

Análisis Difuso de Imágenes a Color de Productos Agrícolas

Jose Luis Troncoso¹, Trung T. Pham¹, Ph.D., Per Bro², Ph.D.

¹Escuela de Ingeniería Informática Empresarial, Universidad de Talca – Campus Lircay, Talca, Chile

²Facultad de Ingeniería, Universidad de Talca – Campus Curicó, Curicó, Chile

jtroncoso@alumnos.otalca.cl, tpham@otalca.cl, pbro@otalca.cl

Resumen. Este artículo presenta un método de aproximación difuso para analizar la calidad de las frutas en la Zona Central de Chile sobre la base de las imágenes en color de estas frutas. Las imágenes están tomadas al principio de la cinta transportadora en un proceso automatizado de variedad (para los envases). Las imágenes se procesan para obtener información cuantitativa preliminar sobre la calidad de los frutos: color, textura, tamaño, etc. Luego, estos datos se analizan (por software) basados en un conjunto de reglas de lógica difusa dados a priori por los expertos para determinar la calidad del lote de los frutos. La información de calidad se utiliza para el control de calidad, asignación de destino, post-procesamiento, etc. También (la información de calidad) puede ser utilizado en futuras investigaciones como una retroalimentación automática en un semi-supervisado proceso de aprendizaje para descubrir las nuevas reglas de análisis y reforzar las reglas existentes.

1. Introducción

La agricultura es un sector importante e integral de la economía chilena [1-4]. En éste, la exportación de productos agrícolas a países desarrollados, alcanza una cantidad aproximada de 14 mil millones de dólares anuales, según lo estimado en 2008 [5]. Esta cantidad considerable de dinero es la fuerza motriz para garantizar un flujo continuo de ingresos en la economía nacional. A fin de lograr esta continuidad, es importante garantizar la calidad de los productos exportados para establecer la imagen de marca y la confianza de los consumidores [6-7]. Por lo tanto, los aspectos del control y aseguramiento de la calidad de los productos agrícolas son importantes en la exportación para mantener la ventaja competitiva y la cuota de mercado internacional.

A pesar de que el trabajo manual es bastante barato en Chile [8], el costo añadido de la inspección manual eventualmente puede neutralizar la ventaja del costo de los productos chilenos en el mercado internacional. Por esta razón, es que son ampliamente utilizados los sistemas automatizados para el surtido de frutas y envasado [9-10]. Sin embargo, este tipo de sistemas aún requiere la inspección manual en el bucle de control de la calidad y la toma de rápidas decisiones para mantener o eliminar las frutas de la cinta transportadora que se

mueven a través del proceso de calibrado y envasado. Este proceso de inspección de frutas es bastante simple, pero su carácter repetitivo fácilmente puede degradar la eficacia de la cognición humana y aumentar el tiempo necesario para realizar las tareas simples pero repetitivas. Por lo tanto, la ventaja del bajo costo de mano de obra (por unidad de tiempo) puede ser fácilmente anulada por el aumento del número de unidades de tiempo necesarios para realizar una tarea simple.

Los esfuerzos realizados para proporcionar un análisis automatizado de las frutas han sido por medio de imágenes digitales [11-13]. Cada uno de éstos se centró en la detección de una característica específica de una única fruta, basado en el procesamiento digital de imágenes. El tamaño de una fruta puede obtenerse con la extracción de alambre [14] de la fruta y la distancia entre la cámara y ésta. El color de la piel se puede obtener con la detección y eliminación de los antecedentes [15] para aislar los pertinentes píxeles espaciales que muestran el color de la fruta. La mancha [16] de la piel puede ser detectada con diferentes técnicas de análisis de las relaciones espaciales entre los píxeles correspondientes.

Este estudio propone un sistema automatizado de toma decisional, usando imágenes digitales, aplicando lógica difusa, para la inspección masiva de calidad en el

proceso productivo, a frutas de la Zona Central de Chile. En la infraestructura actual, la fruta ya está ordenada y envasada de forma automática, donde, en primer lugar, las frutas son cargadas en una cinta transportadora que se mueve a través de un mecanismo de calibre que las separa acorde a sus tamaños. Luego, son trasladadas a un mecanismo de embalaje que son puestas en las cajas de cartón, y después, en los pallets. Los pallets se cargan en contenedores de transporte. Las etiquetas se aplicarán las correspondientes a las cajas de cartón, pallets y contenedores de diversos pedidos [17-18]. En este ciclo automático, la cámara digital puede ser estacionada adecuadamente para tomar fotos de las frutas. Luego, son procesadas las imágenes digitales y analizadas para la determinación de la calidad de las frutas.

Específicamente en este estudio, las imágenes son analizadas en dos etapas: una primera transformación, el procesamiento y análisis de correlación. El pre-procesamiento preliminar consta de los siguientes pasos de cálculo numérico: (i) filtrar el fondo (de la cinta transportadora en movimiento), (ii) determinar el color espectral de la fruta, y (iii) determinar la textura de la piel de la fruta. El tamaño de las frutas se asume de manera uniforme y correcta, ordenadas por el dispositivo de clasificación mecánica y por lo tanto, no hay necesidad de analizar tal información. Por otra parte, este supone que el color de la cinta transportadora se conoce, y ello ayudará a acelerar el cálculo en la etapa de filtración. El análisis post-proceso consta de tres pasos: (i) fusificación [19-20] de los datos numéricos obtenidos en el procesamiento preliminar, (ii) procesamiento de las reglas difusas en el sistema basado en el conocimiento de expertos para determinar las normas adecuadas que se adapten, y (iii) defusificación de los resultados borrosos en el paso anterior para una sola conclusión sobre la calidad de los frutos.

Este artículo consta de las siguientes secciones básicas: (i) visión general del sistema, (ii) las formulaciones de los pasos de pre-procesamiento, (iii) el análisis difuso, (iv) los resultados numéricos, y (v) la dirección de la investigación futura. En primer lugar, la visión general del sistema se resume, con la descripción del sistema difuso de clasificación de la fruta y la visión adicional propuesta a la infraestructura existente. Luego, se presentan las fórmulas para calcular la información del color y de la textura, y se muestran los algoritmos de

programación. La fusificación, las reglas difusas de activación y de-fusificación se enumeran en la identificación de la calidad de las frutas. Además, se identifican los futuros temas de investigación como la continuación del trabajo en curso.

2. Visión General del Sistema

Las frutas son cosechadas en el campo y transportadas a una planta donde son envasadas o procesadas. Allí, es típico que éstas sean cargadas a una cinta transportadora, donde se mueven en una larga cinta con varias estaciones de trabajo, donde los operarios seleccionan manualmente las frutas de calidad específica. Las frutas restantes de calidad uniforme son más tarde movidas a través de un calibrador mecánico, donde se ramifican a rutas diferentes por diferentes cintas transportadoras hacia propósitos específicos en consecuencia. La figura 1(a) muestra la carga de frutas al comienzo de la cinta transportadora donde operarios manualmente inspeccionan las frutas antes de moverlas a una cinta elevadora para el enrutamiento a diferentes estaciones. La figura 1(b) muestra el paso de la fruta hacia una estación de lavado.



(a)

(b)

Figura 1. Etapas de la línea de proceso de las frutas

La velocidad que una persona puede trabajar en la cinta transportadora es el factor limitante de cuán rápido se pueda mover la cinta. Es a menudo que éstas son más lentas que la velocidad más baja de la cinta transportadora, por lo que es una práctica común detenerla para que el personal pueda relevar, evitando que la fruta se acumule en una estación de trabajo determinado. La eficiencia de una cinta transportadora se ve afectada por cuánto ésta se detiene. Así, esta cinta es un sistema semi-automático con personal en el bucle que la limita en la eficiencia de trabajo. La mayoría de las veces, los sistemas actuales están equipados con el

sistema de calibrado mecánico para seleccionar el tamaño, dejando la tarea de clasificación por color al personal. La evaluación de la calidad final, mayormente realizado en un lote de fruta, y empaquetado en una caja, también se hace por el personal al final de la cinta transportadora.

Con el fin de aumentar la eficiencia de la operación de una cinta transportadora de fruta, las tareas repetitivas, como el color de selección y evaluación de la calidad, tradicionalmente realizadas por personas, pueden ser delegadas a la máquina automatizada. En varios lugares de la cinta transportadora, las cámaras digitales pueden ser colocadas para tomar imágenes de las frutas que van pasando y ser transmitidas a un ordenador para realizar la inspección visual. La ubicación de la cámara puede ser determinada, basándose en el uso del resultado del análisis difuso. Si el análisis difuso de las frutas se utiliza para determinar la calidad de los paquetes individuales para el etiquetado correcto y para el enrutamiento de éste al destino adecuado, la cámara debe ser colocada cerca del punto de embalaje; si el análisis se utiliza para determinar la calidad de las frutas individualmente, la cámara debe estar situada justo después del calibrado, donde la fruta puede ser alineada en un solo archivo.

El procesamiento de las imágenes digitales debe ser tan rápido como la velocidad de la cinta transportadora, para lograr la única razón de la sustitución de personal en el circuito semi-automatizado. Esta restricción es el requisito mínimo para el cómputo. Además, la precisión del análisis debe ser tan buena como la proporcionada por el personal. Dado que las normas de inspección son llevadas a cabo por la máquina (reglas difusas), se puede fácilmente deducir que el rendimiento es siempre coherente, una mejora en el rendimiento esporádico de personas quienes podrían verse afectados por factores externos.

3. Pre-procesamiento de imágenes colores

En esta sección, los dos datos numéricos básicos, color y textura, son extraídos de las imágenes digitales para que las reglas difusas (con criterios múltiples) puedan aplicarse para analizar la calidad de la fruta. La información de tamaño se puede obtener directamente del calibrado. Juntos, los tres datos (color, textura y tamaño) serán analizados por las reglas difusas que se describen en la siguiente sección. Estas reglas difusas

son proporcionadas por los expertos que entienden las frutas. Es una presunción fundamental de la ingeniería que si las reglas difusas, con dos o tres criterios, se pueden procesar de manera efectiva por un ordenador, entonces las normas pueden extenderse a incluir tantos criterios como sean necesarios para dar cabida a los nuevos conocimientos proporcionados por otros expertos o por cualquier otra técnica de descubrimiento de conocimiento. La única restricción sobre el número de criterios es, posiblemente, la potencia de cómputo, a fin de que todos los pasos de cálculo puedan ser realizados tan rápido como se mueva la cinta transportadora.

Los datos obtenidos de la cámara digital estarán en la forma de un conjunto de tres imágenes en dos dimensiones que corresponden a los colores rojo, verde y azul (espectros RGB, por sus siglas en inglés). La imagen estará llena de frutas, como se muestra en la figura 2(a) o con el fondo de la cinta transportadora, como se muestra en la figura 2(b). La figura 2(a) es un escenario típico en que las frutas se cargan en una cinta transportadora más rápido de lo que puede moverse, resultando en una situación de sobre-poblamiento que la cubre por completo. La figura 2(b), en cambio, es un caso típico en que las frutas se cargan en un ritmo más lento, donde parte de la superficie de la cinta transportadora se muestra.



Figura 2. Imágenes típicas de frutas tomadas en una cinta transportadora

Esta sección proporciona la fórmula detallada para las tres fases de pre-procesamiento: (i) filtrar el fondo, (ii) la obtención de información del color, y (iii) la obtención de información de la textura. Es importante filtrar el fondo, porque la información de estos dos aspectos debe ser normalizada acorde con el número de píxeles pertinentes, de modo que el análisis pueda realizarse sobre una base constante.

Dejemos que $I = \{ i_{\text{red}}(n,m), i_{\text{green}}(n,m), i_{\text{blue}}(n,m) \mid 0 \leq n \leq N - 1, 0 \leq m \leq M - 1 \}$ sea una imagen a color de

dimensión $N \times M$. Ésta consiste en tres plantillas espectrales de los colores rojo, verde y azul. Cada plantilla es un arreglo bi-dimensional, de tamaño $N \times M$, y cada elemento del arreglo representa un pixel de valor entre 0 and $2^K - 1$, donde K es el número de bits localizados en un color. Una típica imagen a color simple de 24-bit alojara 8 bits por cada color; así, el valor de cada pixel (en una plantilla individual a color) estará entre 0 y 255. Esta notación será usada en todo el paper, especialmente en las siguientes tres sub-secciones.

3.1. *Filtrando el fondo.* Se asume que el color del fondo es conocido y es de textura consistente. Se tiene en cuenta, además, que la suposición de una textura consistente en el fondo sólo es realista con frutas frescas en una cinta transportadora. Con frutas como la cereza que se habían conservado químicamente, el líquido residual puede hacer que el cinturón húmedo sea más reflexivo que el efecto del flash de la cámara se note.

Por cada plantilla a color de una imagen, el filtro de fondo se aplicaría de la siguiente manera:

$$i_{\text{color}}(n,m) = \begin{cases} 0 & \lambda_{\text{color}} \leq i_{\text{color}}(n,m) \leq \mu_{\text{color}}, \\ i_{\text{color}}(n,m) & \text{else,} \end{cases} \quad (1)$$

donde λ_{color} es el límite más bajo y μ_{color} el límite más alto del fondo de color. Si el valor del pixel cae dentro de este rango, el pixel tiende a cero con el propósito de distinguir los pixeles relevantes y no relevantes para la normalización a usarse en los dos siguientes pasos. De lo contrario, el pixel conservará su valor original (no cero). Observe que el uso del valor cero en la ecuación (1) dejaría el fondo negro. Si se prefiere el fondo blanco, el valor de 255 se utilizará en lugar de cero en el primer caso de la ecuación (1).

Suponiendo que el color del fondo es conocido, ésta será traducida en un conjunto de constantes ya revisadas, representando el fondo B :

$$B = \{\lambda_{\text{red}}, \mu_{\text{red}}, \lambda_{\text{green}}, \mu_{\text{green}}, \lambda_{\text{blue}}, \mu_{\text{blue}}\}. \quad (2)$$

3.2. *Obteniendo información del color.* Por cada color, un conjunto de tres constantes se calculan y se normalizan de modo tal que una indicación numérica del color puede ser obtenida para toda la imagen, si esta imagen contiene fruta o frutas. Por cada plantilla de color, la intensidad de éste es calculada como la suma de todos los pixeles (después de filtrar el fondo):

$$\gamma_{\text{color}} = \frac{1}{\pi_{\text{color}}} \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} i_{\text{color}}(n,m). \quad (3)$$

La constante de normalización π_{color} es calculada basado en el número de pixeles relevantes como:

$$\pi_{\text{color}} = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} r_{\text{color}}(n,m), \quad (4)$$

y $r_{\text{color}}(n,m)$ es la matriz de relevancia donde el valor es cero para un pixel no relevante y uno para un pixel relevante:

$$r_{\text{color}}(n,m) = \begin{cases} 0 & \text{if } i_{\text{color}}(n,m) = 0, \\ 1 & \text{else.} \end{cases} \quad (5)$$

3.3. *Obteniendo información de la textura.* La textura de la fruta es una indicación de cuán liso o irregular está la piel de las frutas. Si bien hay muchas razones por la piel irregular de una fruta, la suave textura de la piel de la fruta representa un indicio de que ésta es saludable. Por esta razón, la información de la textura de la piel de la fruta se calcula así:

$$\tau = \frac{1}{3} (\tau_{\text{red}} + \tau_{\text{green}} + \tau_{\text{blue}}), \quad (6)$$

donde la textura individual de cada plantilla de color se calcula como:

$$\tau_{\text{color}} = \frac{1}{\pi_{\text{color}}} \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} d_{\text{color}}(n,m), \quad (7)$$

donde la constante π_{color} es definida en (4) y $d_{\text{color}}(n,m)$ es la matriz de indicadores

$$d_{\text{color}}(n,m) = \{ \mathbf{1} ("0" \& "if" \tau_{\text{color}} "(n,m) (" \theta" , @ "1" \& "else.") \} \quad (8)$$

Esta matriz se calcula basándose en el filtro de baja transición y alta transición separados por una constante θ . La actual matriz transicional espacial $t_{\text{color}}(n,m)$ es calculada basada en el promedio de la transición entre un pixel y sus circundantes:

$$t_{\text{color}}(n,m) = \frac{1}{P} \sum_{[i]} |i_{\text{color}}(n,m) - s_{\text{color}}(n,m)|, \quad (9)$$

donde P es el número de pixeles circundantes cerca de la posición (n,m) : este número es 8 si el pixel está dentro de la imagen ($0 < n < N-1$, y $0 < m < M-1$), 5

si el pixel está en el borde, pero no en la esquina ($n = 0$ o $n = N - 1$ o $m = 0$ o $m = M - 1$, y $n \neq 0$ o $m \neq 0$ o $n \neq N - 1$ o $m \neq M - 1$), y 3 si el pixel está en la esquina de una imagen ($n = 0$ y $m = 0$, o $n = 0$ y $m = M - 1$, o $n = N - 1$ y $m = 0$, o $n = N - 1$ y $m = M - 1$). La notación $s_{\text{color}}(n,m)$ representa cualquier pixel adyacente a la posición (n,m) en la plantilla de color.

4. Análisis difuso de las imágenes a color

Una regla difusa tiene la forma de *si-entonces*, donde la frase de “*si*” se suministra con un conjunto de condiciones de reglas difusas, y la frase “*entonces*” es la indicación de la acción consecuente o conclusión. Por tanto, una regla difusa tiene la siguiente forma:

SI (condición) ENTONCES (acción), (10)

Donde la condición puede ser una simple operación lógica o una compleja combinación de varias simples operaciones lógicas. Cada operación lógica simple está asociada con un cálculo aritmético difuso, asociada a la membresía difusa de la regla total. Esta información es especialmente útil cuando hay muchas reglas aplicables a la misma situación. La resolución de estas normas es la clave de la flexibilidad en el uso de la lógica difusa para sistemas expertos que pueden aceptar unas normativas distintas de diferentes expertos.

Un ejemplo de una regla popular para inspeccionar frutas es que, si ésta es *grande*, con color *rojo profundo*, y con muy pocas *pecas* en la piel, las frutas poseen alta calidad. Este ejemplo se usa para ilustrar o desarrollar una regla difusa basada en el sistema experto para la inspección de la fruta.

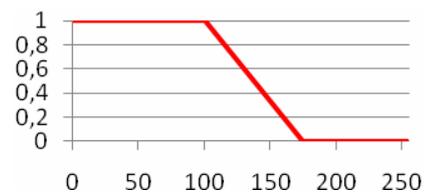
El concepto básico de un conjunto difuso es que éste es un conjunto regular con una membresía difusa asociada. Dejemos S como la notación del conjunto difuso, y $\mu_S(\cdot)$ la membresía difusa en el conjunto difuso S . Esta membresía se asignaría un elemento a un valor real, indicando el grado de pertenencia a ese conjunto. Por convención, el dominio de una función de membresía estaría entre 0 y 1:

$$0 \leq \mu_S(\cdot) \leq 1, \quad (11)$$

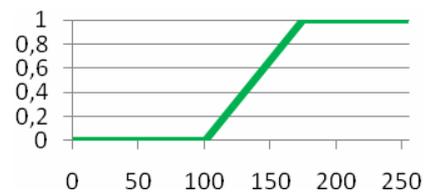
con un extremo (cero) muestra que un elemento, definitivamente, no está en el conjunto; y el otro extremo (uno), muestra que un elemento, sin duda,

pertenece al conjunto. Cualquier valor entre estos dos extremos muestra algún grado de parcial pertenencia al conjunto.

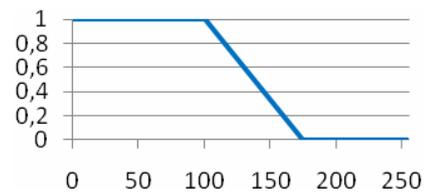
Desde que el color de la fruta no es exactamente describable en términos numéricos precisos, sin pérdida de flexibilidad, es natural usar conjuntos difusos para tal descripción. Un color rojo profundo puede ser descrito en un espectro entre 0 y 255 en un color de 24-bit, como se muestra en la figura 3. El eje horizontal representa el rango de los datos entre 0 y 255. El eje vertical representa el valor de membresía a la cual pertenece el espectro de color:



(a) plantilla del espectro color rojo



(b) plantilla del espectro color verde



(c) plantilla del espectro color azul

Figura 3. Conjunto típico y membresía del color rojo profundo

donde las formulas específicas para las tres funciones de membresía $\mu_{\text{deepRed,R}}(\cdot)$, $\mu_{\text{deepRed,G}}(\cdot)$, y $\mu_{\text{deepRed,B}}(\cdot)$ son:

$$\begin{aligned} \mu_{\text{deepRed,R}}(x) &= \begin{cases} 1, & \text{if } x < \alpha_R, \\ (\beta_R - x)/(\beta_R - \alpha_R), & \text{if } \alpha_R \leq x \leq \beta_R, \\ 0, & \text{if } \beta_R < x, \end{cases} \\ \mu_{\text{deepRed,G}}(x) &= \begin{cases} 0, & \text{if } x < \alpha_G, \\ (x - \alpha_G)/(\beta_G - \alpha_G), & \text{if } \alpha_G \leq x \leq \beta_G, \\ 1, & \text{if } \beta_G < x, \end{cases} \\ \mu_{\text{deepRed,B}}(x) &= \begin{cases} 1, & \text{if } x < \alpha_B, \\ (\beta_B - x)/(\beta_B - \alpha_B), & \text{if } \alpha_B \leq x \leq \beta_B, \\ 0, & \text{if } \beta_B < x, \end{cases} \end{aligned} \quad (12)$$

y las constantes α_R , β_R , α_G , β_G , α_B , y β_B indican la descripción difusa del color rojo profundo. Obsérvese que, para la simplicidad, estas constantes se colocan en los valores, $\alpha_R = \alpha_G = \alpha_B$, $\beta_R = \beta_G = \beta_B$, en general, para describir el color rojo profundo. Los valores de estas constantes pueden ser afinados (como se sugiere en la sección posterior sobre la futura orientación de este estudio) para una descripción más precisa y un mejor desempeño de la evaluación de las reglas difusas.

La descripción difusa de “pequeñas pecas” puede ser examinada por medio del dato de textura obtenido en la sub-sección 3.3. Aquí, el dato es normalizado para estar entre cero y uno. Así, una descripción difusa puede ser vista en la figura 4.

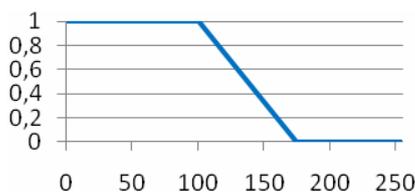


Figura 4. Conjunto típico y membresía para “pequeñas pecas”

donde la fórmula matemática para la función de membresía $\mu_{\text{littleFreckles}}(t)$ se define similarmente a la ecuación (12).

Otras reglas populares para la inspección de la fruta son: (i) si la fruta es *grande*, con el color *verde claro*, y con muy pocas *pecas* en la piel, la fruta posee calidad *media*, o (ii) si la fruta es *pequeña*, con el color *verde*

claro, y con muchas *pecas* en la piel, la fruta posee calidad *mala*, etc.

5. Resultados Numéricos

Se desarrolló una aplicación donde inicia cargando una imagen en cualquier formato; después, la transforma en un archivo “bitmap” (extensión BMP) de 24 bits y cada pixel que pertenezca a ésta, se analiza en las matrices para los colores rojo, verde y azul (RGB por sus siglas en inglés, donde los valores oscilan entre 0 y 255), y en función de su textura. Las imágenes de parámetro corresponden a dos casos: a frutas normales y a degradadas. En el primero, sus valores fueron los siguientes:

#	color1	color2	color3	textura
1	120	34	49	818075
2	162	78	77	1401780
3	108	32	39	632521
4	47	17	11	297093
5	54	20	13	338663
6	142	123	103	1576098
7	148	91	104	836507
8	140	28	41	885825
9	153	101	114	1217484
10	144	91	52	1084630

Tabla 1. Colores y texturas para diez imágenes normales a color de frutas.

Las imágenes N°1 y la N° 8, corresponden a frutas de buena calidad, donde se destaca un alto valor de la capa roja (sobre 100), pero bajo para la verde (20-40), con una textura promedio de 850.000; en cambio, la N° 6 pertenece a una dañada, donde supera notoriamente en la capa verde con un valor sobre 100, y en la textura, por sobre 1.000.000.

Luego, entran a una función de membresía (*fm*) para cada capa; sus valores de pertenencia fueron:

#	fm1	fm2	fm3
1	4902	230	10512
2	1441	746	8817
3	4755	159	10457

4	8698	22	11465
5	8116	32	11466
6	6041	1475	6708
7	1149	1432	3910
8	4435	422	11081
9	1323	2590	4765
10	2264	850	9523

Tabla 2. Funciones de membresía a las capas RGB para diez imágenes normales a color de frutas.

Se confirma la pertenencia a las capas: en el caso de las frutas de calidad, su valor está entre 4500 y 5500 en la capa roja, y en la capa verde, a 450; en cambio, la fruta dañada, el valor de esta última capa se duplica a las anteriores: más de 1400.

En el segundo, se trabajaron con las mismas imágenes, pero degradadas a un color amarillo verdoso, tal como se muestra en la siguiente imagen:



Figura 5. Imagen de frutas tomadas en una cinta transportadora, degradada en color amarillo verdoso.

Los resultados fueron los siguientes:

#	color1	color2	color3	textura
1	91	41	70	813106
2	100	95	93	1271796
3	58	41	41	555793
4	35	22	12	270974
5	39	26	13	306882
6	57	155	117	1412163
7	74	109	135	777677
8	116	34	59	886447
9	72	122	146	1121984
10	93	107	46	933205

Tabla 3. Colores y texturas para diez imágenes degradadas de frutas.

Los datos de la Tabla N° 3 nos permiten determinar una diferencia entre lo obtenido de la Tabla 1 y la actual,

estableciendo una tendencia de los pixeles degradados hacia una cierta membresía de las capas RGB, generando los siguientes totales:

#	diferencia1	diferencia2	diferencia3
1	29	-7	-21
2	62	-17	-16
3	50	-9	-2
4	12	-5	-1
5	15	-6	0
6	85	-32	-14
7	74	-18	-31
8	24	-6	-18
9	81	-21	-32
10	51	-16	6

Tabla 4. Diferencial entre los pixeles de las imágenes normales y degradadas.

Si se observa, la diferencial de la segunda capa tuvo un valor negativo en todas las imágenes; es decir, hay más pixeles pertenecientes a la capa verde cuando la captura es degradada; por tanto, es verdadero que una fruta amarillo-verdosa, aunque suene obvio, tiende hacia el color verde.

6. Investigaciones Futuras

Un sistema de expertos basado en reglas difusas sólo puede realizarse tan bien como los expertos que las proporcionan. Por lo tanto, es imperativo que estas reglas establecidas por los expertos sea robusta, pero precisa. Por esta razón en particular, éstas se utilizan en este estudio para proporcionar la flexibilidad en la incorporación de reglas de diferentes expertos. Esta flexibilidad permite la adición de nuevas reglas en cualquier momento en que un nuevo descubrimiento se haga o se trabaje con un nuevo experto. Mientras los nuevos expertos se pueden encontrar a través de la interacción humana, las nuevas reglas pueden ser descubiertas mediante el examen de los datos acumulados a través de la operación (de inspección).

Una de las ventajas del conocimiento de los expertos que puede ser fácilmente convertido en una desventaja es que la experiencia puede ser tan eficaz (en la mayoría de las veces) que refuerza la tendencia humana frente a ver o aceptar los nuevos descubrimientos. Por lo tanto, el examen de los datos acumulados durante la operación, puede proporcionar una evaluación objetiva que es útil para aumentar la confianza en las reglas

existentes, mejorando la precisión y la eficacia de las reglas existentes, o el descubrimiento de nuevas reglas.

La tarea de descubrir nuevas reglas puede lograrse con el uso de técnicas numéricas que surgen de la minería de datos [21-22]. Específicamente, la técnica de la agrupación [23-24] es un método de determinación de las zonas en un espacio multidimensional en que los datos se concentran. Estas áreas de concentración de datos pueden considerarse como conjuntos de puntos de datos con características similares, donde cada característica representa una dimensión del espacio multidimensional. El centro de cada área de éstos se representa con una serie de coordenadas numéricas en el espacio multidimensional. Las coordenadas numéricas del centro y el radio del área de datos de la concentración puede expresarse en términos de reglas difusas que describen el área. Las nuevas reglas pueden ser completamente diferentes de las reglas vigentes, por lo que el descubrimiento de éstas, o que se superponen con las reglas vigentes, permiten la modificación de las normas existentes para mejorar la precisión.

Hay varias técnicas de agrupación existentes. Se diferencian en el objetivo de colocar el centro de un área, la formulación de la distancia (entre dos puntos en un espacio multidimensional), y las medidas de ejecución. Un algoritmo simple pero eficaz y sorprendente para la agrupación técnica es el algoritmo de agrupación k -media [25], donde el espacio de datos está dividido en k regiones. Los k centros de las k regiones son generados al azar en los pasos iniciales. Cada punto se asigna a una región basada en su proximidad más cercana al centro de la región. Después de la asignación de la región a todos los puntos de datos, los centros se vuelven a calcular y se repite el proceso hasta que no haya cambios en la asignación (durante todo el ciclo anterior). Este algoritmo es fácil de implementar y los resultados fáciles de visualizar. El radio del clúster puede ser calculado desde el centro del grupo a un punto que efectivamente cubre todos los puntos de datos en el clúster.

La tarea de mejorar la precisión y la eficacia de las reglas existentes se puede lograr fácilmente con la técnica de la agrupación como la técnica de la k -media. Sea k el número de reglas existentes, a continuación, cada regla puede ser vista como una descripción de un grupo en un espacio multidimensional. La regla se puede convertir en el centro y el radio de la agrupación. Ahora, las k reglas se pueden ver como k grupos. Los

datos serán utilizados para actualizar los grupos k hasta que no haya más cambios (para mejor) de los miembros de la agrupación. Esta técnica es particularmente adecuada para mejorar las normas existentes ya definidos por los expertos. El cambio de los centros de las regiones representa la modificación de las reglas para una mayor precisión sobre la base de los datos recogidos durante las operaciones.

Otra posible opción para la investigación futura es el uso de un tipo diferente de imágenes: imágenes hiperespectrales. Este tipo de datos de imágenes pueden proporcionar información adicional pertinente para analizar la frescura de la fruta: la absorción de agua en la piel de la fruta. La indicación de agua en la piel de las frutas es un indicador de que el fruto esté fresco. La cantidad de agua presente, cuando se combina con la percepción visual de una característica de las arrugas de la piel del fruto puede indicar que la fruta ya no es fresca para el consumo.

7. Conclusiones

Se ha demostrado que la capacidad de visión artificial se pueden agregar fácilmente a una infraestructura ya existente en una planta procesadora de frutas para mejorar la eficiencia en el control de calidad. La eficiencia es la clave para mantener la ventaja de costos que Chile está gozando actualmente en el mercado internacional. La extensión de este sistema automático de visión artificial para control de calidad debería ser un procedimiento sistemático para incluir capacidades de futuro tales como la incorporación de las opiniones de muchos expertos, el automático descubrimiento de las nuevas reglas, y el refuerzo de las reglas existentes.

El impacto económico que generaría el sistema consistiría en tres aspectos: primero, se reducirían costos por devolución, ya que, al reducirse los errores de selección de mercado, tales costos decaerían en similar proporción (que son los que más afectan al mercado chileno, debido a que las regulaciones son bastante rígidas internacionalmente); por consiguiente, habría mayor certeza en que los productos estén en los mercados correctos y menos pérdidas de inversiones en tal aspecto; por tanto, mayor rentabilidad, logrando posicionar la fruta en un mercado destino a un precio de la industria; segundo, la aplicación desarrollada para implementarse, que fundamenta su toma de decisión analizando la tendencia de los píxeles a los bloques

W o r k S h o p
EIG2009

WORKSHOP INTERNACIONAL

EIG2009

Departamento de Ingeniería de Sistemas

Universidad de La Frontera – Chile

Diciembre 3 y 4, 2009

difusos, reemplazaría a la selección e inspección humana en el bucle de control del proceso productivo, evitando problemas como tareas repetitivas, bajas de rendimiento e ineficiencia; y finalmente, éste se presentaría como una nueva solución ante las actuales soluciones de pre-calibrador, actualmente guiadas por el concepto de Six Sigma, que tiene el objetivo de reducir los errores. Si ésta llegara a ser exitosa durante el transcurso del proyecto y generara mejor rendimiento que sus competidoras, se tendría un nuevo pre-calibrador para lanzar al mercado, distinto de los existentes, donde las potencias de la industria son Bélgica, Italia y España. Por tanto, la empresa generaría un nuevo “valor agregado” dentro del mercado, a un costo menor.

Agradecimientos

Este estudio fue patrocinado en parte por la empresa AgVision en Curicó y los datos fueron generosamente proporcionados por compañías locales de frutas cerca de Curicó.

Referencias

- [1] Ramón Lacayo, and Cristian Morales. "An analysis of the performance of Chilean agricultural exports (1994-2004)." *Intersciencia*, Vol. 32, No. 5 (May 2007), pp 296-302.
- [2] Luis E. Cárcamo-Huechante. *Tramas del mercado: imaginación económica, cultura pública y literatura en el Chile de fines del siglo veinte*. Santiago, Chile: Editorial Cuarto Propio (2007).
- [3] Integrated Assessment and Planning (IAP) Commission. *Chile: Integrated assessment of the ministry of agriculture's environmental agenda*. United Nations Environment Programme Joint Final Report with the Chile Ministry of Agriculture (2004).
- [4] Eul-Soo Pang. *The international political economy of transformation in Argentina, Brazil, and Chile since 1960*. New York, NY: Palgrave MacMillan (2002).
- [5] Chile Central Bank Statistical Economics Database (http://si2.bcentral.cl/Basededatoseconomicos/951_portada.asp?idioma=1)
- [6] Frederick F. Reichheld, and W. Earl Sasser, Jr. "Zero Defections: Quality Comes to Services," *Harvard Business Review* (September-October, 1990), pp 105-111.
- [7] D. Gefen. "E-commerce: the role of familiarity and trust." *Omega: The International Journal of Management Science*, Vol. 28 (2000), pp 725-737.
- [8] Emporiki Bank: Country Trading Profiles for Chile - Labour Market (<http://emporikitrade.com/uk/countries-trading-profiles/chile/labour-market>)
- [9] Alfred Angerer. *The impact of automatic store replenishment on retail*. Frankfurt, Germany: Springer Science (2006).
- [10] T. Bergmann. *Mechanisation and agricultural development*. Göttingen, FRG: Edition Herodot (1984).
- [11] M. Z. Abdullah, A. S. Fathinul-Syahir, and B. M. N. Mohd-Azemi. "Automated inspection system for colour and shape grading of starfruit using machine vision sensor." *Transactions of the Institute of Measurement & Control*, Vol. 27, No. 2 (2005), pp 65-87.
- [12] J. Blasco, N. Aleixos, and E. Moltó. "Machine vision system for automatic quality grading of fruit." *Biosystems Engineering*, Vol. 85, No. 4 (2003), pp 415-423.
- [13] J. R. Brodie, A. C. Hansen, and J. F. Reid. "Size assessment of stacked logs via the Hough Transform." *Transaction of the ASAE*, Vol. 37, No. 1 (1994). pp 303-310.
- [14] J. Mukherjee, P. P. Das, and B. N. Chatterji. "An algorithm for the extraction of the wire frame structure of a three-dimensional object." *ACM Journal of Pattern Recognition*, Vol. 23, No. 9 (1990). pp 999-1010.
- [15] M. J. Knowles, and M. Spann. "Motion compensated background filtering for real time tracking in moving background sequences." *IEEE International Conference on Systems, Man and Cybernetics* (October 2005), pp 1059-1065.
- [16] V. Leemans, H. Magein, and M. F. Destain. "On-line fruit grading according to their external quality using machine vision." *Biosystems Engineering*, Vol. 83, No. 4 (2002), pp 397-404.
- [17] Marianne R. Klimchuk. *Packaging design : successful product branding from concept to shelf*. Hoboken, NY: J. Wiley & Sons (2006).
- [18] Herbert M. Meyers, and Richard Gerstman. *The visionary package : using packaging to build effective brands*. New York, NY: Palgrave Macmillan (2005).
- [19] Guanrong Chen, and Trung Pham. *Introduction to fuzzy sets, fuzzy logic, and fuzzy control system*. Boca Raton, FL: CRC Press (2001).
- [20] Guanrong Chen, and Trung Pham. *Introduction to fuzzy Systems*. Boca Raton, FL: Chapman & Hall (2005).
- [21] Chandrika Kamath. *Scientific data mining: a practical perspective*. Philadelphia, PA: Society for Industrial and Applied Mathematics (2009).
- [22] Igor Kononenko. *Machine learning and data mining: introduction to principles and algorithms*. Chichester, UK: Horwood Publishing (2007).
- [23] Boris G. Mirkin. *Clustering for data mining: a data recovery approach*. Boca Raton, FL: Chapman & Hall/CRC (2005).
- [24] Weili Wu, Hui Xiong, and Shashi Shekhar (eds.). *Clustering and information retrieval*. Norwell, MA: Kluwer Academic Publishers (2004).
- [25] Z. Huang. "Extensions to the K-means Algorithm for Clustering Large Datasets with Categorical Values." *Data Mining and Knowledge Discovery Vol. 2* (1998), pp. 283-304.