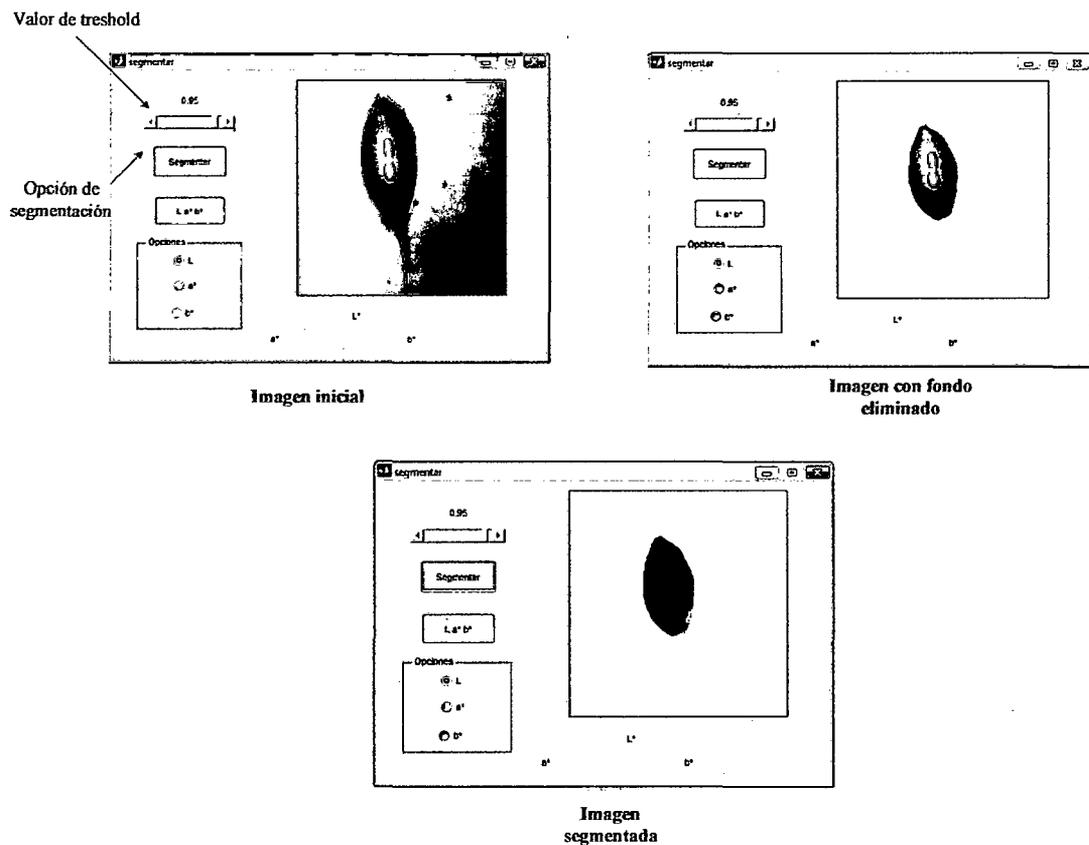


Figura 12. Resultado de la aplicación del algoritmo de segmentación

3- Determinación de parámetros de color- los parámetros de color fueron obtenidos mediante la función LAB, también observable en el Anexo 1. Esta función analiza el color de la imagen obtenida al aplicar la función de segmentación. Dicha imagen al ser, esencialmente, una matriz tridimensional. El valor de los elementos, pixeles, que conforman la matriz se encuentra en el rango de [0 a 255], véase Figura 13, cada dimensión de dicha matriz representa un color básico (R = red, G = green, B = blue) y cuya combinación, suma o resta, genera los colores observables en la imagen.

Al aplicar la función LAB los valores numéricos de cada pixel del elemento de interés, así como su histograma, son calculados mediante las funciones propuestas por Huamán y Saldaña (2012).

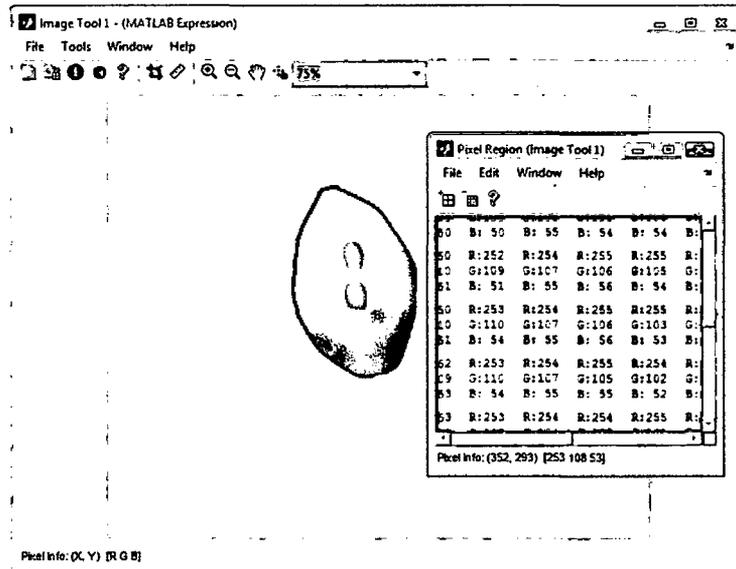


Figura 13. Matriz tridimensional

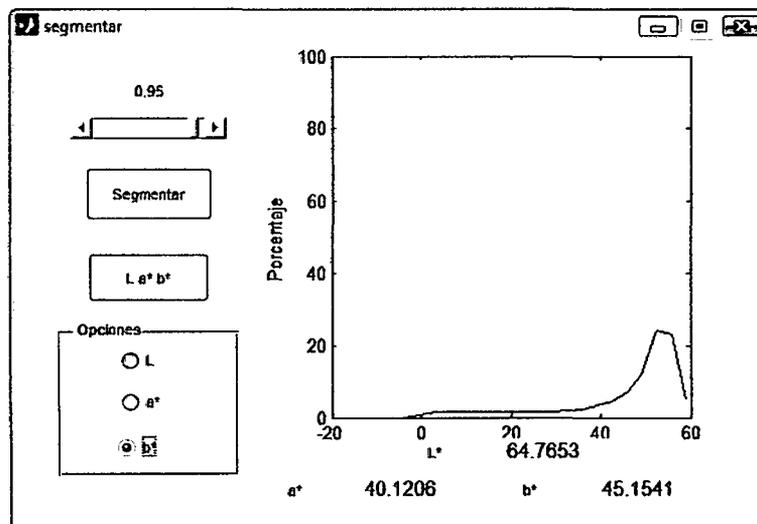


Figura 14. Resultados de la aplicación de función Lab

Estos datos se registraron en tablas. En este punto es necesario mencionar los códigos que se utilizan exclusivamente para identificar las muestras y permitir la posterior correlación entre las propiedades fisicoquímicas (pH y °Brix) y parámetros de color en el espacio CIELab.

- d) Determinación del pH y °Brix en tomate de árbol (*Cyphomandra betacea*); para este fin cada una de las muestras fueron analizadas para determinar el valor de pH y °Brix, aplicando los métodos 932.12 y 970.21, modificados para su uso con los frutos en cuestión; algunas fotografías del proceso y los detalles de estos métodos se pueden apreciar en los anexos. Los resultados se recogieron en tablas, de acuerdo a la codificación de las muestras.

En este caso los códigos son los mismos que fueron utilizados en la determinación de los parámetros de color.

- e) Determinación predictiva de pH y °Brix a partir de parámetros de color; para este fin se aplicó una red neuronal artificial y cuya implementación se realizó en el software matemático Matlab 2011a.

La arquitectura de la red neuronal planteada se obtuvo a partir de un proceso de minimización del porcentaje de error; para lo cual la variable a optimizar fue el número de neuronas por capa.

Número de capas: 2

Número de neuronas: [1 a 40]

Funciones de activación: tangente sigmoidea (tansig)

Es decir, fueron probadas 1600 combinaciones de tamaños para las capas ocultas 1 y 2; el error analizado fue $error(\%) = 100(Lr - Lc)/Lr$ donde Lr = lectura real y Lc = lectura calculada.

La predicción se realizó utilizando los valores de L, a^* y b^* de las imágenes de muestra y con ellas determinando los valores pH y °Brix. Posteriormente, con los valores calculados y los valores reales, se determinó el error porcentual (%) de la estimación.

III.RESULTADOS

Los resultados obtenidos, como respuestas a cada uno de los objetivos planteados en la presente tesis se muestran en las siguientes páginas.

III.1. Parámetros de color tomate de árbol

Los resultados de la determinación de los parámetros de color en las muestras analizadas, se muestran en las figuras 17 a 19 los valores de los parámetros L, a* y b* en las muestras analizadas.

Tabla 1. Resultados de los parámetros de color en las muestras analizadas

Código	L	a*	b*
M.1	66.88	31.37	47.81
M.2	62.15	-9.56	18.25
M.3	60.70	14.23	31.90
M.4	64.82	19.07	38.38
M.5	61.60	25.33	40.37
M.6	67.18	-6.71	23.22
M.7	76.70	18.90	46.69
M.8	74.26	23.42	49.27
M.9	64.66	25.92	42.61
M.10	67.02	21.51	44.30
M.11	62.16	33.69	46.51
M.12	74.17	22.65	46.00
M.13	74.77	40.87	45.15
M.14	58.27	1.83	19.77
M.15	65.09	19.41	41.17
M.16	63.20	9.22	38.74
M.17	71.41	9.52	40.10
M.18	69.64	1.70	31.91
M.19	61.33	31.27	45.71
M.20	68.17	-22.14	26.49
M.21	57.45	26.58	41.87
M.22	75.48	16.96	43.43
M.23	54.92	14.86	38.44
M.24	64.00	22.59	39.63
M.25	63.06	30.93	47.41
M.26	70.25	19.81	48.04
M.27	66.87	31.44	48.36
M.28	79.81	9.79	46.19
M.29	58.07	8.00	29.83

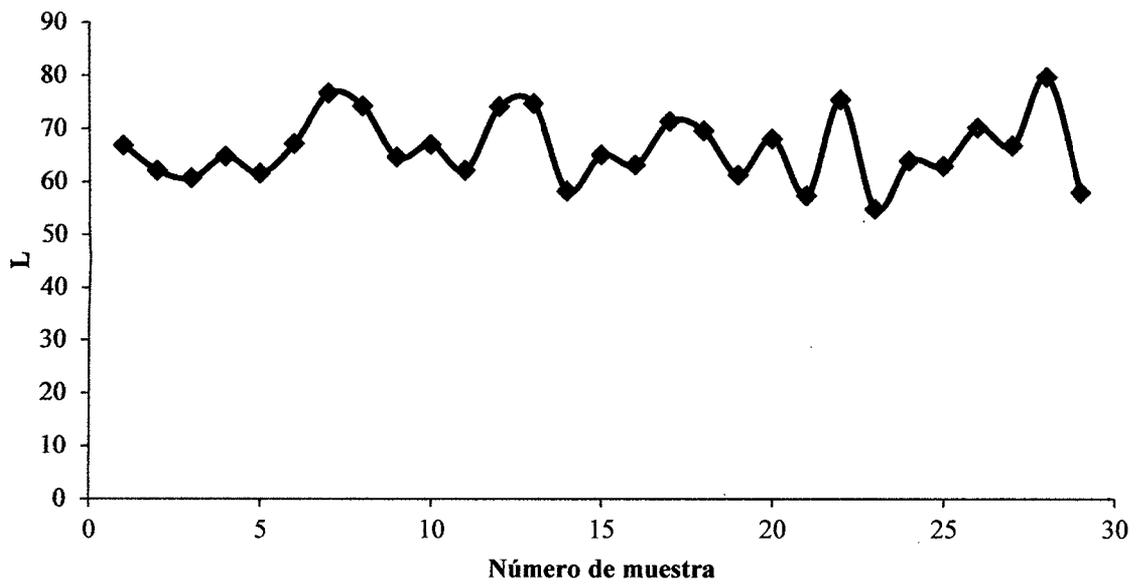


Figura 15. Parámetro L de las muestras analizadas

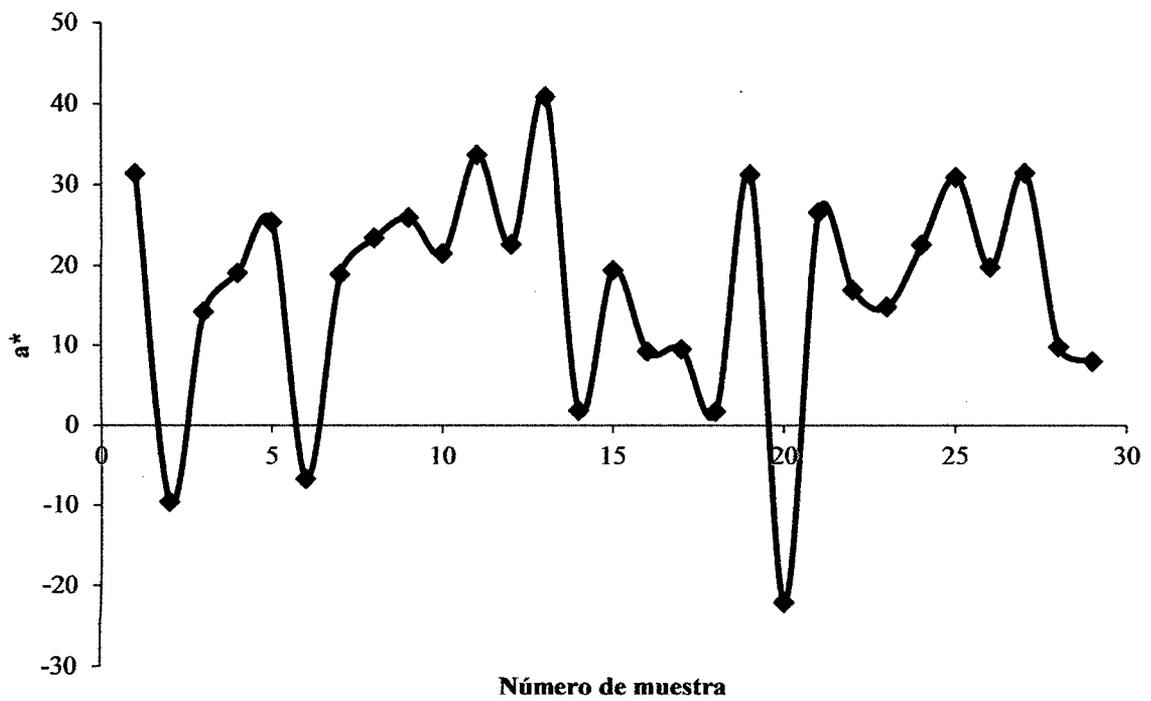


Figura 16. Parámetro a* de las muestras analizadas

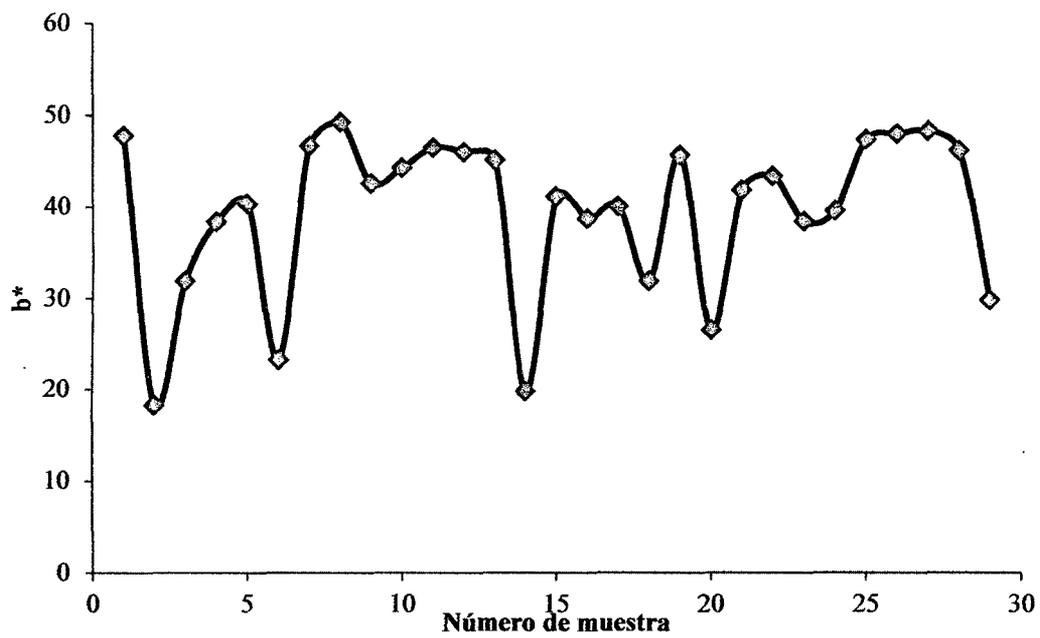


Figura 17. Parámetro b* de las muestras analizadas

Por otro lado en la Figura 18 se muestran los parámetros de color de tres de las muestras analizadas en diferentes estadios de madurez.



M2
L = 62.15
a* = -9.56
b* = 18.25



M29
L = 58.07
a* = 8.00
b* = 29.83



M13
L = 74.77
a* = 40.87
b* = 45.15

Figura 18. Parámetros de color de tres estados de madurez de tomate de árbol

III.2. Determinación del pH y °Brix en tomate de árbol

En la Tabla 2 se muestran los resultados de la determinación de pH y °Brix de las muestras analizadas, ordenadas según el código asignado a cada una de estas. Los valores mínimos y máximos para cada una de las muestras se detallan en la tabla 3.

Tabla 2. Resultados de los parámetros de color en las muestras analizadas

Código	pH	°Brix	Código	pH	°Brix
M.1	9.86	4.98	M.16	7.58	4.22
M.2	6.61	3.98	M.17	8.41	3.73
M.3	8.29	4.29	M.18	7.50	3.99
M.4	8.50	4.14	M.19	9.52	4.87
M.5	9.10	3.98	M.20	5.56	3.55
M.6	6.04	3.65	M.21	9.12	4.22
M.7	9.29	4.13	M.22	8.22	4.10
M.8	8.94	4.29	M.23	8.08	3.94
M.9	9.78	4.86	M.24	9.35	4.36
M.10	8.86	4.46	M.25	9.60	4.87
M.11	10.28	4.39	M.26	8.40	3.98
M.12	8.70	3.99	M.27	9.93	4.09
M.13	10.49	5.20	M.28	7.83	4.02
M.14	7.36	3.38	M.29	7.22	3.78
M.15	8.67	4.53			

Tabla 3. Valores mínimos y máximos de pH y °Brix de las muestras

Valor	pH	°Brix
Mínimo	5.6	3.4
Máximo	10.49	5.20

En las siguientes figuras se puede apreciar la variación del pH y °Brix en las muestras analizadas.

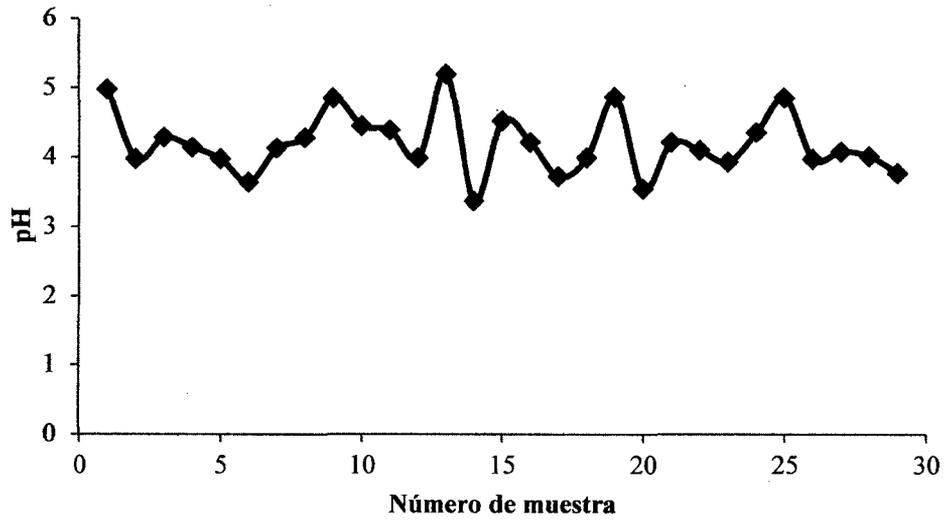


Figura 19. Valores de pH de muestras analizadas

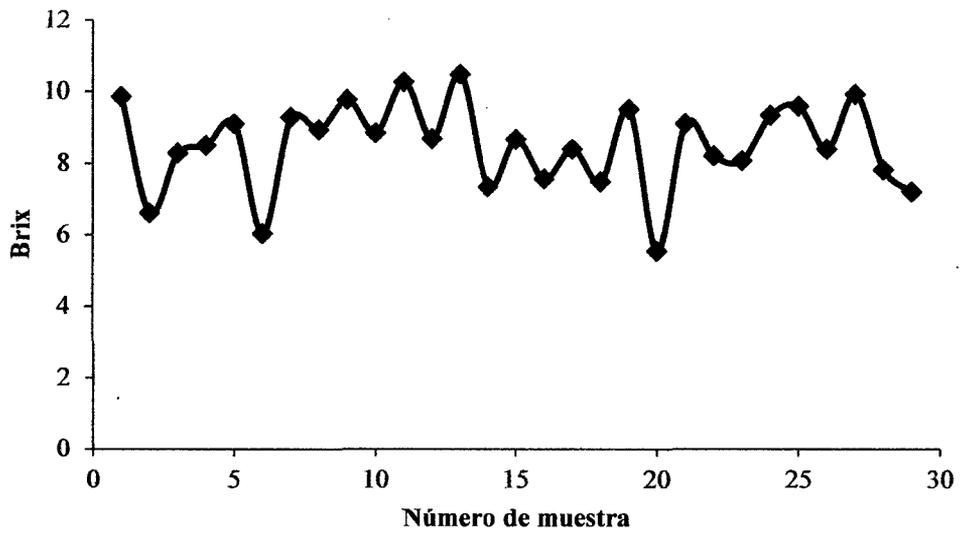


Figura 20. Valores de °Brix de muestras analizadas

III.3. Determinación predictiva de pH y °Brix a partir de parámetros de color.

En las figuras 23 a 24 se muestran las arquitecturas de las redes neuronales utilizadas en la predicción del pH y °Brix del tomate de árbol.

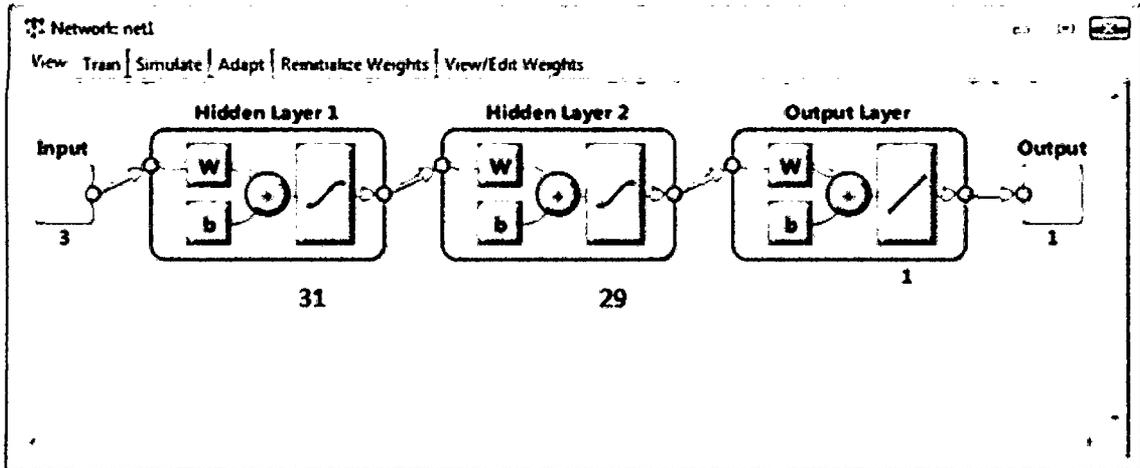


Figura 21. Arquitectura de la red neuronal utilizada para la predicción del °Brix

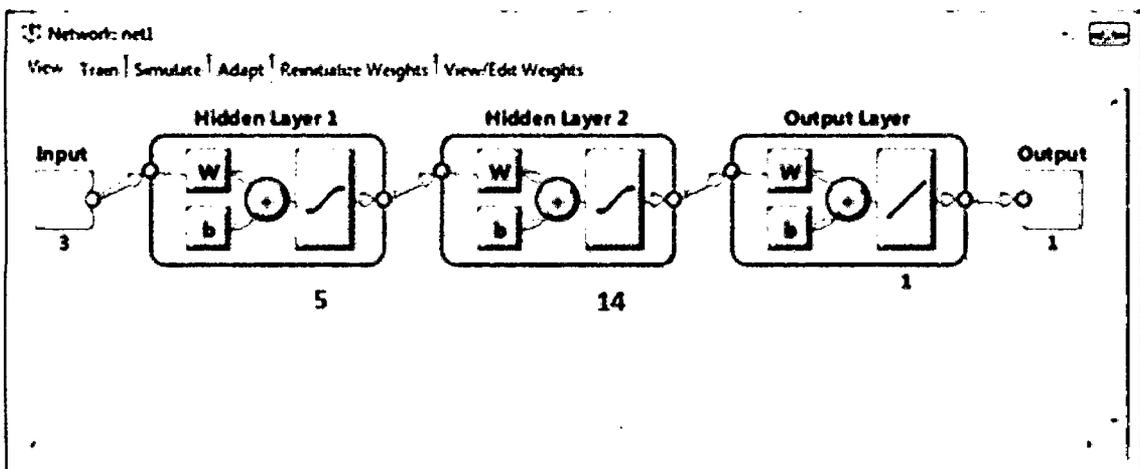


Figura 22. Arquitectura de la red neuronal utilizada para la predicción del pH

En este punto es necesario mencionar que la arquitectura de estas redes se determino a partir del cálculo de los errores cuadrados, para los valores predichos y reales, mismos que se pueden apreciar en los anexos.

Los resultados, así como los errores cuadrados, de la aplicación de las redes neuronales antes mencionadas se pueden apreciar en la Tabla 4.

Tabla 4. Errores cuadrados de la aplicación de redes neuronales a la predicción de °pH y Brix

pH			°Brix		
Real	Simulado	Error (%)	Real	Simulado	Error (%)
4.98	4.03	19.04	9.86	9.31	5.61
3.98	5.26	32.33	6.61	6.42	2.97
4.29	3.95	7.94	8.29	8.43	1.69
4.14	3.54	14.71	8.50	8.03	5.51
3.98	3.78	4.94	9.10	8.68	4.70
3.65	4.87	33.53	6.04	6.21	2.83
4.13	2.88	30.38	9.29	9.65	3.83
4.29	3.07	28.45	8.94	8.82	1.38
4.86	3.48	28.36	9.78	9.46	3.31
4.46	3.42	23.23	8.86	8.88	0.28
4.39	4.12	6.22	10.28	10.02	2.56
3.99	2.92	26.90	8.70	8.68	0.17
5.20	2.92	43.86	10.49	10.44	0.51
3.38	4.29	27.16	7.36	6.79	7.64
4.53	3.55	21.66	8.67	8.33	3.96
4.22	3.81	9.75	7.58	6.82	9.96
3.73	3.12	16.19	8.41	6.65	20.89
3.99	3.66	8.37	7.50	7.20	3.99
4.87	4.05	16.97	9.52	9.67	1.60
3.55	5.67	59.62	5.56	6.14	10.35
4.22	4.17	1.10	9.12	8.89	2.53
4.10	2.83	31.02	8.22	8.52	3.69
3.94	4.25	7.93	8.08	8.14	0.77
4.36	3.52	19.17	9.35	8.78	6.05
4.87	4.23	13.07	9.60	9.46	1.49
3.98	3.41	14.32	8.40	8.46	0.73
4.09	4.14	1.24	9.93	9.30	6.33
4.02	2.84	29.26	7.83	7.99	2.06
3.78	3.96	4.70	7.22	7.51	4.05

En la siguiente figuras se muestran los porcentajes de error alcanzados en la predicción del contenido de °Brix y pH de las muestras.

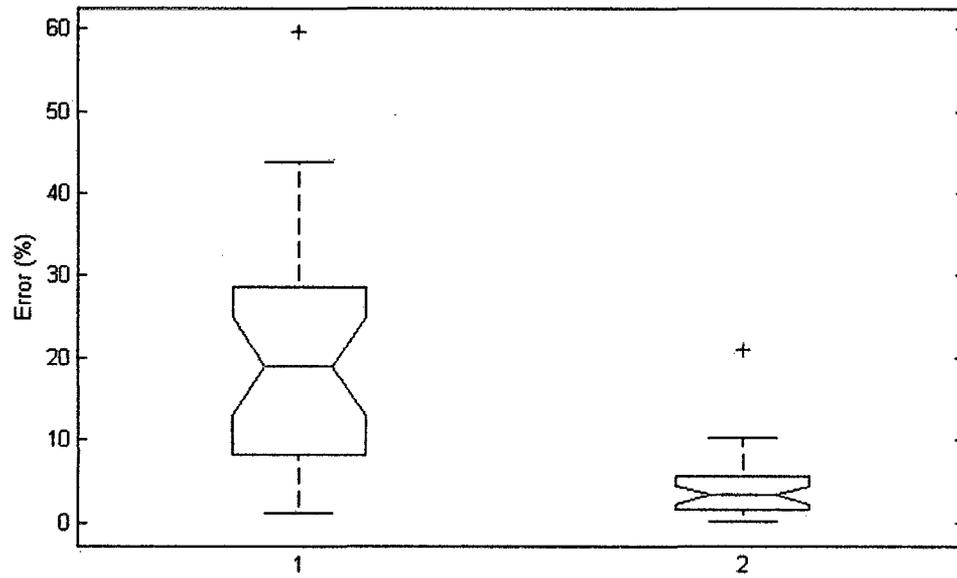


Figura 23. Porcentajes de error en la predicción de pH y °Brix de las muestras
* El numero 1 corresponde a pH y el 2 a °Brix

IV. DISCUSION

Los parámetros de color, determinados en esta investigación y mostrados en la tabla 1, mediante el sistema creado para este fin son dependientes tanto del material así como de las características del sistema (iluminación, sensibilidad del CCD, algoritmo de procesamiento de imágenes, etc.). Por tanto; para que estos sean reproducibles es necesario mantener calibrado el sistema y estabilizar las posibles variables que afecten al rendimiento del mismo, tal como fluctuaciones de voltaje. Al llegar a este punto salta el problema del intercambio de información entre investigadores u laboratorios, debido a que en la actualidad los sistemas de este tipo no han sido estandarizados en las dimensiones, flujos luminosos, etc. y generarán diferencias en los resultados (Abdullah, 2005).

Es así que, en esta investigación, el cálculo del color en el sistema de color CIELab se tuvo en cuenta los valores de los ejes X, Y y Z, geometría de medición, tipo de luz, tipo cámara CCD; por lo tanto, si cambia cualquiera de estos parámetros, cambian también, los valores de L, a* y b*.

En cuanto a los resultados del análisis de color que se presentan en la Tabla 2 No hubo referencias en la literatura sobre los parámetros de color para tomate de árbol y por tanto, simplemente, se presentan los resultados a continuación: L= [54.92-79.81], a*= [-22.14-40.87] y b*= [18.25-49.27]. Al respecto la poca fluctuación de L, nos demuestra que el sistema ha tenido estabilidad en la iluminación de las muestras. Los valores que asume a* (de negativo a positivo) nos indica que el fruto va cambiando de tonalidad verde a roja y los valores asumidos por b* informa del incremento de la saturación del color amarillo.

Por otro lado, es conveniente analizar y correlacionar el cambio en los parámetros de color a^* y b^* en los rangos de $[-22.14 - 40.87]$ y $[18.25 - 49.27]$ respectivamente; esto nos indica, según lo reportado por Westland (2001), que las muestras pasan de tonalidades verdes a rojizas e incrementa las tonalidades de color amarillo; el resultado de estos cambios se observa en la Figura 20, la cual muestra que el tomate de árbol vira de color verde a anaranjado, combinación de rojo y amarillo, durante el proceso de maduración. Por tanto, es posible hacer el seguimiento de la maduración, relacionada con los cambios composicionales del fruto, y clasificar a estos de verde a maduro siguiendo este patrón y aún más utilizarlos, tal como menciona Shewfelt (2009), en la determinación de la composición de frutales.

De acuerdo con la Tabla 3 el pH y el °Brix de las muestras analizadas de tomate de árbol se encuentran en el rango de $[3.40 - 5.20]$ y $[5.60 - 10.49]$ respectivamente; estos valores son cercanos a los reportados por Cáceres (2012), de $[3.17-3.80]$ para el pH y $[13.60-14.80]$ para el °Brix y los utilizados por Tabarez (2003) determino 12 °Brix y 3.7 para el pH. Como es posible observar el valor de pH mínimo determinado en este trabajo es muy cercano a los reportados en trabajos anteriores. Mas el contenido en °Brix en los trabajos citados, tanto de Cáceres (2012) como de Tabarez (2003), es superior al determinado en esta investigación; esto posiblemente debido a las diferencias en el estado de madurez de las frutas como en posibles diferencias en los ecotipos puesto que los trabajos de Cáceres y Tabarez se desarrollaron en Colombia.

En cuanto a la determinación predictiva del pH y °Brix en las muestras, mediante la aplicación de las redes neuronales, se ha demostrado que existen muchas combinaciones posibles y en la presente tesis se han evaluado diferentes combinaciones de número de neuronas por capa, véase las tablas 4 y 5 de los anexos, determinándose de acuerdo al mínimo porcentaje de error que la más adecuada combinación de número de neuronas

por capa es de 31 y 29 para la primera y segunda capa, respectivamente, de la red neuronal creada para la predicción de °Brix en función de los parámetros de color, alcanzado un error total de 1.75 % (98.25% de exactitud). En cuanto a la red neuronal para la determinación de pH se determinó que la más adecuada combinación es 5 y 14 con un error total de 2.4% (97.6% de exactitud). Estos valores se encuentran muy cercanos a los reportados por Du y Sun (2004) para otros productos y lo cual se recoge en la tabla siguiente. De estos se desprende que los parámetros utilizados en la presente investigación pueden utilizarse para la determinación predictiva del pH y °Brix, con relativamente buena exactitud.

Tabla 5. Resumen de aplicaciones de redes neuronales para clasificación de productos alimentarios.

Category	Products	Characterisation	Accuracy (%)
Fishery	Fish	Widths and heights at various locations of different species	95.0
Fruit	Apple	Surface quality conditions	93.3
		Spectral reflectance of blemishes	89.5
		Fractal features	93.0
	Pear	Fourier descriptor of shape	90.0
	Pistachio nuts	Physical attributes	95.9
		X-ray data	88.7
	Strawberry	Shape features	96.0
Table olive	Defects in the surface	96.1	
Grain	Barley	Morphological and colour features	93.2
	Oat	Morphological and colour features	97.8
	Rye	Morphological and colour features	92.7
	Wheat	Morphological and colour features of healthy and damaged kernels	96.0
		Morphological and colour features	97.2
Meat	Beef	Texture features of primitive fractions and run lengths	78.8
	Poultry carcasses	Spectral reflectance of unwholesome and wholesome carcasses	89.1
Vegetable	Carrot	Shape features	88.5
	Green peppers	Shape features	89.0
	Sweet onions	Internal defects	90.0

Fuente: Du y Sun (2004)

V. CONCLUSIONES

- A pesar de la morfología, convexidad, de las muestras la iluminación de la superficie, reflejada en el parámetro L, no se altera significativamente.
- Los parámetros de color, en el espacio CIElab, pueden utilizarse como índices indirectos de la composición de tomate de árbol.
- Es posible realizar la determinación predictiva del pH y °Brix en Tomate de árbol, mediante redes neuronales, alcanzando exactitudes del 98,25 y 97,26 % respectivamente.
- El parámetro de color de mayor relevancia para este sistema de predicción del color es a^* , por cuantificar este el cambio de las tonalidades verdes a rojas.

VI. RECOMENDACIONES

- Aplicar este estudio a otras frutas o productos que tengan variación similar de color en la corteza, a fin de desarrollar la técnica de determinación predictiva y potenciarla como un método no destructivo de análisis de la composición.
- Estandarizar el método de obtención de imágenes a fin de poder uniformizar y difundir una metodología de análisis de imágenes con miras a la aplicación industrial.
- Realizar análisis de imágenes aplicando espectros luminosos de distinto rango, infrarrojos o ultravioleta a fin de determinar el efecto de estos sobre los espectros de la imagen y su relación en posibles aplicaciones industriales de control de los procesos biológicos; tal como el proceso de generación de CO₂ en productos climatéricos.

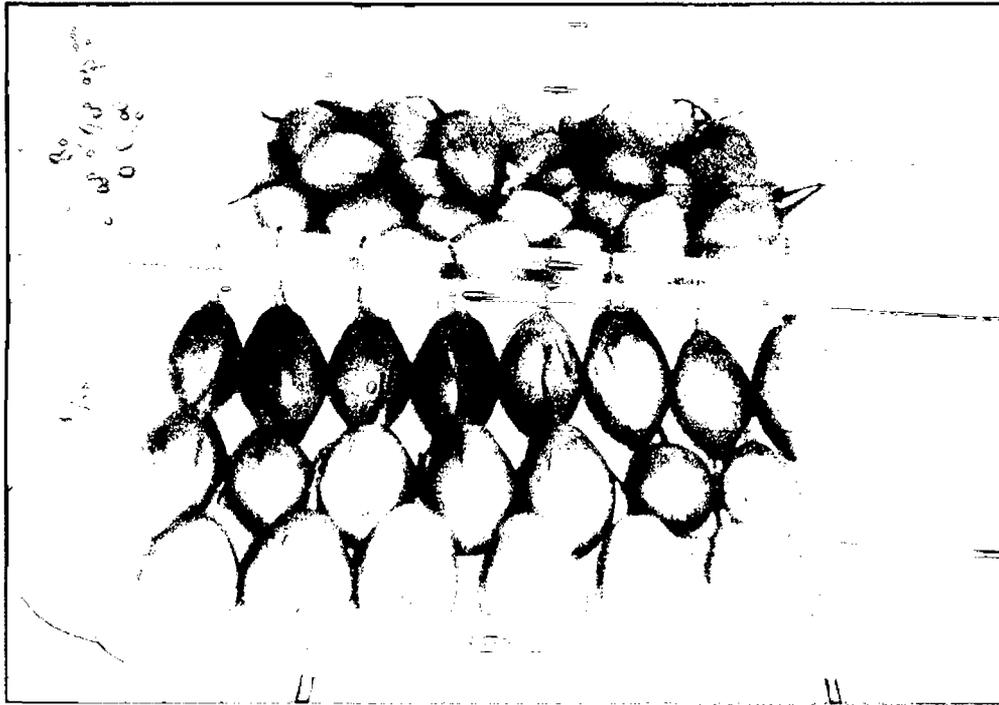
VII. REFERENCIAS BIBLIOGRAFICAS

- Abdullah MZ, A.-A. S.-M. (2000). Quality inspection of bakery products using color-based machine vision system. *Journal of Food Quality*, 39–50.
- Abdullah MZ, F.-S. A.-A. (2005). Automated inspection for color and shape grading of starfruit (*Averrhoa carambola* L.) using machine vision sensor. *Transactions of the Institute Measurement and Control*, 65–87.
- Brosnan, T (2004). Improving quality inspection of food products by computervision. *Journal of Food Engineering*, 125–135.
- Bustos M. (2004). Inteligencia Artificial en el Sector Agropecuario. Seminario de Investigación I. 299622. Versión 1.1. Bogota - Colombia.
- Cáceres, L. (2012). Manejo postcosecha de los frutos de tomate de árbol (*Cyphomandra betacea*) y su relación con el tiempo de vida útil en el mercado central del canton Ambato. Tesis de Maestria. Universidad Técnica de Ambato. Ambato - Ecuador.
- Cheng, J. y Sun, D. (2006). Learning techniques used in computer vision for food quality evaluation: a review. *Journal of Food Engineering*. 72. 39–55.
- Du, C. y Sun, D. (2004). Shape extraction and classification of pizza base using computer vision. *Journal of Food Engineering*, 489–496.
- Huaman, R. y Saldaña, E. (2012). Cambios en los parámetros de color de rodajas de yacón (*Smallantus sonchifolius*) mínimamente procesadas obtenidas mediante visión computacional. Tesis de pregrado. Universidad Nacional de Trujillo.
- Leon, K. M. (2006). Color measurement in $L^*a^*b^*$ units from RGB digital images. *Food Research International*, 1084–1091.

- Navarrete, N. y Gemma M. (2003). Influence of osmotic pre-treatment and microwave application on properties of air dried strawberry related to structural changes. Ref. revista: European Food Research and Technology.
- Pearson, T. (1996). Machine vision system for automated detection of stained pistachio nuts. Lebensmittel Wissenschaft und Technologie, 203-209.
- Pedreschi F, L. J. (2006). Development of a computer vision system to measure the color of potato chips. Food Research International, 1092–1098.
- Sun D. y Du, C. (2004). Segmentation of complex food images by stick growing and merging algorithm. Journal of Food Engineering, 17–26.
- Sun, D. (2000). Inspecting pizza topping percentage and distribution by a computer vision method. Journal of Food Engineering: 245–249.
- Tabares, C. y Velasquez, J. (2003). Estudio de la vida de anaquel del tomate de arbol (Cyphomandra betacea) osmodeshidratado empacado en atmosferas modificadas. Tesis de pregrado. Universidad Nacional de Colombia.
- Tao Y, H. P. (1995). Machine vision for color inspection of potatoes and apples. Transactions of the ASAE, 1555–1561.

ANEXOS

Anexo 1. Fotografías



Fotografía 1. Muestras de tomate de árbol



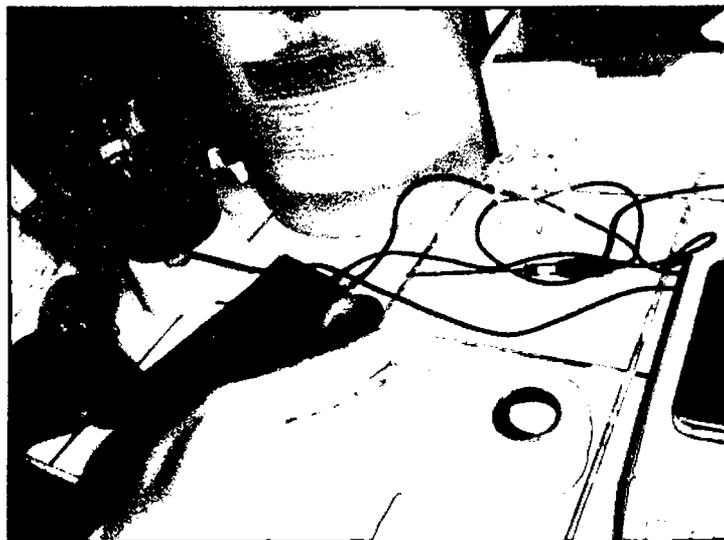
Fotografía 2. Adecuación del sistema de adquisición de imágenes



Fotografía 3. Colocación de muestras y sistema de adquisición de imágenes



Fotografía 4. Acondicionamiento de las muestras para la determinación de pH y °Brix



Fotografía 5. Determinación de pH y °Brix

Anexo 2. Código fuente

OBTENCIÓN DE FOTOGRAFÍAS

```
function varargout = Video1(varargin)
gui_Singleton = 1;
gui_State = struct('gui_Name',    mfilename, ...
                  'gui_Singleton', gui_Singleton, ...
                  'gui_OpeningFcn', @Video1_OpeningFcn, ...
                  'gui_OutputFcn', @Video1_OutputFcn, ...
                  'gui_LayoutFcn', [] , ...
                  'gui_Callback', []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end

if nargin
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
```

EJECUCIÓN AL ABRIR EL GUIDE

```
function Video1_OpeningFcn(hObject, eventdata, handles, varargin)
%Declaración de variables globales
global vid
%Capturando la información del video
vid = videoinput('winvideo', 1, 'UYVY_720x480');
%Cambiano el espacio de color a rgb
vid.ReturnedColorspace = 'rgb';
%Seteando la salida de la cámara al guide
vidRes = get(vid, 'VideoResolution');
nBands = get(vid, 'NumberOfBands');
hImage = image(zeros(vidRes(2), vidRes(1), nBands), 'Parent',...
              handles.Video);
```

```

%Mostrando la imagen previsualizada
preview(vid,hImage);
%Eliminando los ejes del axes Fotografía
axes(handles.Fotografia);
box on; Showaxes('off')
%Retornando el eje al axes Video
axes(handles.Video);
handles.output = hObject;
guidata(hObject, handles);
%Salida a la línea de comando

function varargout = Video1_OutputFcn(hObject, eventdata, handles)
varargout{1} = handles.output;

```

EJECUCIÓN AL HACER CLIC SOBRE EL BOTÓN CAPTURAR

```

function Capturar_Callback(hObject, eventdata, handles)
%Declaración de variables globales
global vid Fotografia rgb
%Obtención de la fotografía
Fotografia = getsnapshot(vid);
%Muestra la fotografía
axes(handles.Fotografia);
image(Fotografia,'Parent',handles.Fotografia);
%Muestra la fotografía realizada
rgb = getimage(handles.Fotografia);
if isempty(rgb), return, end
box on; Showaxes('off')
handles.output = hObject;
guidata(hObject, handles);

```

FUNCIÓN PROCESAR IMAGEN EN LAB

```
function cmd_lab_Callback(hObject, eventdata, handles)
% Cierre de guide Video1
Close(Video1)
% Llamada a guide LAB1
LAB1
```

FUNCIÓN PARA GUARDAR FOTOGRAFÍA

```
function cmd_grabar_Callback(hObject, eventdata, handles)
global rgb
% Guardar como archivo
fileTypes = supportedImageTypes;
% Función auxiliar.
[f,p] = uiputfile(fileTypes);
if f==0, return, end
fName = fullfile(p,f);
imwrite(rgb,fName);
msgbox(['Imagen guardada en ' fName]);
```

FUNCIÓN TIPO DE ARCHIVOS - PARA GRABAR FOTOGRAFÍA

```
function fileTypes = supportedImageTypes
% Función auxiliar: formatos de imágenes.
fileTypes = {'*.jpg','JPEG (*.jpg)';*.tif,'TIFF (*.tif)';...
'*.bmp','Bitmap (*.bmp)';*.*,'All files (*.*)'};
```

FUNCIÓN DE SALIDA DEL GUIDE

```
function salida_Callback(hObject, eventdata, handles)
clc, close(Video1)
```

LLAMADA AL GUIDE SEGMENTAR

```
function cmd_segmentar_Callback(hObject, eventdata, handles)
close(Video1);
```

FUNCTION SEGMENTAR

```
function varargout = segmentar(varargin)
gui_Singleton = 1;
gui_State = struct('gui_Name',    mfilename, ...
                  'gui_Singleton', gui_Singleton, ...
                  'gui_OpeningFcn', @segmentar_OpeningFcn, ...
                  'gui_OutputFcn', @segmentar_OutputFcn, ...
                  'gui_LayoutFcn', [] , ...
                  'gui_Callback', []);
if nargin && ischar(varargin{1})
    gui_State.gui_Callback = str2func(varargin{1});
end
if nargout
    [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
else
    gui_mainfcn(gui_State, varargin{:});
end
```

MUESTRA LA IMAGEN LA IMAGEN FOTOGRAFÍA EN EL GUIDE

```
function segmentar_OpeningFcn(hObject, eventdata, handles, varargin)
%Declaración de variable global fotografia
global Fotografia Th
Fotografia =imread('2.jpg');
%Inicializando Th
Th=0.95;
set(handles.txt_Th,'String','0.95')
set(handles.sld_Th,'Value',0.95)
%Muestra la fotografía
image(Fotografia,'Parent',handles.axes1);
box on; Showaxes('off')
handles.output = hObject;
% Update handles structure
guidata(hObject, handles);
```

SALIDA A LA LÍNEA DE COMANDOS

```
function varargout = segmentar_OutputFcn(hObject, eventdata, handles)
varargout{1} = handles.output;
```

EJECUCIÓN DEL COMANDO SEGMENTAR

```
function Segmentar_Callback(hObject, eventdata, handles)
global Fotografia Th R G B imge
%aplicando la funcion callIm
[R G B imge]=callIm(Fotografia,Th);
%Muestra la nueva imagen etiquetada
image(label2rgb(imge),'Parent',handles.axes1);
box on; Showaxes('off')
%Salvando los datos de la imagen
save R R; save G G; save B B
```

EJECUCIÓN EN CADA MOVIMIENTO DEL SLIDER

```
function sld_Th_Callback(hObject, eventdata, handles)
%declaracion de variable global
global Th
Th=get(hObject,'Value');
set(handles.txt_Th,'String',Th);
```

EJECUCIÓN AL CREAR EL SLD_TH

```
function sld_Th_CreateFcn(hObject, eventdata, handles)
% Hint: slider controls usually have a light gray background.
if isequal(get(hObject,'BackgroundColor'), get(0,'defaultUicontrolBackgroundColor'))
    set(hObject,'BackgroundColor',[.9 .9 .9]);
end
```

LLAMADA A LA FUNCIÓN LAB

```
function LAB_Callback(hObject, eventdata, handles)
```

```
%declaración de variables globales
```

```
global R G B L a b
```

```
%separación de imagen en matrices R,G y B
```

```
imaR= double(R)/255;
```

```
imaG= double(G)/255;
```

```
imaB= double(B)/255;
```

```
%determinando la dimensión de la matriz
```

```
[nfil ncol]=size(imaR);
```

```
for i=1:nfil
```

```
    for j=1:ncol
```

```
        if (imaR(i,j) > 0.04045 )
```

```
            imaR(i,j)= ((imaR(i,j)+0.055)/1.055 )^ 2.4;
```

```
        else
```

```
            imaR(i,j) = imaR(i,j) / 12.92;
```

```
        end
```

```
    end
```

```
end
```

```
for i=1:nfil
```

```
    for j=1:ncol
```

```
        if (imaG(i,j)>0.04045 )
```

```
            imaG(i,j)= ((imaG(i,j) + 0.055 )/1.055)^ 2.4;
```

```
        else
```

```
            imaG(i,j) = imaG(i,j) / 12.92;
```

```
        end
```

```
    end
```

```
end
```

```

for i=1:nfil
    for j=1:ncol
        if (imaB(i,j) > 0.04045 )
            imaB(i,j) = ((imaB(i,j) + 0.055 ) / 1.055 ) ^ 2.4;
        else
            imaB(i,j) = imaB(i,j) / 12.92;
        end
    end
end

imaR = imaR*100; imaG = imaG*100; imaB = imaB*100;
%Pasando de RGB a XYZ
% Constantes para el Observador = 2°, Illuminant = D65
X = imaR.*0.4124 + imaG.*0.3576 + imaB.*0.1805;
Y = imaR.*0.2126 + imaG.*0.7152 + imaB.*0.0722;
Z = imaR.*0.0193 + imaG.*0.1192 + imaB.*0.9505;
%Pasando de XYZ a Lab
var_X = X./95.047; %usando Observador= 2°, Illuminant= D65
var_Y = Y./100.000;
var_Z = Z./108.883;
%Determinando la dimensión de la matriz
[nfil ncol]=size(var_X);
%seteando var_X, var_Y, var_Z
for i=1:nfil
    for j=1:ncol
        if (var_X(i,j)>0.008856 )
            var_X(i,j)=var_X(i,j).^(1/3);
        else
            var_X(i,j)=(7.787*var_X(i,j))+(16/116);
        end
    end
end
end

```

```

for i=1:nfil
    for j=1:ncol
        if (var_Y(i,j)>0.008856 )
            var_Y(i,j)=var_Y(i,j).^(1/3);
        else
            var_Y(i,j)=(7.787*var_Y(i,j))+(16/116);
        end
    end
end
end

```

```

for i=1:nfil
    for j=1:ncol
        if (var_Z(i,j)>0.008856 )
            var_Z(i,j)=var_Z(i,j).^(1/3);
        else
            var_Z(i,j)=(7.787*var_Z(i,j))+(16/116);
        end
    end
end
end

```

%Calculando matrices L, a*, b

```

L =(116.*var_Y)-16;
a=500.*(var_X-var_Y);
b=200.*(var_Y-var_Z);

```

```

cla;

```

```

save L L

```

```

save a a

```

```

save b b

```

EJECUCIÓN AL CAMBIAR EL OPTION BUTTON

```
function optcnt_SelectionChangeFcn(hObject, eventdata, handles)
%declaración de variables globales
global L a b
d=size(L);
switch get(eventdata.NewValue,'Tag')
% Get Tag of selected object.
    case 'optL'
        [n xout]=hist(L,20);
        xlabel('Valor L')
    case 'opta'
        [n xout]=hist(a,20);
        xlabel('Valor a')
    case 'optb'
        [n xout]=hist(b,20);
        xlabel('Valor b')
end
n=n./d(2);
plot(xout, n*100)
ylim([0 100]);
ylabel('Porcentaje')
```

Anexo 3. Métodos de determinación del pH y °Brix

La determinación del porcentaje de sólidos solubles (°Brix) se realizó mediante el método oficial AOAC 932.12.

**AOAC Official Method 932.12
Solids (Soluble)
In Fruits and Fruits Products**

**Refractometer Method
Final Action 1980**

(Insoluble matter present. Applicable to fresh and canned fruits, fruit jellies, marmalades, and preserves)

% Soluble solids = % solids determined by refractometer x (100-b)/100, where b = % H₂O-insoluble solids.

Note: U.S. Federal standards for frozen fruits, canned fruits, fruits jellies, and preserves make no correction for H₂O-insoluble solids, invert sugar, or other substances.

Reference: JAOAC 15,384 (1932)

**AOAC Official Method 970.21
pH of Cacao Products
Potentiometric Method
First Action 1970
Final action 1974**

- (a) For products other than cacao butter.- weigh 10 g sample into 150 mL beaker and slowly add, with stirring 90 mL boiling H₂O. Suspension must be free from lumps. Filter, cool filtrate to 20-25 °C, and immediately determine pH, using electrodes and potentiometer standardized with buffer at pH 4.0 and 6.86. Report to nearest 0.1 pH unit.
- (b) For cacao butter. - Melt sample and mechanically stir 5 min with equal weight of H₂O at 50 °C. Separate aqueous layer, cool to 20 – 25 °C, filter, and determine pH as in (a).

References: Analytical method of the office international du Cacao et du Choclat Niklausstrasse 4, Zurich, Switzerland, page 9-E/1963. JAOAC 53, 474 (1970).