

Detección de Focos de Infección de *Ramularia Tulasnei* Usando Segmentación y una Red Neuronal

J. Jalomo, F. Ordoñez, H. Méndez
Instituto Tecnológico de Ciudad Guzmán
Zapotlán el Grande, Jalisco, México
jjalomo3@yahoo.com.mx

Resumen—Se describe el diseño de un sistema de reconocimiento de patrones basado en procesamiento de imagen y una Red Neuronal para la detección de focos de infección de *Ramularia Tulasnei* en hojas de fresón. Este trabajo envuelve el problema global, desde la adquisición de imagen, el procesamiento de imagen de las muestras tomadas, la generación y extracción de características, hasta la identificación y localización usando una Red Neuronal Backpropagation. Este trabajo es diseñado usando MATLAB y Simulink, y puede ser implementado para el análisis en tiempo real de infecciones en plantas en los sistemas de invernadero. Este trabajo es desarrollado en investigación con la colaboración del Centro Universitario de Ciencias Biológicas y Agropecuarias de la Universidad de Guadalajara y la participación del Dr. José Luis Martínez Ramírez.

Palabras clave: Redes Neuronales, Sistemas Biomédicos, Visión Artificial.

I. INTRODUCCIÓN

Ramularia Tulasnei es una enfermedad típica de los sistemas de cultivo bajo invernadero al Sur de Jalisco. Los primeros síntomas de esta aparecen como pequeñas manchas circulares color púrpura en la superficie de las hojas del fresón, estas manchas van desde los 3 hasta los 6 mm de diámetro. La *Ramularia Tulasnei* es causada por el hongo *Mycosphaerella fragariae*. Conforme las manchas se agrandan, el centro se vuelve de gris a blanco con fronteras rojizas, cuando las condiciones climáticas son favorables, las manchas se multiplican y se unen, produciendo que las hojas se sequen y mueran. Todas las partes aéreas de la planta eventualmente son atacadas, las manchas se tornan negras, llegando a niveles de epidemia [4].

Hay una gran cantidad de enfermedades con apariencia similar, como las mostradas en la figura 1 [6], siendo de gran importancia el tener personal calificado en los sistemas de cultivo bajo invernadero para la detección oportuna de enfermedades en plantas. Sin embargo, tener el personal adecuado es muy costoso, ya que cada consulta externa para la detección de enfermedades llega a costar hasta 5,000 dólares.

De la visita en sistemas de cultivo invernadero al Sur de Jalisco, se encontró que ninguno de ellos cuenta con un especialista en campo para el diagnóstico de enfermedades. Este trabajo ofrece una solución computacional para el

diagnóstico en campo, donde la primera fase es la detección de infecciones de *Ramularia Tulasnei* en las hojas de fresón.

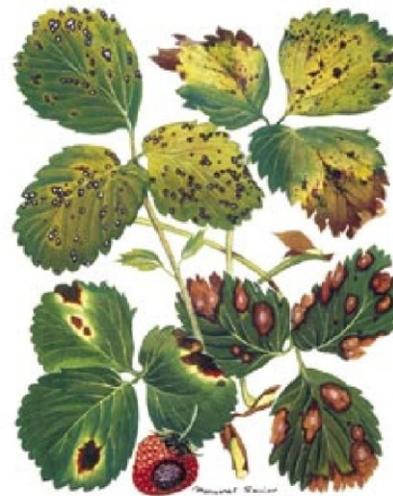


Fig. 1. Leaf spot (superior izquierda), leaf scorch (superior derecha), leaf blotch and gnomonia fruit rot (inferior izquierda), leaf blight (inferior derecha).

II. DESCRIPCIÓN DEL SISTEMA

Un sistema de reconocimiento de patrones debe considerar la cantidad de características, parámetros desconocidos, el entrenamiento del sistema, así como el sensor a usar, selección y extracción de características y los algoritmos necesarios para la clasificación de patrones [19]. Siendo así, el sistema diseñado para la detección de *Ramularia Tulasnei* está formado por las etapas mostradas en la figura 2.



Fig. 2. Sistema de Identificación de *Ramularia Tulasnei*.

El sensor para el sistema es una cámara común con una resolución de 3000x4000 píxeles. Sin embargo para el análisis en MATLAB y lograr un procesamiento más veloz, las muestras fueron reducidas a una resolución de 500x500 píxeles. El pre-procesamiento aplicado a las muestras consiste en la aplicación de un filtro de suavizado, un filtro de color en el modelo HSV, procesamiento morfológico y

procesamiento lógico para la eliminación de fondo, con el fin de identificar correctamente las características a extraer.

Después del filtrado de imagen, las características a extraer son claramente visibles, por lo que una red neuronal Backpropagation filtra la imagen para encontrar el centroide de las infecciones de *Ramularia Tulasnei*.

III. ANÁLISIS DE MUESTRAS Y PRE-PROCESAMIENTO

Analizando en muestras de la enfermedad como la mostrada en la figura 3c y 3d, *Ramularia Tulasnei* muestra una gran variedad en estructura y color, los tonos van desde café claro hasta rojo oscuro. Sin embargo las manchas incluyen tonos amarillos y verdes en los bordes, siendo de gran dificultad el análisis en el modelo RGB para la búsqueda de patrones.

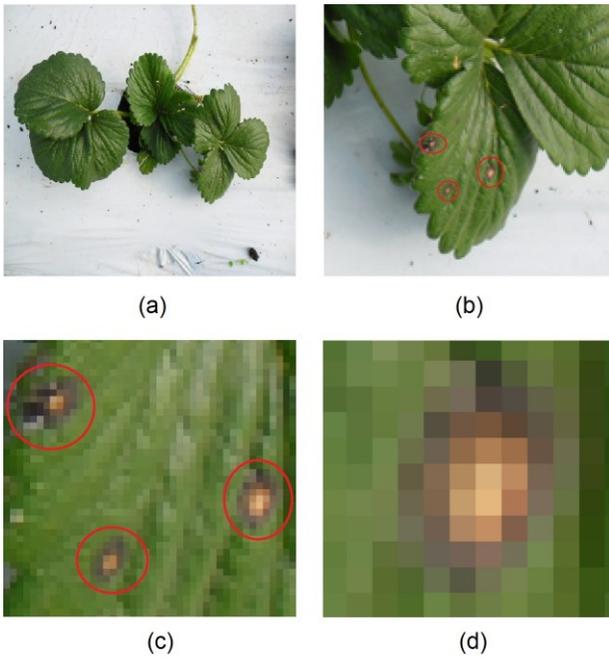


Fig. 3. Muestra tomada de *Ramularia Tulasnei*, (a) Original, (b) Enfocada en una hoja, (c) Enfocada en infecciones, (d) Enfocada en una sola infección.

A. Filtro de Color

El modelo RGB está representado por una combinación de colores primarios, donde cada pixel se encuentra en un rango entre 0 y 1 (figura 4a). El modelo HSV en cambio está representado por tres capas Hue, Saturation y Value [10].

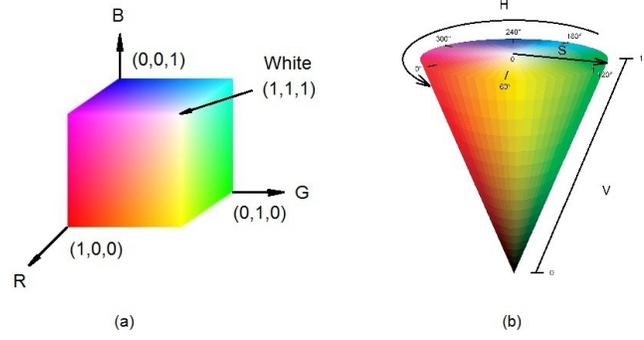


Fig. 4. Modelos de espacios de Color, (a) RGB, (b) HSV.

A través del modelo de color HSV tomamos información de la imagen, teniendo una mejor representación del contenido de color en cada muestra de nuestro caso de estudio.

El filtro de color diseñado toma la información y la convierte a una representación en el modelo HSV de la planta. Si los rangos de los componentes R, G y B están en el rango [0 255], la relación entre el modelo RGB y el HSV está descrita por:

$$\begin{aligned} C_{\max} &= \max \{R, G, B\} \\ C_{\min} &= \min \{R, G, B\} \\ C_{dif} &= C_{\max} - C_{\min} \end{aligned} \quad (1)$$

donde S y V están definidos como:

$$V = C_{\max} \quad (2)$$

$$S = \begin{cases} \frac{C_{\max} - C_{\min}}{C_{\max}} & \text{if } C_{\max} > 0 \\ 0 & \text{if } C_{\max} \leq 0 \end{cases} \quad (3)$$

Para obtener Hue es necesario normalizar los componentes R, G y B como sigue:

$$H' = \begin{cases} B' - G' & \text{if } R = C_{\max} \\ R' - B' + 2 & \text{if } G = C_{\max} \\ G' - R' + 4 & \text{if } B = C_{\max} \end{cases} \quad (4)$$

donde

$$R' = \frac{C_{\max} - R}{C_{dif}} \quad G' = \frac{C_{\max} - G}{C_{dif}} \quad B' = \frac{C_{\max} - B}{C_{dif}} \quad (5)$$

finalmente Hue es dado por:

$$H = \frac{1}{6} \begin{cases} H' + 6 & \text{if } H' < 0 \\ H' & \text{if } H' \geq 0 \end{cases} \quad (6)$$

La tabla 1 define cada tono de color para el filtro implementado en el modelo HSV. A través de este filtro, las manchas de la enfermedad y la morfología de la planta son observables de forma clara y en esencia, tal como lo muestra la figura 5b.

Tonality	Ranges
Yellow	$40^\circ \leq h < 90^\circ$
Green	$90^\circ \leq h < 160^\circ$
Cyan	$160^\circ \leq h < 190^\circ$
Blue	$190^\circ \leq h < 255^\circ$
Magenta	$255^\circ \leq h < 310^\circ$
Red	$310^\circ \leq h < 360^\circ$ y $0^\circ \leq h < 40^\circ$
Gray	$s = 0$ y $v < 0.95$
White	$0 < s \leq 0.2$
Black	$v \leq 0.3$

Tabla 1. Rangos usados para el filtro de color.



Fig. 5. Filtrado de Color, (a) RGB, (b) HSV.

La figura 5 muestra como en la morfología de la planta predominan los tonos verdes y amarillos, además de mostrarnos zonas con tono rojos y grises, objetos que actuaran como ruido en la búsqueda de patrones. Estos pueden crear confusión al sistema de reconocimiento, y dado que los sistemas de cultivo bajo invernadero es muy común el uso de piedra rojiza, es necesario extraer el cuerpo principal de la planta, eliminando el fondo de cada muestra tomada.

B. Creación de una Máscara para Eliminación de Fondo

De los resultados previos, si eliminamos los tonos verdes y amarillos, obtenemos una máscara con la estructura morfológica de la planta (figura 6a). Sin embargo la imagen muestra la existencia de regiones con pequeños objetos como ruido, estos objetos son removidos a través de procesamiento morfológico.

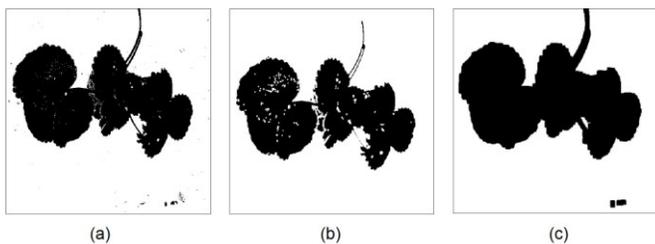


Fig. 6. Procesamiento Morfológico.

1) *Procesamiento Morfológico*: A través de erosión y dilatación podemos definir una mejor máscara para la eliminación del fondo. La Dilatación expande los pixeles en blanco de acuerdo a una imagen de referencia. La figura 6b muestra como los objetos pequeños de la máscara anterior desaparecen, pero también deja huecos dentro de la planta. La erosión recupera estos espacios y la estructura principal de la planta (figura 6c), sin embargo también recupera un pequeño objeto en la imagen. Las estructuras de referencia usados para la dilatación y la erosión son matrices unitarias 3x3 y 10x10 respectivamente.

Para la eliminación total de los objetos no deseados en la imagen, se procedió a usar la operación lógica XOR entre el complemento de la imagen (figura 7a) y la eliminación del objeto de mayor área en la imagen (figura 7b), obteniendo la mejor definición de la estructura de la planta en una máscara binaria (figura 7c).

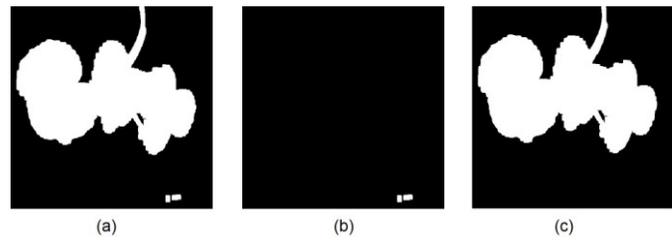


Fig. 7. Procesamiento Adicional para creación de un máscara de Eliminación de Fondo.

2) *Aplicación de la Mascara Binaria*: Aplicando la máscara (figura 8b) sobre la muestra original de la planta (figura 8a) se logra la completa eliminación del fondo de la imagen. Tal que si la máscara es aplicada al resultado del filtro de color, obtenemos la información principal de la imagen en ambos modelos RGB y HSV.

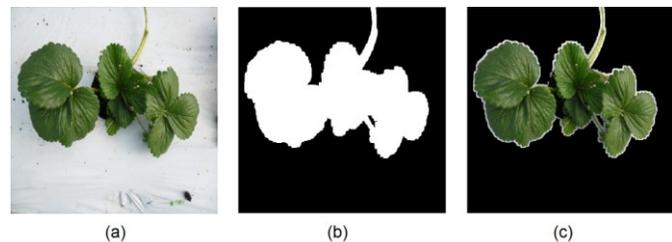


Fig. 8. Aplicación de la Máscara sobre la imagen original.

IV. ENTRENAMIENTO DE LA RED NEURONAL Y SU APLICACIÓN POR CONVOLUCIÓN

A. Extracción de Características y Entrenamiento de una Red Neuronal Backpropagation

Después de la aplicación del filtro de color resaltan matrices 3x3 como patrones, estos formados por bordes con tonos rojos, blancos y negros (figura 9).

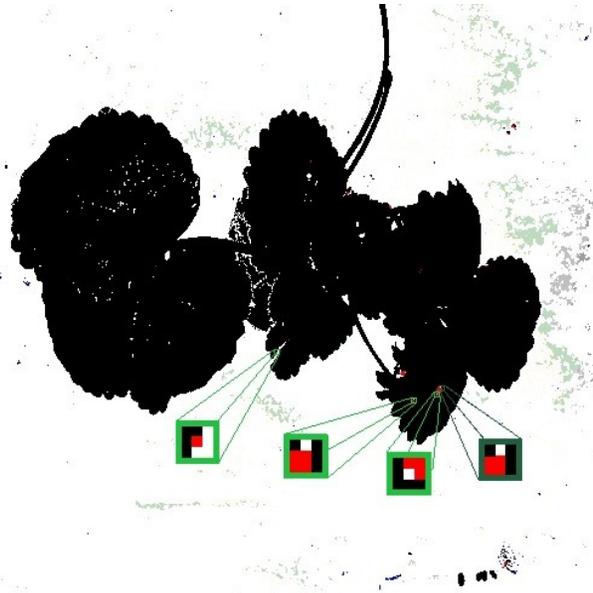


Fig. 9. Extracción de Características de *Ramularia Tulasnei*.

Tras el análisis de 120 muestras tomadas en cultivos bajo invernadero, se encontraron la recurrencia de los siguientes patrones:

$$\begin{bmatrix} 1 & 1 & 0 \\ 0 & 0.6 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0.6 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0.6 & 1 \\ 0 & 1 & 1 \end{bmatrix} \\
 \begin{bmatrix} 0 & 0.6 & 0.6 \\ 0 & 1 & 0.6 \\ 0 & 0 & 0.6 \end{bmatrix} \quad \begin{bmatrix} 0.6 & 1 & 0 \\ 0.6 & 0.6 & 0 \\ 0.6 & 0.6 & 0 \end{bmatrix} \quad \begin{bmatrix} 0 & 0 & 0 \\ 0.6 & 1 & 0 \\ 0.6 & 0.6 & 0 \end{bmatrix} \\
 \begin{bmatrix} 1 & 0.6 & 0.6 \\ 0 & 0.6 & 0.6 \\ 0 & 0 & 0 \end{bmatrix} \quad \begin{bmatrix} 0 & 0.6 & 0.6 \\ 1 & 0.6 & 0.6 \\ 0 & 0 & 0 \end{bmatrix}$$

Estos patrones fueron usados para el entrenamiento de una red neuronal backpropagation con dos neuronas como capa oculta y la función tangente sigmoial (figura 10). Para el entrenamiento de la red neuronal, los patrones fueron reordenados, tal que cada matriz 3x3 fuese un vector columna y el objetivo un renglón unitario, por lo que entrada y salida de la red neuronal puede ser expresada como:

$$P = [\text{pattern}_1 \quad \text{pattern}_2 \quad \dots \quad \text{pattern}_8]$$

$$T = [\quad 1 \quad \quad 1 \quad \quad \dots \quad \quad 1 \quad]$$

La red neuronal converge a 1 tras la existencia de alguno de los patrones en la imagen analizada. Sin embargo para el análisis de las muestras tomadas y con una resolución de 500x500 pixeles, la red neuronal filtra la información para cada subconjunto 3x3 sobre la imagen, teniendo un costo menor en la velocidad de procesamiento respecto a la resolución original de las muestras.

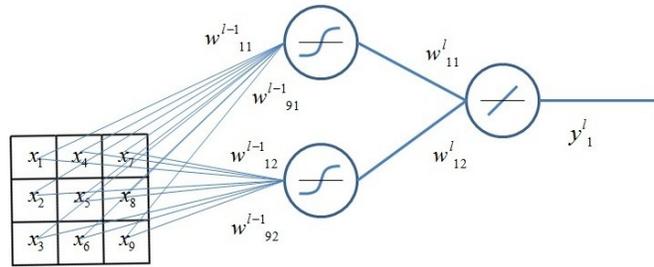


Fig. 10. Uso de una Red Neuronal Backpropagation para reconocimiento de imágenes de 3x3 pixeles.

B. Filtrado de Imagen usando una red neuronal Backpropagation

Los operadores de convolución son frecuentemente usados en el procesamiento de imagen para filtrar una imagen completa por medio de una máscara numérica, con efectos como suavizado, contraste, bordes, etc. Usando este concepto los pesos sinápticos de la red neuronal filtraran la información usando convolución (figura 11).

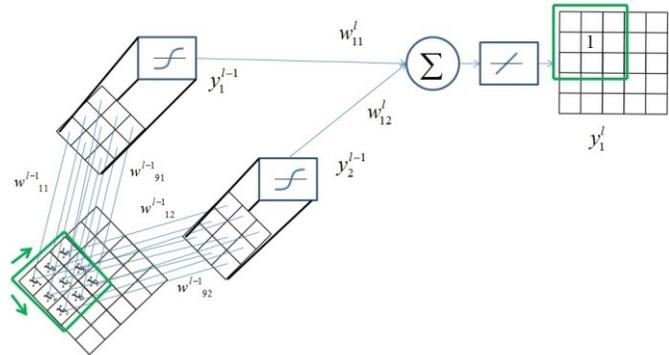


Fig. 11. Red Neuronal Backpropagation usada para detección de *Ramularia Tulasnei*.

Por este medio, los pesos sinápticos de las dos neuronas en la capa oculta y la función de transferencia actúan como filtro por medio de convolución, donde los resultados del filtrado por los pesos sinápticos son dos imágenes de la misma dimensión que la entrada. La neurona de salida toma estas imágenes y usa sus pesos sinápticos para filtrarlos y producir una imagen formada por subconjuntos 3x3 con un "1" como pixel central tras la existencia de alguna infección detectada de *Ramularia Tulasnei*.

V. RESULTADOS

El sistema desarrollado bajo SIMULINK se muestra en la figura 12, donde la muestra es tomada, procesada a través del filtro de color en el modelo HSV, procesamiento morfológico, extracción de características y filtrado a través de una red neuronal Backpropagation.

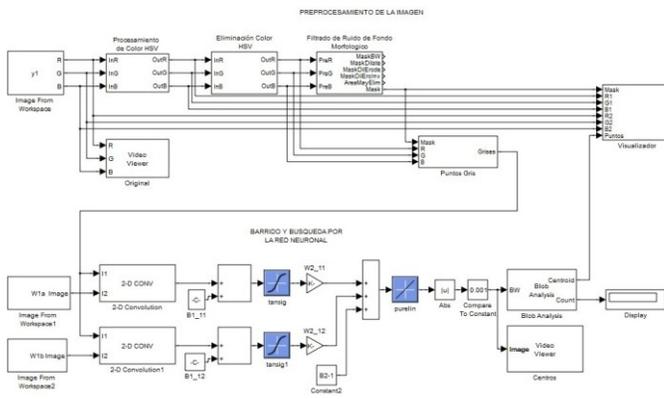


Fig. 12. Sistema de Identificación realizado en Simulink.

Los pesos sinápticos encontrados para cada neurona son los siguientes:

$$W1a = \begin{bmatrix} 1.7304 & 1.1631 & -0.2518 \\ 0.1977 & 0.0186 & 1.0878 \\ -0.4102 & -0.6950 & -1.6510 \end{bmatrix}$$

$$W1b = \begin{bmatrix} 1.5061 & 0.5487 & -0.2426 \\ -0.5543 & 1.2639 & -0.0823 \\ 1.2919 & 0.0777 & 1.7202 \end{bmatrix}$$

$$B1 = \begin{bmatrix} 1.0834 \\ -1.1769 \end{bmatrix} \quad B2 = [0.7894]$$

La figura 13 muestra el resultado de la aplicación del sistema de reconocimiento sobre cada muestra tomada de plantas infectadas con *Ramularia Tulasnei*.

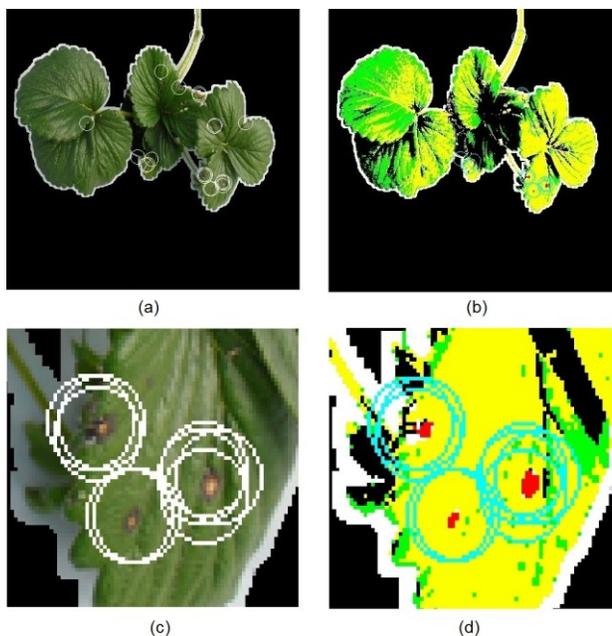


Fig. 13. Resultados del Procesamiento de Imagen y la Identificación del Sistema.

El sistema muestra también que a través de la implementación de la máscara binaria la información presentada es más clara. Las figuras 13a y 13b representan los hallazgos encontrados en cada uno de los modelos RGB y HSV respectivamente. Las figuras 13c y 13d muestran un acercamiento sobre las anteriores.

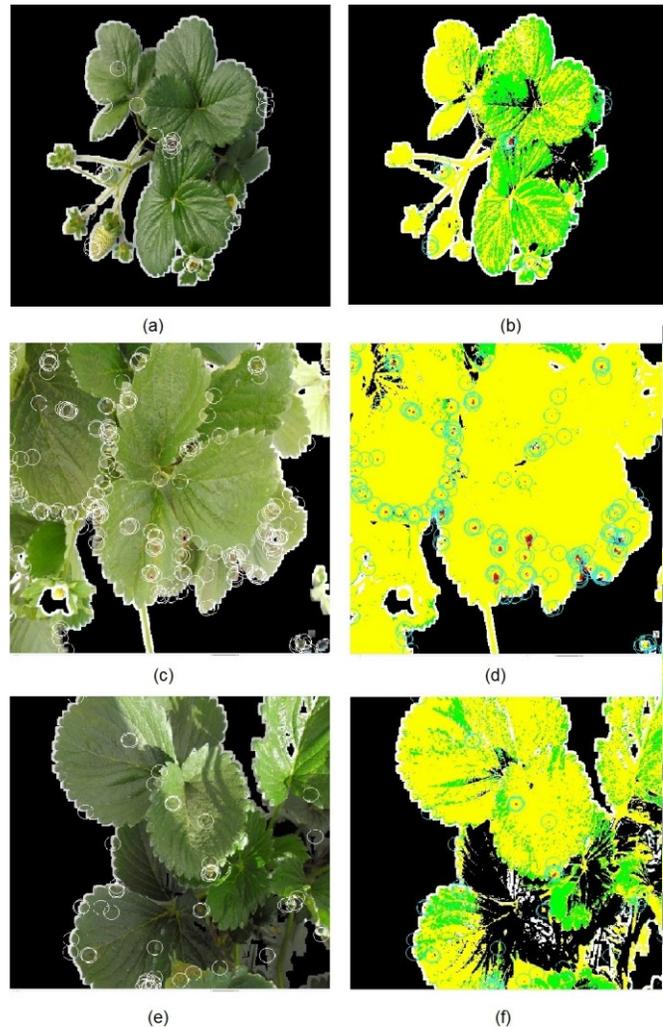


Fig. 14. Resultados de la Detección en otras muestras.

Cada círculo creado en la imagen en análisis está localizado en los centroides encontrados por medio de la Red Neuronal.

El sistema fue probado sobre las muestras tomadas de *Ramularia Tulasnei* en sistemas de cultivo bajo invernadero, tales como las mostradas en la figura 14, mostrando la detección de focos de infección de la enfermedad en análisis.

VI. CONCLUSIONES

El sistema de reconocimiento de patrones diseñado trabaja directamente con las imágenes que se tomen de muestra en un sistema de cultivo bajo invernadero, tal que puede ser implementado en tiempo real por medio de SIMULINK. El sistema fue diseñado considerando las características de *Ramularia Tulasnei*, tomando las propiedades de regiones de color 3x3, por lo que puede ser configurado para reconocimiento de otras enfermedades, procesando la imagen

y entrenando nuevamente la red neuronal con los patrones adecuados.

El sistema fue probado también adhiriendo ruido gaussiano a la imagen, pero dado que las manchas dejadas por *Ramularia Tulasnei* pueden ser muy pequeñas, el sistema es vulnerable a este, ya que su efecto bajo imágenes de color es muy similar a pequeñas manchas de *Ramularia Tulasnei*.

Tras el análisis de diferentes fuentes de información se advirtió que las técnicas de procesamiento de imagen en conjunto con redes neuronales son de frecuente uso para el reconocimiento de patrones, pero para el tema a tratar en este artículo no se encontraron trabajos similares.

El sistema de reconocimiento de patrones se encuentra en desarrollo, por lo que en trabajos futuros se analizarán enfermedades semejantes a *Ramularia Tulasnei*, de tal manera que el sistema sea ampliado para detección de más enfermedades tanto para fresón como para otros cultivos y sea aprobado por los sistemas de cultivo bajo invernadero como herramienta de detección oportuna.

REFERENCIAS

- [1] Narayanasamy, P. (2001). Plant Pathogen Detection and Disease Diagnosis. Dekker. USA.
- [2] Macías, O., Delgado, Y., Pea, E., León, R. y Barreto, R. (2006). Técnicas para el diagnóstico y determinación de variabilidad genética de fitopatógenos. Cuba.
- [3] Rosales, I. (2002). Diagnóstico de Enfermedades en Plantas: Uso de Herramientas Moleculares. INIA- CRI La Platina. Chile.
- [4] Brodeur, C., Carisse, O. and Bourgeois, G. (1997). STRAWBERRY LEAF SPOT Control strategies, Agriculture and Agri-Food Canada Research Branch. Horticulture. Canada.
- [5] SENASA (2010). *Ramularia Tulasnei*. Argentina.
- [6] Lawrence, U. (2004). Strawberry disease control guide. NSW Agriculture. Australia.
- [7] SAGARPA (2005). Plan Rector Sistema Nacional Fresa. México D.F.
- [8] IICA (2007). Guía práctica para la exportación a EE.UU FRESA. Managua.
- [9] Shih, F. (2010). Image Processing and Pattern Recognition – Fundamentals and Techniques. Wiley. USA.
- [10] Solomon, C. and Breckon, T. (2011). Fundamentals of Digital Image Processing - A Practical Approach with Examples in Matlab. Wiley-BlackWell. UK.
- [11] Gonzalez, R. and Woods, R. (2002). Digital Image Processing. Prentice Hall. USA.
- [12] Cuevas, E., Zaldivar, D. y Pérez, M. (2010). Procesamiento Digital de Imágenes con MATLAB y Simulink. Alfaomega Ra-Ma. México.
- [13] Haykin, S. (1999). Neural Networks - A Comprehensive Foundation. Prentice Hall. USA.
- [14] Fausett, L. (1993). Fundamentals of Neural Networks - Architectures, Algorithms and Applications. USA.
- [15] Yeung, D., Shi, D. and Ng, W. (2010). Sensitivity Analysis for Neural Networks. Springer. Berlin.
- [16] Matignon, R. (2005). Neural Network Modeling using SAS Enterprise Miner.
- [17] Chow, T. and Cho, S. (2007). Neural Networks and Computing - Learning Algorithms and Applications. Vol. 7. Imperial College Press. USA.
- [18] Theodoridis, S. and Koutroumbas, K. (2008). Pattern Recognition. Elsevier. USA.
- [19] Zheng, N. and Xue, J. (2009). Statistical Learning and Pattern Analysis for Image and Video Processing. Springer. London.
- [20] Cambridge in Color. (2012). Digital Camera Sensors. <http://www.cambridgeincolour.com/tutorials/camera-sensors.htm>