

MÉTODO PARA LA DETECCIÓN DE DEFECTOS EN MANZANAS BASADO EN LÓGICA DIFUSA

Erwin LÓPEZ-MARTÍNEZ

Departamento de Ciencias computacionales, Centro Nacional de Investigación y Desarrollo Tecnológico.
Cuernavaca, Morelos, C.P. 62490, México.
erwin05c@cenidet.edu.mx

y

José RUIZ-ASCENCIO

Departamento de Ciencias computacionales, Centro Nacional de Investigación y Desarrollo Tecnológico.
Cuernavaca, Morelos, C.P. 62490, México.
joser@cenidet.edu.mx

y

Andrea MAGADAN-SALAZAR

Departamento de Ciencias computacionales, Centro Nacional de Investigación y Desarrollo Tecnológico.
Cuernavaca, Morelos, C.P. 62490, México.
magadan@cenidet.edu.mx

RESUMEN

Este artículo propone un método para detectar defectos en manzanas “Golden Delicious” y “Fuji” usando imágenes a color RGB de 24 bits basado en la utilización de funciones de color creada mediante sistemas difusos. Dichas funciones de color clasifican los píxeles correspondientes al área de una manzana en sano y defectuoso en base a los valores de intensidad de sus bandas rojo, verde y azul del modelo RGB. Los resultados demuestran que trabajar solamente con la información de color no es suficiente cuando se trabaja con condiciones de iluminación no controlada.

Palabras claves: detección de defecto, Golden Delicious, Fuji, sistema difuso, lógica difusa.

1. INTRODUCCIÓN

En la actualidad los sistemas de inspección visual automática aplicados a la calidad en frutas han tenido grandes avances debido al perfeccionamiento de las técnicas del procesamiento digital de imágenes. Dichos sistemas son aplicados con éxito en un amplio rango de procesos, siendo uno de ellos la clasificación de manzanas en base a su tamaño, color y presencia de tallo. Sin embargo, la clasificación de manzanas en base a los defectos es todavía una tarea desafiante, ya que en la actualidad no existe un método que pueda clasificar defectos de una manera 100% correcta.

Dicha clasificación ha sido estudiada por algunos investigadores usando diversas técnicas. Leemans, Magein, y Destain presentaron dos métodos [4, 5] para detectar defectos en manzanas “Golden Delicious” y “Fuji” basados en la información del color. El método para detectar defectos en manzanas “Golden Delicious” constó de un modelo gaussiano del color para segmentar defectos y dos pasos de refinamiento de la segmentación. Por otra parte, el método para la detección de defectos en manzanas “Fuji” usó el teorema de bayes para detectar defectos y la distribución de la frecuencia de color de la piel sana y defectuosa para estimar la distribución de probabilidad de cada clase. La detección de defectos para manzanas “Golden Delicious” solamente fue efectiva para defectos bien contrastados mientras que para manzanas “Fuji” se obtuvo una tasa de reconocimiento total de 73%. Los errores de estos métodos provienen básicamente de una mala segmentación de defectos ligeros (como el rojizo y las magulladuras resientes) y de la confusión del tallo y cáliz. Unay y Gosselin [3] presentaron un método usando imágenes espectrales para detectar defectos en manzanas “Fuji”. Dicho método esta basado en una red neuronal artificial tipo *back-propagated* la cual clasificó los píxeles en sanos y defectuosos para posteriormente extraer de las áreas defectuosas características estadísticas e introducirlas al clasificador *support vector machines* el cual clasificó las manzanas en sanas y defectuosas. La segmentación de los defectos mediante la red neuronal fue exitosa presentando solamente una baja segmentación en las magulladuras, mientras que el clasificador obtuvo una tasa de reconocimiento total del 90%.

Kleynen, Leemans y Destain [6] presentaron un método para la detección de defectos en manzanas “Fuji” usando imágenes multi-espectrales. Dicho método constó de un procedimiento de clasificación de píxeles basado en el teorema de *bayes* y un modelo no paramétrico de la piel sana y defectuosa. Este método alcanzó una tasa de reconocimiento para la piel sana de 94.3% y de 84.6% para la piel defectuosa. La mala segmentación de los defectos en este método se debió a la presencia de defectos leves tales como el *russet* y del daño de helada.

Qingzhong, Maohua y Weikang [7] desarrollaron un método para la detección de defectos en manzanas “Fuji”. Dicho método constó de una sustracción de imágenes entre una imagen de referencia de las manzanas y una imagen original. Posteriormente, mediante un proceso de umbralización, se extrajeron los defectos de la manzana. Los resultados muestran que los defectos y las áreas de tallo/cáliz fueron básicamente extraídos. Wen y Tao [8] desarrollaron un sistema de visión cercano al infrarrojo para la detección de defectos en manzanas “Fuji”. Dicho método usó para el reconocimiento de defectos un sistema basado en reglas en forma de árbol binario. Las áreas posiblemente defectuosas fueron extraídas mediante una transformada esférica adaptativa seguido de un proceso de umbralización global. Este método tuvo una tasa de reconocimiento total de 95.88% para las manzanas buenas y 93.97% para manzanas defectuosas.

Como se aprecia en el estado del arte presentado, todos los trabajos tienen problemas con golpes bajamente contrastados como son las magulladuras. Por esta razón, este artículo presenta un método (en su etapa experimental) para la detección de magulladuras, raspones y podredumbre en manzanas “Golden Delicious” y “Fuji” basado en lógica difusa.

El artículo está organizado de la siguiente manera, primeramente se presenta la localización de la manzana en la imagen, posteriormente la propuesta de solución y por último las pruebas y resultados experimentales así como las conclusiones.

2. LOCALIZACIÓN DE LA MANZANA EN LA IMAGEN

La localización de una manzana en una imagen (Figura 1) se realizó mediante un proceso de umbralización utilizando los valores de intensidad de las bandas rojo y azul de cada píxel de la imagen en RGB. Si el píxel tiene un valor de intensidad en su banda azul mayor que el de su banda roja, éste píxel pertenece al fondo de la imagen. En caso contrario, el píxel pertenece al área de la manzana como se muestra en el siguiente pseudocódigo.

Si $BandaAzul_Píxel(x,y) > BandaRoja_Píxel(x,y)$ entonces
 $ImagenTransformada(x,y)$ en sus tres bandas = 255

Sino

$$ImagenTransformada(x,y) = ImagenOriginal(x,y)$$

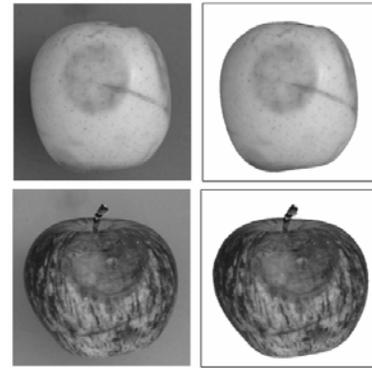


Figura 1. Imágenes resultantes del proceso de extracción del fondo

3. PROPUESTA DE SOLUCION

La segmentación de los defectos tanto para manzanas “Fuji” como para “Golden Delicious” se realizó mediante el uso de funciones de color creadas usando sistemas difusos construidos bajo la metodología de sintonización propuesto por Hiroyoshi Nomura [1]. Dicha propuesta surgió debido a que la lógica difusa maneja grados de pertenencia que indican el grado en que un objeto puede pertenecer a una determinada clase, lo cual puede ayudar a la clasificación de defectos ya que existe piel sana que por su color podría llegar a pertenecer a la piel defectuosa y viceversa. Además se realizaron pruebas (figura 2) en las cuales se observó que un sistema difuso podía separar píxeles pertenecientes a piel sana de los defectuosos. Por lo tanto, se consideró que el uso de la lógica difusa podría ayudar a solucionar dicho problema.

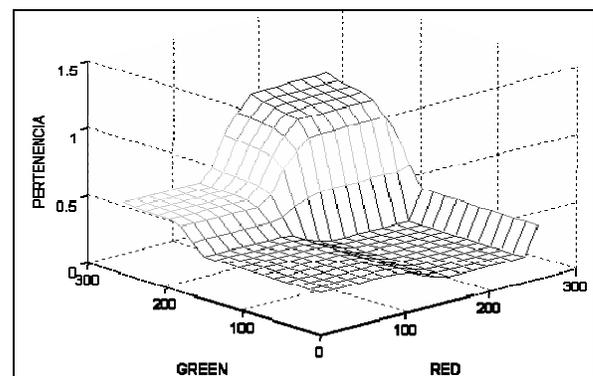


Figura 2. Gráfica resultante del estudio previo realizado para manzanas “Golden Delicious”. El grado de pertenencia 1 indica la piel sana y el 0 la piel defectuosa.

Las funciones de color creadas mediante lógica difusa clasifican los píxeles pertenecientes al área de la manzana en 2 clases (sano y defectuoso) y tienen como datos de entrada los valores de intensidad de las bandas rojo, verde y azul de un píxel a clasificar en RGB y como salida la clase a la que pertenece el píxel (figura 3). Dicha salida está dada en el intervalo [0,1] por lo que se discretizó cada

función de color mediante un umbral de manera experimental.

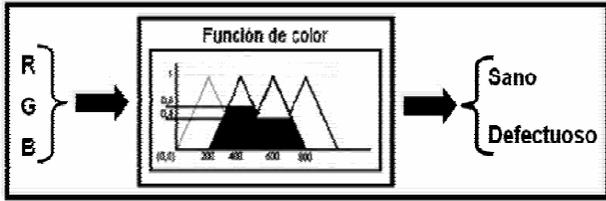


Figura 3. Diseño de la función de color.

El proceso de detección de defectos se realizó utilizando una o dos funciones de color. En el caso del uso de una función de color, esta se entrenó con los tonos válidos para la piel sana y defectuosa de toda el área de la manzana. Mientras que, con el fin de tratar de evitar confusiones existentes entre los defectos y la piel sana ubicada en los bordes de la manzana, en los cuales existe la presencia de sombras dada la forma esférica de la manzana que provocan dicha confusión se usaron dos funciones de color, una se entrenó con los tonos válidos para la piel sana y defectuosa del área del centro de la manzana y otra los tonos válidos para el área del borde.

Para poder crear las dos funciones de color (centro y borde) se dividió el área de la manzana en dos partes mediante un círculo (figura 4). El tamaño del radio usado para crear el círculo fue obtenido de forma experimental y es igual a tres cuartas partes el tamaño del radio original que tiene la manzana a analizar. Dicho tamaño es debido a que la manzana no tiene una forma totalmente esférica, por lo tanto, si se consideraba un radio mayor existía la posibilidad de que el círculo excediera el área de la manzana.

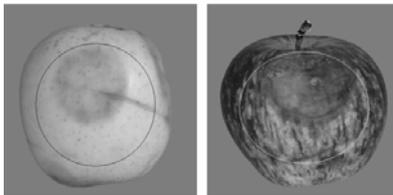


Figura 4. Manzanas divididas en dos partes mediante un círculo con un radio igual a tres cuartas partes del radio original de la manzana.

Metodología de Aprendizaje de Reglas de Inferencia Difusas

Los sistemas difusos usados para crear las funciones de color que detecten defectos en manzanas “Fuji” y “Golden Delicious” fueron creados bajo la metodología propuesta por Hiroyoshi Nomura [1] basada en un método de gradiente descendente. Dicha metodología fue elegida debido a que es capaz de sintonizar tanto conjuntos difusos (bases y centros) como la base de reglas del sistema difuso.

Esta metodología usa como información inicial un vector de datos, que consta de dos partes: un vector de entrada (x_1, x_2, \dots, x_m) y su respectiva salida y , los cuales se pueden describir mediante una regla difusa Ec. (1).

$$\text{if } x_i \text{ is } A_{1i} \wedge \dots \wedge x_m \text{ is } A_{1m} \text{ then } y \text{ is } w_i \quad (1)$$

Donde, x_1, \dots, x_n son las variables de entrada al sistema (escalados en el intervalo $[-1, 1]$), A_{11}, \dots, A_{1m} son los conjuntos difusos de la parte antecedente, ‘ y ’ es la salida del sistema, $i=1, 2, \dots, n$ y w_i es un escalar que representa el peso o aportación de la regla ‘ i ’ a la solución del sistema.

Las funciones de pertenencia usadas por esta metodología son en forma de triángulo isósceles y se definen mediante dos parámetros: base (anchura sobre el eje de las abscisas) b_{ij} y centros (eje central del triángulo) a_i (figura 5).

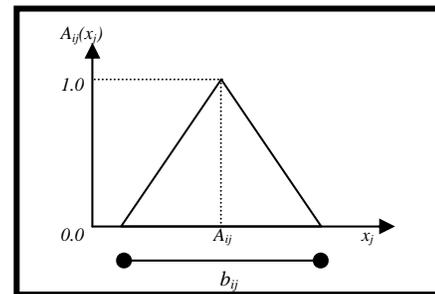


Figura 5. Función de pertenencia usada por [1]

Reconocimiento: El proceso de reconocimiento consiste:

- i. Fusificar un valor x_j de entrada Ec. (2).
- ii. Calcular el grado de disparo de cada una de las reglas mediante el producto de los grados de pertenencia $A_{ij}(x_j)$ de los antecedentes que componen a las reglas difusas Ec. (3).
- iii. Defusificar la salida mediante un promediado de los pesos de cada regla y de su grado de disparo Ec. (4).

$$A_{ij}(x_j) = 1 - \frac{2|x_j - a_{ij}|}{b_{ij}} \quad (2)$$

$$\mu_i = A_{i1}(x_1) \cdot A_{i2}(x_2) \cdot \dots \cdot A_{im}(x_m) \quad (3)$$

$$y = \frac{\sum_{i=1}^n \mu_i w_i}{\sum_{i=1}^n \mu_i} \quad (4)$$

Cabe mencionar que los grados de pertenencia que maneja esta metodología están dados en el intervalo $[-1, 1]$, lo cual fue modificado [2] para que estos estuvieran en el rango de $[0, 1]$ como los maneja la lógica difusa tradicional. Dicha modificación se utilizó en este trabajo y se realizó sobre la Ec. (2) dando como resultado la Ec. (5).

$$A_{ij}(x_j) = \begin{cases} 1 - \frac{2|x_j - \alpha_{ij}|}{b_{ij}} & \text{si } \alpha_{ij} - \frac{b_{ij}}{2} < x_j \leq \alpha_{ij} + \frac{b_{ij}}{2} \\ 0 & \text{de otra manera} \end{cases} \quad (5)$$

Entrenamiento: El proceso de entrenamiento consiste en la optimización de los parámetros del sistema difuso de manera iterativa a partir de los valores calculados por el sistema y y los deseados o esperado y' como resultado de una de entrada u al sistema.

Las condiciones iniciales que necesita el sistema difuso son: conjuntos difusos espaciados uniformemente, bases entre conjuntos adyacentes traslapadas entre si y pesos iniciales de las reglas difusas en 0.5.

El algoritmo de sintonización necesita un vector de dimensiones p definido como $Z=(z_1, z_2, \dots, z_p)$ que contiene los parámetros a sintonizar. Dicho vector en el método de descenso minimiza una función objetivo $E(Z)$ Ec. (6) hasta que esta sea menor que un valor de aceptación ε .

$$E = \frac{1}{2}(y - y_r)^2 \quad (6)$$

La optimización de los parámetros para la adaptación del sistema difuso de un estado actual t a un estado siguiente $t+1$ es dado mediante las Ec. (7, 8, 9), las cuales son obtenidas despejando parcialmente Ec. (6) con respecto a a_{ij} , b_{ij} y w_i y ajustan los centros, bases y pesos respectivamente en base al error calculado.

$$a_{ij}(t+1) = a_{ij}(t) - K_a \cdot \frac{\mu_i}{\sum_{i=1}^n \mu_i} (y - y') \cdot (w_i(t) - y) \cdot \text{sgn}(x_j - a_{ij}(t)) \cdot \frac{2}{b_{ij}(t) \cdot A_{ij}} \quad (7)$$

$$b_{ij}(t+1) = b_{ij}(t) - K_b \cdot \frac{\mu_i}{\sum_{i=1}^n \mu_i} (y - y') \cdot (w_i(t) - y) \cdot \frac{1 - A_{ij}(x_j)}{A_{ij}(x_j)} \cdot \frac{1}{b_{ij}(t)} \quad (8)$$

$$w_i(t+1) = w_i(t) - K_w \cdot \frac{\mu_j}{\sum_{j=1}^n \mu_j} (y - y') \quad (9)$$

Donde, K_a , K_b y K_w son constantes que representan la ganancia de aprendizaje o la tasa de modificación independiente para cada tipo de parámetro y $\text{sgn}()$ es la función signo.

El algoritmo usado para la sintonización de los parámetros del sistema consta de los siguientes pasos:

1. Contar con una base de entrenamiento.
2. Calcular la aportación de cada uno de los datos de entrenamiento (x_1, x_2, \dots, x_m) en cada w .
3. Calcular para cada w_i el promedio de las aportaciones, tal como una votación que hace más dirigido el proceso de sintonización.

4. Aplicar el incremento promedio a cada w_i .
5. Realizar los pasos 1 y 3 ahora para a_{ij} y b_{ij} .
6. Calcular el resultado de la función de costo E utilizando los nuevos valores de los parámetros.
7. Si $E > \varepsilon$ regresar al paso 1, en caso contrario se llega a la solución deseada.

4. PRUEBAS Y RESULTADOS EXPERIMENTALES

Las pruebas se realizaron sobre 122 imágenes de manzanas “Fuji” y 118 de manzanas “Golden Delicious” de origen mexicano. Las manzanas contienen defectos tales como: magulladuras, raspones y podredumbre en diferentes tamaños y formas (Figura 6).

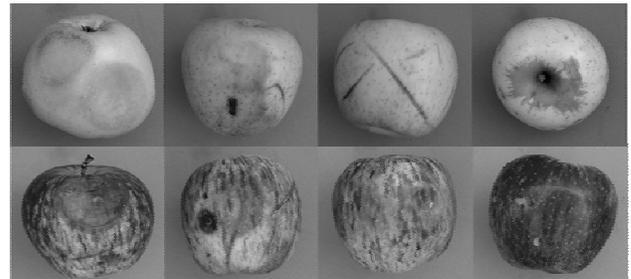


Figura 6. Imágenes adquiridas.

Las imágenes utilizadas fueron adquiridas usando como fuente de iluminación el sol y estando las manzanas a la sombra. La adquisición se realizó mediante una cámara digital a color marca MINOLTA modelo DIMAGE G400 usando una superficie plana color azul como fondo. Cada imagen esta compuesta de 500x500 píxeles a una resolución de 24 bits en el modelo de color RGB.

Los archivos de entrenamiento utilizados para entrenar los sistemas difusos se crearon con áreas sanas y defectuosas de las manzanas. Dichas áreas fueron segmentadas de forma manual.

Detección de Defectos Mediante una Función de Color

Para esta prueba la función de color utilizada para las manzanas “Golden Delicious” se entrenó con 78,615 píxeles, de los cuales 46,769 pertenecían a la clase sano y 31,846 a la clase defectuoso. El sistema convergió en 1500 épocas y la salida fue discretizada mediante un umbral de 0.7. En cuanto a la función de color usada para las manzanas “Fuji”, esta se entrenó con un total de 79,134 píxeles, de los cuales 45,123 pertenecían a la clase sano y 34,011 a la clase defectuoso. Dicho sistema convergió en 1450 épocas y se usó un umbral de 0.5 para su discretización.

Como se puede apreciar en la figura 7 la segmentación de defectos no es correcta para manzanas “Golden Delicious” debido a las sombras producidas (en los

bordes) por las condiciones de iluminación. Dichas sombras presentan un color oscuro similar al que presenta la piel defectuosa lo cual provoca que estas áreas sean segmentadas como defectos.

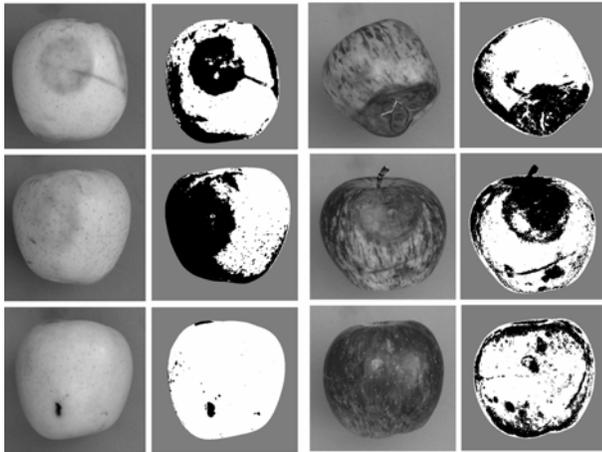


Figura 7. Segmentación de manzanas “Golden Delicious” y “Fuji” usando una función de color.

Por otra parte, la segmentación de defectos en manzanas “Fuji” (figura 7) tampoco funcionó correctamente debido a la variedad de color que presentan estas manzanas ya que lo que en algunas de ellas es piel sana en otras es piel defectuosa, además de las condiciones de iluminación.

Detección de Defectos Mediante Dos Función de Color (Centro y Borde)

La función de color del centro para manzanas “Golden Delicious” se entrenó con 12700 píxeles defectuosos y 19344 píxeles sanos, mientras que para la función de color del borde se usaron 15489 píxeles defectuosos y 20432 píxeles sanos. Ambos sistemas convergieron en un total de 500 épocas y se usó como umbral para la función de centro un valor de 0.6 y para la del borde de 0.5. Por otra parte, la función de color del centro usada para las manzanas “Fuji” se entrenó con 27870 píxeles defectuosos y 28993 píxeles sanos, mientras que la función de color del borde se entrenó con 8538 píxeles defectuosos y 47141 píxeles sanos. Ambas funciones convergieron en 1000 épocas y usaron umbrales de 0.7 y 0.6 para la función del centro y borde respectivamente.

Como se puede apreciar en la figura 8 la segmentación de defectos para manzanas “Golden Delicious” y “Fuji” usando dos funciones de color (centro y el borde) no mejoró los resultados obtenidos en la anterior prueba. Esto debido principalmente a las condiciones de iluminación utilizadas las cuales provocan confusión entre áreas sanas y defectuosas.

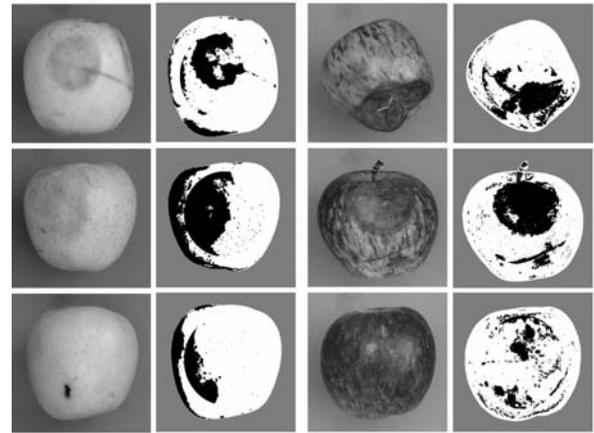


Figura 8. Segmentación de manzanas “Golden Delicious” y “Fuji” usando dos funciones de color.

5. CONCLUSIONES

En este artículo se presentó un método (en su etapa experimental) para detectar defectos en manzanas “Golden Delicious” y “Fuji” usando funciones de color creadas mediante sistemas difusos. Dichas funciones de color usaron como información de entrada los valores de intensidad de las bandas rojo, verde y azul de un píxel en RGB y como salida la clase a la que pertenece el píxel (sano, defectuoso). Las pruebas demuestran que la información del color por si sola no es suficiente para detectar defectos en manzanas, ya que existe un fuerte traslape entre las clases sano y defectuoso (figura 9) provocado tanto por los tonos similares entre estas como por las condiciones de iluminación utilizadas, por lo cual es necesario el uso de otros descriptor que indique entre otras cosas la cantidad de luz que existe sobre el píxel ya que éste es uno de los problemas existentes.

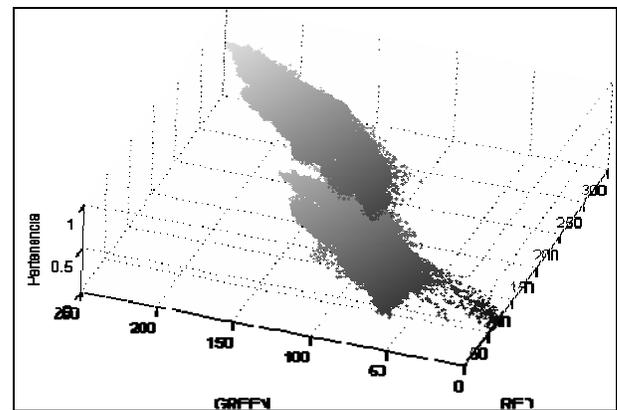


Figura 9. Clase sano y defectuoso para manzanas “Golden Delicious”

6. REFERENCIAS

[1] Hiroyoshi Nomura, Lsao Hayashi, Noboru Wakami; “A Learning Method of Fuzzy Inference Rules by Descent Method”, Proceedings IEEE International Conference on

Fuzzy System, San Diego, California, March 1992, pp. 203-210.

[2] Rodolfo Castillo, José Ruiz, Francisco Múgica; “*Construcción automática de aproximadores difusos mediante la sintonización de sus parámetros utilizando el método de gradiente descendiente*”, Memorias del Simposium Internacional en computación CIC’98, Instituto Politécnico Nacional IPN, México, D.F. pp. 418-425, 1998.

[3] Unay Devrim, Gosselin Bernard; “*Artificial neural network-based segmentation and apple grading by machine vision*”, Proc. of IEEE ICIP, Genova, Italy, 2005.

[4] V. Leemans, H. Magein, M.F. Destain; “*Defects segmentation on Golden Delicious apples by using colour machine vision*”, Computers and Electronics in Agriculture Vol. 20 Pag. 117–130, 1998.

[5] V. Leemans, H. Magein, M.F. Destain; “*Defect segmentation on ‘Fuji’ apples using colour vision and a Bayesian classification*” Computers and Electronics in Agriculture Vol. 23 Pag. 43–53, 1999.

[6] O. Kleynen, V. Leemans, M.-F. Destain; “*Development of a multi-spectral vision system for the detection of defects on apples*”, Journal of Food Engineering Vol. 69, Pag. 41–49, 2005.

[7] Qingzhong Li a, Maohua Wang b, Weikang Gua; “*Computer vision based system for apple surface defect detection*”, Computers and Electronics in Agriculture Vol. 36 Pag. 215 -22, 2002.

[8] Zhiqing Wen, Yang Tao; “*Building a rule-based machine-vision system for defect inspection on apple sorting and packing lines*”, Expert Systems with Applications Vol. 16, Pag. 307–313, 1999.