



Universidad Autónoma de Querétaro
Facultad de Instrumentación
Maestría en Instrumentación y Control Automático

Desarrollo de un método de procesamiento de imágenes para la
discriminación de maleza en cultivos de maíz

TESIS

Que como parte de los requisitos para obtener el grado de
Maestro en Ciencias en Instrumentación y Control Automático

Presenta:

Daniela Guadalupe Ramírez Osuna

Dirigido por:

M. C. Aurora Femat Díaz.

SINODALES

M.C. Aurora Femat Díaz
Presidente

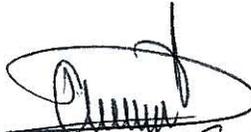
Dr. Damián Vargas Vázquez
Secretario

Dr. Alberto Pastrana Palma
Vocal

Dr. Edgar Rivas Araiza
Suplente

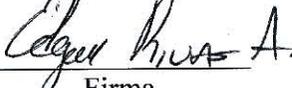
M.I. Luis Miguel Contreras Medina
Suplente

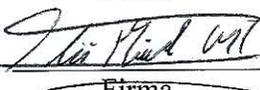

Dr. Aurelio González Domínguez
Director de la Facultad


Firma


Firma


Firma


Firma


Firma


Dr. Irineo Torres Pacheco
Director de Investigación y
Posgrado

Centro Universitario
Querétaro, Qro.
Mayo de 2012
México

RESUMEN

El presente trabajo, propone una metodología basada en técnicas de procesamiento digital de imágenes para la discriminación de maleza, cultivo y suelo presente en sembradíos de maíz. Se usa una base de datos formada por 200 imágenes, tomadas durante el período crítico de competencia del cultivo y bajo condiciones naturales de iluminación; de las cuales, 100 se emplearon para el entrenamiento del sistema y el resto para la evaluación del mismo. La metodología se divide en dos etapas fundamentales: Segmentación de la vegetación contra la no vegetación y segmentación de la maleza contra el cultivo. La primer etapa tiene como objetivo clasificar la vegetación (maíz, maleza) contra el suelo (tierra, escombros, piedras, etc.) apoyándose en técnicas de transformadas de color, filtrado y umbralización. La segunda etapa se divide en tres secciones para su estudio: (1) Análisis textural Wavelet, que realiza un análisis textural de descriptores estadísticos de primer y segundo orden basados en la transformada Wavelet. (2) Extracción de características, donde se disminuye la dimensionalidad de los datos aumentando la eficacia del clasificador a través del método *IFFS (Improve Floating Forward Selection)*. (3) Clasificación, en la cual se realiza una identificación de las hojas de maleza y de maíz en la imagen a través de una combinación de técnicas de segmentación basadas en redes neuronales (Perceptrón Multicapa) y detección de transiciones. Los resultados demuestran la eficacia del método, con una tasa de clasificación del 94.77%

(Palabras claves: maleza, textura, transformada Wavelet, procesamiento de imágenes).

SUMMARY

This paper proposes a methodology based on techniques of digital image processing for the discrimination of weed, crop and soil in corn fields. It was used a database consisting of two hundred images taken during the critical period of crop competition and under natural conditions of lighting. One hundred were used for training the system and the balance for evaluation. Methodology is divided in two main stages: segmentation of vegetation against non-vegetation and weed segmentation against the crop. First, vegetation – corn, weeds – and ground – soil, debris, rocks – are classified using color transformation, filtering and thresholding. Second, corn and weed are segmented using a three steps methodology: (1) Wavelet textural analysis, which was made an analysis through textural descriptors of first and second order based on wavelet transform. (2) Feature extraction, dimensionality of data was decreased enhancing the classifier effectiveness. (3) Classification, a Multilayer Perceptron and segmentation by detection of transitions were applied for weed and corn leaves classification. The results demonstrated the effectiveness of the proposed methodology with a classification rate of 94.77%.

(Keywords: wavelet transform, image processing, texture, weed.)

**Dedico esta tesis a mi familia, que siempre estuvo
en mis pensamientos en cada paso y esfuerzo realizado.**

AGRADECIMIENTOS

Agradezco el presente trabajo, primeramente, a DIOS por permitirme llegar a este punto de la vida dándome las fuerzas necesarias para seguir luchando día tras días e ir rompiendo las barreras que se me presentan.

A mis padres, Guadalupe Osuna Flores y Jesús Daniel Ramírez Cañedo por creer en mí, por apoyarme en las buenas y en las malas, por sus esfuerzos para darme una mejor educación, por estar conmigo en todo momento, pero sobre todo por su cariño y amor incondicional, los ama su hija. A mi hermana, Diana Lizeth Ramírez Osuna que con su alegría me inspira a seguir adelante y ser mejor cada día, por darme una sonrisa y cariño cuando lo necesito, te quiero mucho. A la niña que siempre está en mis pensamientos y corazón, Helguita Ramírez, por darme alegría y estar conmigo tanto en las buenas como en las malas. A Víctor Manuel Ramírez Alonso por su apoyo incondicional, amistad y amor. Por esto y mucho más les estoy eternamente agradecida, los quiero mucho.

Agradezco a mi asesora la M.C. Aurora Femat Díaz por su tiempo, confianza y apoyo durante la elaboración de esta tesis. A CONACYT por el apoyo económico otorgado a lo largo de mis estudios de posgrado.

ÍNDICE

RESUMEN	i
SUMMARY	ii
DEDICATORIAS	iii
AGRADECIMIENTOS	iv
I. INTRODUCCIÓN	1
1.1 Descripción de los capítulos	5
1.2 Justificación	6
1.3 Hipótesis	7
1.4 Objetivos	7
II. REVISIÓN DE LITERATURA	8
2.1 Antecedentes	8
2.2 Fundamentación teórica	13
2.2.1 Análisis de texturas	13
2.2.1.1 Métodos de caracterización de texturas	14
2.2.2 Transformada Wavelet	16
2.2.2.1 Transformada Wavelet Estacionaria 2D	17
2.2.3 Métodos de selección de características	19
2.2.3.1 Métodos óptimos	21
2.2.3.2 Métodos sub-óptimos con una solución	22
2.2.3.3 Métodos de redes neuronales	22
2.2.4 Algoritmo de búsqueda IFFS	23
2.2.5 Detección de transiciones	25
2.2.6 Binarización	26
2.2.7 Adelgazamiento	26
2.2.8 Cierre de contornos	27
2.2.9 Etiquetado de regiones	28
2.2.10 Redes neuronales	29
2.2.10.1 Perceptrón	31

III. METODOLOGÍA	32
3.1 Adquisición de imágenes	33
3.2 Creación de base de datos	33
3.3 Segmentación de la vegetación contra la no vegetación	35
3.4 Segmentación del cultivo contra la maleza	38
3.4.1 Análisis textural	40
3.4.1.1 Análisis textural basado en la Transformada Wavelet	40
3.4.2 Parámetros de la transformada Wavelet	47
3.4.2.1 Selección de la función escala	47
3.4.2.2 Selección del nivel de descomposición	48
3.4.3 Selección de características	49
3.4.3.1 Selección del procedimiento de búsqueda	49
3.4.3.2 Selección de la función de evaluación	50
3.4.3.3 Metodología empleada para la selección del subconjunto	51
3.5 Clasificador	52
3.5.1 Segmentación neuronal	53
3.5.2 Segmentación por transiciones	54
3.6 Evaluación de resultados	57
IV. RESULTADOS Y DISCUSION	58
4.1 Segmentación de la vegetación	58
4.2 Segmentación del cultivo y la maleza.	59
4.2.1 Análisis textural	59
4.2.2 Selección de características	60
4.3 Clasificador	61
4.4 Conclusiones	66
V. REFERENCIAS BIBLIOGRÁFICAS	68

ÍNDICE DE CUADROS

Cuadro		Página
3.01	Matriz de confusión.	57
3.02	Medidas de evaluación para el clasificador.	57
4.01	Evaluación de resultados.	61
4.02	Comparación de resultados con otros trabajos.	62

ÍNDICE DE FIGURAS

Figuras		Página
2.01	Estructura de banco de filtros de la TWS.	18
2.02	Métodos de selección de características.	20
2.03	Diagrama de flujo del algoritmo IFFS.	24
2.04	(a) Gradiente fila y (b) gradiente columna.	25
2.05	(a) Vecindad V4 y (b) V8.	28
2.06	Modelo de una neurona estándar.	29
3.01	Esquema general del capítulo.	33
3.02	Separabilidad estadística de los conjuntos de clases.	35
3.03	Segmentación de la vegetación. (a) Imagen de entrada, (b) Imagen segmentada.	36
3.04	Segmentación de hojas de maleza y maíz. (a) Imagen de entrada, (b) Imagen segmentada	39
3.05a	Entrenamiento del sistema de segmentación.	39
3.05b	Evaluación del sistema de segmentación.	40
3.06	Estructura del Perceptrón Multicapa (MLP).	53
3.07	Etapas del clasificador. (a) Imagen de entrada, (b) Vegetación segmentada, (c) Realce de bordes y cerrado de contorno, (d) Imagen etiquetada por regiones, (e) Segmentación neuronal e (f) Imagen clasificada, donde el maíz es representado de verde y la maleza de rojo.	56

4.01a	Segmentación de la vegetación con el Método I. (a) Imagen de entrada; (b) Imagen monocroma; (c) Imagen binarizada; (d) Imagen segmentada con $r = -1$, $g = 2$, $b = -1$, $umbral=25$.	58
4.01b	Segmentación de la vegetación con el Método II. (a) Imagen de entrada. (b) Imagen binarizada; (c) Imagen segmentada con $I_{min}=45$, $I_{max}=236$.	59
4.02	(a) Distancia de Mahalanobis , (b) para cada tamaño de subconjunto de características evaluado.	60
4.03	Ejemplo de clasificación I. (a) Imagen de entrada, (b) Imagen de segmentada.	63
4.04	Ejemplo de clasificación II. (a) Imagen de entrada, (b) Imagen de segmentada.	64
4.05	Ejemplo de clasificación III. (a) Imagen de entrada, (b) Imagen de segmentada.	65

I. INTRODUCCIÓN

Los esfuerzos por incrementar y mejorar la productividad de la agricultura en México han generado importantes debates entre los sectores político, social y económico durante los últimos años, debido a que el bajo rendimiento de la agricultura ha ocasionado un considerable incremento del desempleo y el empobrecimiento de la clase rural con graves efectos migratorios (Excelsior, 2009).

En la actualidad, gran parte de los problemas que afectan a la agricultura se deben a aspectos fitosanitarios, entre los cuales, el crecimiento de las malezas ocupa un lugar predominante. Sin embargo, debido a que los efectos nocivos de estas malas hierbas no son evidentes al inicio del desarrollo de los cultivos, no se le otorga la importancia debida y se aplican sistemas de control cuando los cultivos ya han sido infectados (Rosales *et al.*, 2002). El crecimiento de las malas hierbas representa un problema de gran relevancia para la mayoría de los cultivos comerciales, ya que suele ser un factor determinante contra el desarrollo óptimo de la planta y su posterior rendimiento.

A nivel mundial, informes de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) estiman que entre el 20 y 40% de las pérdidas en la producción agrícola es causado por diferentes plagas, entre las cuales destacan las enfermedades, insectos y maleza. La magnitud del problema y el tipo de plaga, varía de acuerdo a la región, año y tipo de cultivo; así, por ejemplo, respecto del maíz las pérdidas se calculan en 34.8%, de las cuales, aproximadamente el 37% se debe a la maleza, el 36% a insectos y el 27% a enfermedades. En el trigo, las pérdidas alcanzan el 23.9%, de este porcentaje el 41% es atribuible a malezas y el 20% a insectos. El sorgo es el cultivo más afectado por malezas en el mundo, ya que de un 38% de sus pérdidas totales, el 47% se debe a esta plaga y el resto a enfermedades e insectos. Por el contrario, en los cultivos de papa, las pérdidas ascienden a 32.3%, imputables en un 67% a enfermedades y en un 33% a malezas e insectos, mientras que del total de las pérdidas del arroz, que ascienden al 46.4%, el 57% corresponde a los insectos y el 43% a malezas y enfermedades (Bifani, 1999).

A nivel nacional, la agricultura se encuentra gravemente afectada por la invasión de maleza en los cultivos, pues la mayor parte de las pérdidas de éstos se debe a esa problemática. La academia de la Facultad de Estudios Superiores (FES) Cuautitlán de la UNAM, advirtió que el surgimiento de malezas o especies invasoras en México afecta, en promedio, al 30% del rendimiento de algunos cultivos; sin embargo, las pérdidas pueden elevarse hasta 70%, e incluso, ser totales (Universia, 2010).

Las plantaciones más afectadas por plagas son el maíz, el sorgo de grano, el cártamo, el frijol y el trigo (SIAP, 2010); de los cuales, las plantaciones de maíz y frijol son las que sufren mayores daños a causa de las malas hierbas. Debe tenerse en cuenta que la producción del maíz es una de las actividades más importantes del sector rural en México, no sólo en términos de uso de suelo, sino también en la generación de empleo y en el suministro de alimentos a la población rural y urbana del país.

El periodo crítico del maíz se encuentra entre los primeros 30 a 45 días después de la siembra; si la maleza no se controla durante este periodo de una manera eficiente y oportuna, se estima una pérdida del 45% del rendimiento de la cosecha. Esto se debe a que las malas hierbas compiten con el cultivo por el espacio, el agua, la luz y los nutrientes, además de favorecer la presencia de plagas, dificultar el proceso de cosecha, y provocar alergias e incluso envenenamiento en el ser humano.

Existen diferentes tipos de control o métodos tradicionales que pueden ser usados para tratar la infestación de malas hierbas como son: manual, mecánico, biológico y químico. El primero, no contamina el medio ambiente y puede ser usado en cultivos que se plantan muy juntos, sin embargo, es un trabajo intensivo y poco eficiente que consume mucho tiempo e implica un alto costo de mano de obra. El segundo, es amigable con el medio ambiente, pero es un trabajo que puede llegar a dañar el suelo y provocar alteraciones que favorezcan la germinación de semillas de maleza o la regeneración de la misma. El tercero, utiliza la naturaleza para controlar de forma segura las plantas dañinas, pero la eficacia no puede ser garantizada, además de ser de acción lenta y costoso. El

cuarto, es de acción rápida y eficaz, esto lo convierte en la principal opción para la mayoría de los agricultores, lo que genera un uso indiscriminado de herbicidas.

El amplio uso de herbicidas no solo ha contaminado el agua, el suelo y el aire, sino también los cultivos, provocando efectos nocivos en la salud de los seres humanos; estudios realizados en Brasil sugirieron que, para el maíz, los costos por intoxicación aguda puede representar el 64% de los beneficios del uso de herbicidas e insecticidas, y en la mejor de las hipótesis, eliminando factores de riesgos, pueden alcanzar el 8% de los beneficios del uso de estos productos (Soares y Souza Porto, 2009). Otro efecto importante del abuso de herbicidas son las pérdidas económicas, ya que en muchos de los casos su empleo resulta ser innecesario y, en ocasiones, no es capaz de resolver el problema a causa de la avanzada infección que presentan los cultivos, además de que con el tiempo la malas hierbas se vuelven resistentes a los efectos de los herbicidas.

En la actualidad, existe una necesidad evidente de transferir tecnología al manejo de maleza, no solo por aspectos ecológicos, sino también por *marketing*, ya que cada vez más clientes piden productos que sean cultivados orgánicamente. Para la agricultura sustentable, el control de maleza con el uso de herbicidas implica particular atención, por ser los principales contaminantes agrícolas; es por ello que en conjunto con la agricultura de precisión tienen como objetivo reducir el uso de herbicidas mediante el empleo tecnologías de cómputo, sensores, satélites e imágenes; que a su vez proporcione un tratamiento agronómico más apropiado a los campos, rentabilidad a los productores y beneficios ecológicos y ambientales para el público (Zhang *et al.*, 2002).

En los últimos años, el tratamiento de malezas mediante soluciones sustentables ha provocado el desarrollo de trabajos basados en métodos de visión por computadora para la identificación de maleza en cultivos, algunos de estos trabajos son los realizados por: Kavdir (2004) quien empleó una red de retro-propagación neuronal para la discriminación de girasol y malas hierbas con una precisión del 82.55%, sus imágenes fueron tomadas bajo iluminación natural, pero la clasificación se enfocó a imágenes que contenían exclusivamente cultivo o solo maleza. Piron *et al.* (2008) utilizaron una cámara para la

selección de una longitud de onda que permite discriminar la maleza del cultivo mediante una combinación adecuada de filtros; su mejor combinación incluye tres filtros en el orden de 450, 550 y 700 nanómetros, con una tasa de clasificación general del 72%, pero sus resultados dependen altamente de la luminosidad, por lo que un sistema de iluminación artificial debe ser usado para evitar interferencia con la luz natural. Tellaeche *et al.* (2008) realizaron un estudio para la identificación de maleza en cultivos de maíz basados en técnicas de procesamiento de imágenes y teoría de la decisión de Bayes, este método resultó ser eficiente para la identificación de maleza en los surcos; sin embargo, presentó problemas cuando ésta se encontraba entrelazada con las plantas del cultivo.

Burgos-artizzu *et al.* (2011) emplearon una metodología basada en operadores morfológicos y umbralizaciones para la discriminación en tiempo real del cultivo y la maleza presente en campos de maíz; sus resultados demostraron una tasa de clasificación en promedio del 95% para la maleza y del 80% para el maíz, las imágenes fueron tomadas bajo diferentes condiciones de luz natural, humedad del suelo y crecimiento de la vegetación; sin embargo, el método se limita a la a la identificación de maleza en surcos, descartando aquella que se encuentra entrelazada con el cultivo. Por último, Kiani *et al.* (2010) muestran que la transformada Wavelet es un método eficiente, los resultados arrojan un porcentaje de precisión del 97% para imágenes de maíz y del 98% para imágenes de maleza, pero éstas fueron tomadas bajo condiciones de invernadero.

En el presente trabajo, se pretende mejorar los inconvenientes que presentan algunos de los métodos citados con anterioridad, mediante el desarrollo de una metodología basada en técnicas de procesamiento digital de imágenes para la discriminación de maleza, cultivo y suelo presentes en plantaciones de maíz bajo condiciones a campo abierto. El procesamiento de las imágenes se dividió en tres etapas: (1) Extracción de clases, que realiza una selección y recorte de áreas de interés de las imágenes de campo; (2) Análisis y extracción de características, donde se efectúa un estudio de las técnicas texturales, con el objetivo de extraer y caracterizar las cualidades digitales de cada uno de los elementos (maíz, maleza y suelo) de la imagen. (3) Segmentación de áreas de interés, en la cual se

asocian los objetos de la imagen por clases (maleza, cultivo y suelo) en función de las características extraídas, además de medir y cuantificar los mismos.

1.1 Descripción de los capítulos

La tesis se encuentra organizada en seis capítulos, cuyos contenidos se describen a continuación:

El capítulo I, Introducción, además de presentar una breve descripción del tema de investigación y su importancia como objeto de estudio, que ya se hizo, lleva a cabo el planteamiento de la hipótesis, los objetivos y la justificación.

El capítulo II, Antecedentes, presenta los trabajos más relevantes de los últimos años relacionados con el tema tratado en la investigación, describiendo las técnicas usadas por dichos trabajos, así como sus limitaciones y conclusiones, de manera que se pueda entender y evaluar los resultados por ellos presentados.

El capítulo III, Marco teórico, presenta una revisión literaria de los temas principales sobre los que se fundamenta la propuesta metodológica: análisis textural y técnicas de segmentación.

El capítulo IV, Metodología, describe de manera detallada los métodos empleados para cada uno de los objetivos planteados, de tal manera que al término de este capítulo se pueda discriminar la maleza, el cultivo y el suelo presente en imágenes de sembradíos de maíz.

El Capítulo V, Resultados y discusión, describe los resultados obtenidos con las técnicas y metodologías empleadas en el capítulo IV, comparando y evaluando éstos en relación con los trabajos previos, con el propósito de exponer las mejoras encontradas así

como algunas recomendaciones para futuras investigaciones en la misma línea temática propuesta por la tesis.

1.2 Justificación

La dificultad para identificar y discriminar malas hierbas en los cultivos de maíz, así como la falta de eficiencia de los sistemas tradicionales destinados a su control, han generado graves problemas de productividad en la agricultura. Estos sistemas tradicionales se han caracterizado por un elevado costo de mano de obra y tiempo (control manual), por ser perjudiciales para la preservación del medio ambiente (control químico) e incluso, poco eficaces para la erradicación del problema (control mecánico).

Los nuevos sistemas destinados a la discriminación de maleza utilizan sensores ópticos y técnicas de visión artificial, aunque esta nueva sistematización ha venido a reducir significativamente los problemas derivados de los sistemas de control tradicional, aún tiene mucho campo por mejorar, puesto que padece de falta de precisión en los resultados y de imposibilidad de procesamiento en tiempo real. Tales deficiencias dependen íntimamente de la metodología empleada para el desarrollo del sistema, por lo cual es de vital importancia realizar una selección adecuada de las técnicas a utilizar, con el fin de desarrollar métodos eficientes y capaces de adaptarse a las condiciones reales del campo agrícola.

De acuerdo a lo expuesto en los antecedentes y la fundamentación teórica, es notorio que existen diversas técnicas de procesamiento de imagen, que combinadas, son capaces de producir métodos alternativos destinados a la discriminación de malas hierbas en el campo. Muchas técnicas ya han sido utilizadas, sin embargo, la mayor parte de ellas sólo aprovecha la distribución geométrica de los cultivos, discriminando en éstos la maleza por la posición espacial que ocupa en el campo, ignorando características que, si bien son difíciles de identificar, son esenciales para obtener óptimos resultados.

1.3 Hipótesis

Una combinación adecuada de técnicas de procesamiento digital de imágenes permite discriminar la maleza en cultivos de maíz bajo condiciones de campo abierto, con una metodología robusta a la iluminación natural, y con una tasa de clasificación y especificidad mayor al 90%.

1.4 Objetivos

Objetivo general

Desarrollar e implementar un método basado en técnicas de análisis de imágenes, para la identificación de maleza, cultivo y suelo, presente en plantaciones de maíz.

Objetivos particulares

- Investigar y analizar las características de las malas hierbas presentes en plantaciones de maíz.
- Discriminar la vegetación del suelo, mediante técnicas de transformada de color.
- Desarrollar un método para la discriminación de hojas de maleza y de maíz, de acuerdo a sus características, a través de técnicas de segmentación basadas en texturas y detección de transiciones.
- Crear un mapa en el que se especifique la distribución de maleza presente en cultivos de maíz, basado en la aplicación de los métodos desarrollados.

II. REVISIÓN DE LITERATURA

2.1 Antecedentes

En la actualidad, a la situación en la que un organismo vivo (patógeno) ocasiona alteraciones fisiológicas en otro, normalmente con síntomas visibles o daños económicos, se le llama plaga. Desde la antigüedad el control de plagas ha sido una actividad de vital importancia dentro sector agrícola, ya que prevenirlas y combatirlas ha resultado ser sumamente costoso y necesario para la preservación de los cultivos.

El uso de sustancias químicas como pesticidas se remonta a siglos con el uso del mercurio, plomo y arsénico para el control de malas hierbas, pero fue hasta el siglo XIX cuando aparecieron los primeros insecticidas naturales como el piretro y la rotenona. En 1948 el químico suizo Paul Hermann gana el premio nobel de la medicina por el descubrimiento del DDT (Dicloro Difenil Tricloroetano) como pesticida, fecha a partir de la cual se da comienzo al uso de agroquímicos como la principal manera para combatir las plagas en cultivo. Sin embargo, no transcurrió mucho tiempo para que se tomara conciencia del uso indiscriminado de pesticidas y de los efectos que estos podrían ocasionar en la salud de las personas y para la prevención de los recursos naturales.

En la actualidad, existe un gran conflicto entre el uso de agroquímicos y las campañas ecologistas, es por esto que se ha dado el surgimiento de una nueva técnica de producción conocida como “producción ecológica u orgánica”, cuyo esquema productivo no permite el uso de pesticidas. Pero, indudablemente, no puede alcanzar a cubrir la demanda alimenticia e incluso su costo resulta ser mayor al de la agricultura convencional, y en ocasiones, con productos de menor calidad.

A pesar de los problemas que evidentemente los pesticidas puedan generar, lamentablemente, hasta el momento no existe otra técnica que sustituya con la misma

eficacia la eliminación y el control de plagas, he aquí la importancia de desarrollar tecnología para el control y el manejo adecuado de las mismas.

Dentro de las plagas a combatir, sin lugar a duda, las malezas ocupan un lugar predominante; es por esto, que muchos estudios del siglo XIX se han enfocado a la erradicación de este mal, usando métodos que permitan disminuir los costos y el uso innecesario de pesticidas empleados por las técnicas convencionales.

Los sistemas destinados a la detección de maleza pueden ser clasificados en dos grandes grupos: detectores mediante sensores ópticos y mediante visión artificial. A su vez, el primer grupo se divide en dos clases: por detección de color y por detección del rojo e infrarrojo cercano. Mientras que el segundo grupo se divide en tres clases de estudio: por análisis de color, de forma y de textura. Esta clasificación da sin duda un panorama de la cantidad de trabajo que se ha llevado a cabo en este sentido. A continuación, se muestra un estudio de los trabajos realizados en los últimos años para el control y detección de maleza.

Sensores ópticos

En el Instituto de Ingeniería Rural de INTA desarrollo un sensor de malezas que funciona en forma pasiva, es decir dependiendo de la luz solar y que funciona sobre la base de la reflexión de las ondas del infrarrojo cercano (Moltoni y Moltoni, 2005). Actualmente, se está trabajado con el objetivo de transformarlo en activo para permitir su uso nocturno o en situaciones de poca iluminación.

Hemming y Rath (2001) desarrollaron un sensor que analiza en forma conjunta el color y la forma de la planta, llegando a niveles de identificación del 51 y 95% para diferentes especies de malezas; sin embargo, admitieron tener dificultades para la detección de maleza entremezclada en los cultivos.

En ensayos llevados a cabo entre el año 2000 y 2003, sobre cultivos de cereales y maní que emplean sensores de maleza, se llegó a constatar una notable disminución en la

distribución de agroquímicos, ya que gracias a estos sensores se logró cambiar la metodología de distribución de pesticidas de cobertura total a una distribución selectiva del mismo (Dammer y Wartenberg, 2007).

Visión artificial

Muchos métodos de visión por computadora, basados en técnicas de procesamiento digital de imágenes y métodos de inteligencia artificial, se han desarrollado para la identificación de maleza en cultivos, mediante la extracción y evaluación de las características de la imagen.

La distribución geométrica de los cultivos, conocida como geometría de la plantación, ha sido ampliamente utilizada para facilitar la discriminación de las malezas y extracción de características de la imagen (Tillett *et al.*, 2001). Esta geometría de la plantación fue usada por Gée *et al.* (2008) como un aspecto importante dentro de su metodología de trabajo para la estimación de la tasa de infección de maleza en cultivos; este método se divide en dos etapas, la detección de las filas de cultivos mediante un algoritmo basado en la transformada de Hough y la identificación de los cultivos y malas hierbas a través una segmentación de regiones usando un análisis de coloreado de manchas; los resultados mostraron que la transformada Hough resultó ser un método fiable para la detección de filas de cultivo, pero el algoritmo de discriminación de maleza mostró ser poco eficiente, ya que para imágenes con medio y alto grado de infección de maleza, los resultados presentaron un error alrededor del 17 y 55%, respectivamente.

Con el objetivo de disminuir el uso de herbicidas empleado en el campo, Tellaeche *et al.* (2008) realizaron un estudio para la identificación de maleza en cultivos de maíz, el método se basó en dos procesos: la segmentación de la imagen y la toma de decisiones para la aplicación de herbicidas. La segmentación de la imagen combina las técnicas básicas del procesamiento digital de imágenes, y la toma de decisión de basa en la teoría de la decisión de Bayes; este método resulto ser eficiente para identificación de maleza en los surcos; sin embargo, presentó problemas cuando está se encontraba

entrelazada con las plantas de cultivo. Algunos algoritmos de segmentación propuestos por Onyango *et al.* (2003) hacen uso de una cuadrícula de plantación en combinación de un procesado morfológico para aprovechar las diferencias de texturas entre las malezas y los cultivos, con el objetivo de incrementar el potencial de clasificación de áreas cercanas a las plantas; los resultados mostraron que su mejor y peor algoritmo de segmentación clasificó en promedio el 96 y 82% de los píxeles de cultivo correctamente, mientras que el caso de la maleza su mejor clasificador fue del 92% y el peor del 68%.

Burgos-Artizzu *et al.* (2010) presentaron varios métodos basados en la combinación de técnicas de procesamiento digital de imágenes, entre las que destacan el uso de segmentación, morfología y detección de forma para la estimación de los porcentajes de maleza, cultivo y suelo proveniente de imágenes de una región de interés del campo de cultivo, sus resultados proporcionan en promedio un coeficiente de correlación con los datos reales del 84%. Burgos-Artizzu *et al.* (2011) emplearon una metodología basada en operadores morfológicos y umbralizaciones para la discriminación en tiempo real del cultivo y la maleza presente en campos de maíz, los resultados demostraron una tasa de clasificación en promedio del 95% para la maleza y del 80% para el maíz, las imágenes fueron tomadas bajo diferentes condiciones de luz natural, humedad del suelo y crecimiento de la vegetación, sin embargo el método se limita a la a la identificación de maleza en surcos, descartando aquella que se encuentra entrelazada con el cultivo. Siddiqi *et al.* (2008) desarrollaron un algoritmo basado en una erosión seguida por un algoritmo de segmentación Watershed, para la detección y clasificación de malas hierbas; este algoritmo se aplicó en 200 imágenes almacenadas en una base de datos en el laboratorio, de las cuales 100 imágenes pertenecían a malezas de hoja ancha, y el resto a maleza de hoja estrecha; sus resultados mostraron un 89% de efectividad.

Es importante mencionar que los trabajos citados anteriormente y basados en técnicas de procesamiento digital de imágenes, a excepción del trabajo realizado por Onyango *et al.* (2003) se han caracterizado por discriminar la maleza de acuerdo a la posición espacial que ocupa en el campo, ignorando características (textura, forma, color,

entre otras), que si bien son difíciles de identificar, debido a las similitudes físicas entre malezas y cultivos, son esenciales para obtener óptimos resultados.

Un estudio sobre hojas de cultivos de cereales, demostró que a pesar de la dificultad para la determinación del número de plántulas en tiempo real, las técnicas de procesamiento de imágenes son factibles para estimar la superficie relativa de la hoja de malas hierbas como área foliar de malezas, el área foliar total de cultivo y las malezas (Pérez *et al.*, 2000). Algunos métodos de clasificación para la distinción de diferentes especies de malezas han hecho uso extensivo de modelos activos de formas (ASMs) para la segmentación automática del contorno de uno o varios objeto de la imagen (Persson *et al.*, 2008; Sjøgaard, 2005).

Estudios realizados para la Universidad Católica de Lovaina permitieron identificar diferentes especies de maleza por las características de sus respectivos espectros de reflexión (Feyaerts F. y van Gool. 2001); sin embargo, sólo eran posibles bajo condiciones de laboratorio, pero no para la identificación en el campo o en tiempo real.

El uso de la espectroscopia en la cosecha y discriminación de malezas ha resultado ser un método novedoso para el tratamiento de este problema, pero elevadamente costoso para trabajos en el campo, siendo poco usado para procesamiento en tiempo real por su alta complejidad computacional. Borregaard *et al.* (2000) hace uso de este método y de técnicas multivariantes para la identificación de especies de maleza de acuerdo a sus diferentes longitudes de onda. Un estudio reciente en el área es el de Piron *et al.* (2008), quienes realizan un estudio para selección de la mejor combinación de filtros que permita detectar diferentes especies de malezas ubicadas dentro de filas de cultivos de zanahoria, la mejor tasa de clasificación fue del 72%, pero sus estudios están limitados a condiciones de laboratorio con imágenes tomadas bajo luz artificial.

Aitkenhead *et al.* (2003) y Kavdir (2004) emplearon métodos de análisis de imágenes para reconocer y diferenciar entre plántulas de cultivos y malezas, mediante un análisis y medición de la forma de la hoja (perímetro/área); así como el uso de métodos de

inteligencia artificial basados en redes neuronales para la diferenciación de especies de malezas con una precisión superior al 75%. Finalmente, la transformada Wavelet también ha sido utilizada con fines de detección y clasificación de malezas en trabajos presentados por Ishak *et al.* (2009), Bossu *et al.* (2009) y Kiani *et al.* (2010), mostrando que es un método eficiente para la discriminación de malezas en fotografías tomadas a diferentes perspectivas, pero con un elevado costo computacional en comparación con las metodologías basadas en técnicas puras de procesamiento digital de imágenes.

2.2 Fundamentación teórica

2.2.1 Análisis de texturas

El análisis de texturas está basado en el empleo de diversos métodos estadísticos, de filtrado, de transformadas, etc. para calcular índices cuantitativos que describan la distribución de niveles de gris o niveles digitales en una imagen, proporcionando información útil para cualquier tarea posterior de clasificación, segmentación, recuperación de imágenes en bases de datos, síntesis de texturas, etc.

Con el objeto de entender en que consiste un análisis de textura es necesario aclarar que se entiende por este término, aunque se pueden presentar diferencias sutiles en su definición en función del campo de estudio específico, en el tratamiento de imágenes son muchas las definiciones adoptadas siendo muy coincidentes en la idea a expresar. Algunas de las más comunes son:

- Textura es un atributo que presenta la distribución espacial de los niveles de gris de una determinada región (IEEE Std. 610.41990).
- El término textura se refiere, en general, a la repetición de elementos básicos llamados texels. Cada texel contiene varios píxeles, cuya ubicación puede ser periódica, quasi-periodica o aleatoria. Las texturas naturales son generalmente aleatorias, mientras que las artificiales son a menudo deterministas o periódicas.

Una textura puede ser gruesa, fina, suave, granulada, rugosa, regular, irregular, lineal, etc. (Jain, 1989).

- El concepto textura se refiere a la distribución espacial de las variaciones de niveles de gris o de colores en una imagen (Shatadal *et al.*, 1991).
- De manera intuitiva, puede decirse que es un descriptor que da una medida de las propiedades tales como suavidad, rugosidad y regularidad (González y Woods, 2008).

2.2.1.1 Métodos de caracterización de texturas

En procesamiento digital de imágenes, existen tres enfoques principales usados para el análisis de texturas, estos son: estadística, estructural y espectral (Umarani, 2008). La formulación estadística indica si una imagen es suave o burda conforme a sus niveles de gris; la técnica estructural, por otro lado, muestra que arreglos primitivos existen en la imagen; y la técnica espectral está basada sobre las propiedades de Fourier y Wavelet, es usada, principalmente, para detectar periodicidad global en la imagen, identificando pequeños picos de alta energía en su espectro. Estas técnicas pueden usarse por separado o apoyarse unas a otras. En el presente trabajo, se hace uso de las técnicas estadísticas y espectrales para la detección de texturas.

Uno de los principales y recientes desarrollos en la segmentación por textura ha sido el uso de descriptores multiresolución y multicanal. Estos descriptores proveen información acerca del contenido de la imagen en regiones cada vez más pequeñas en el dominio de la frecuencia, y por lo tanto, proporcionan una poderosa herramienta para la discriminación de texturas similares (Manian y Vasquez, 1998). Las texturas presentes en una imagen dependen de dos características importantes. La primera es la distancia a la cual la imagen es adquirida; la segunda es la geometría del objeto, puesto que bajo diferentes escalas y entornos de iluminación las texturas obtenidas son diferentes (Méndez, 2010).

Enfoque estadístico para descripción de texturas

Uno de los enfoques más sencillos para describir la textura es el uso de momentos estadísticos del histograma de niveles de grises de una imagen o región. Este método se basa en el cálculo de descriptores de la distribución de intensidad en la imagen, los cuales son casi constante para cada textura. Estos descriptores estadísticos miden variaciones de niveles de gris en un vecindario y pueden ser de primer, segundo y tercer orden:

- Primer orden: las medidas texturales de primer orden son calculadas a partir de los valores de gris originales de la imagen y su frecuencia, como la media, varianza, desviación estándar. En estas medidas no se considera la relación entre los píxeles.
- Segundo orden: son las medidas que consideran la relación de co-ocurrencia entre grupos de dos píxeles de la imagen original y a una distancia dada.
- Tercer y más orden: se consideran las relaciones entre 3 o más píxeles.

Enfoque espectral de la descripción de texturas

Los modelos espectrales o de frecuencia consisten en obtener la transformada en frecuencia de la imagen y a partir de ésta, obtener ciertas características. Los métodos más comunes son:

- Transformada de Fourier, basado en el análisis del dominio de la frecuencia. Su implementación se ve restringida por la poca información que se puede extraer cuando las texturas son heterogéneas o de carácter aleatorio ya que realiza una descomposición de las señales en sus componentes espectrales, pero sin facilitar información temporal de éstas.
- Filtros Gabor, partiendo de la transformada de Fourier por ventana, cuando la ventana es una gaussiana.
- Transformada Wavelet, que permite analizar la frecuencia de una imagen en función de la escala (análisis multi-resolución).

2.2.2 Transformada Wavelet

La transformada wavelet es la base para cortar datos o funciones en diferentes componentes de frecuencia y estudiar cada uno de esos componentes con una resolución ajustada a su escala (Daubechies, 1992). Se define como:

$$CWT_f^\varphi(\tau, s) = \frac{1}{\sqrt{s}} \int_t^\infty f(t) \varphi^* \left(\frac{t-\tau}{s} \right) dt \quad (2.01)$$

Donde:

τ	Parámetro de traslación.
f	Señal de entrada.
s	Parámetro de escala (1/frecuencia).
φ^*	Función wavelet.

La transformada Wavelet se basa en pequeñas ondas llamadas wavelets, generadas a partir de la traslación y escalado de una función Wavelet básica, la wavelet madre. Es decir, la idea básica de las Wavelets es ofrecer un elemento básico (la función "Wavelet madre") cuya convolución a diferentes escalas, con la señal original permite obtener una expresión de dicha señal en función de la Wavelet madre escogida. Además, estas funciones permiten reconstruir la señal original a través de la transformada Wavelet inversa. Las principales funciones Wavelet son: Wavelet Haar, Wavelet Daubechies y Wavelet Coiflet.

Una cualidad muy importante de las funciones wavelet es la de poder analizar una señal a diversas escalas. En el análisis wavelet, la escala juega un papel muy importante, ya que los diversos algoritmos procesan los datos en diferentes escalas y resoluciones espaciales. Si se observa una señal a una escala pequeña (alta frecuencia) se apreciarán únicamente aquellas entidades de mayores dimensiones. De igual manera, si se observa la misma señal a una escala grande (baja frecuencia) se podrán distinguir pequeños elementos o partes de la señal. Por ello, la idea básica de la transformada wavelet es

representar cualquier función arbitraria como una superposición de ondas wavelet escaladas y trasladadas.

Generalmente, hay dos tipos de descomposiciones Wavelet nombradas: Transformada Wavelet Discreta (TWD) y Transformada Wavelet Estacionaria (TWS). La TWD es variante al cambio, es decir, el comportamiento de los coeficientes de la transformada es impredecible bajo cambios de la señal de entrada. Este es consecuencia de la operación de sub-muestreo, debido a que muchas muestras son eliminadas durante cada cambio de escala, y por lo tanto los detalles en los patrones también son perdidos. Este problema ha sido tratado, introduciendo a la transformada una gran cantidad de redundancia hasta hacerla invariante, como es el caso de la TWS (Gnanadurai *et al.*, 2009). En el presente trabajo, se usa la TWS por las siguientes razones:

- La variación de cambio de la transformada wavelet es considerada el principal inconveniente para la aplicación de análisis de textura.
- A pesar de que la TWS requiere más cálculo y mayor memoria, permite mejorar la eliminación del ruido y la capacidad de detección de bordes, siendo más susceptible para el análisis textural.
- El proceso de sub-muestreo de la TWD provoca que el número de coeficientes sea reducido a la mitad en los subsecuentes niveles de descomposición, lo cual la hace solo adecuada para la implementación de señales discretas o imágenes cuyo tamaño sea potencia de dos, a diferencia de la TWS que puede ser implementada para cualquier tamaño de imágenes, ya que el sub-muestreo no es aplicado, con el fin de mantener el mismo número de coeficientes en todos los niveles de resolución.

2.2.2.1 Transformada Wavelet Estacionaria 2D

La transformada wavelet estacionaria (TWS) fue propuesta por Nason y Silverman (1994), la cual es redundante, invariante a la traslación y da una aproximación más densa a la transformada wavelet continua que la transformada wavelet ortogonal.

La implementación de la TWS en imágenes se puede llevar a cabo mediante el uso de filtros (Mallat, 1989), donde el filtrado de bajas frecuencias suaviza la imagen, mientras que el de altas frecuencias extrae los bordes. Este algoritmo se puede visualizar en la Figura 2.01, donde $H^{[r]}$ es el filtro pasa bajas y $G^{[r]}$ es el filtro pasa altas para cada nivel de descomposición r .

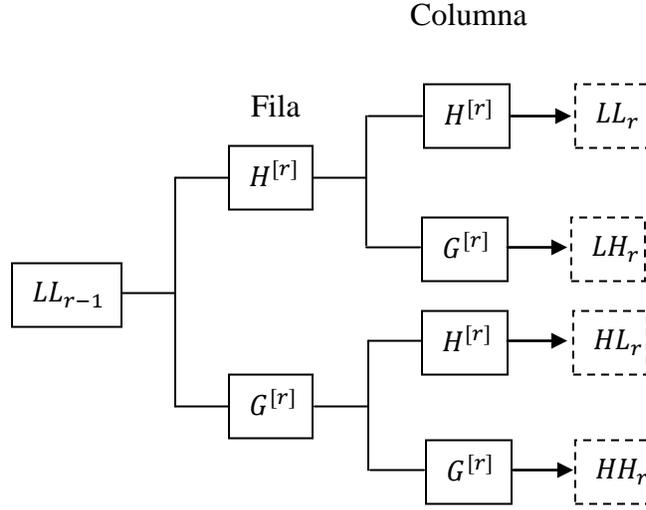


Figura 2.01. Estructura de banco de filtros de la TWS.

El filtro $H^{[r]}$ es obtenido insertando un cero entre cada par adyacente de elementos del filtro $H^{[r-1]}$, análogo para $G^{[r]}$ (Gao *et al.*, 2008). Esto se describe en la siguiente ecuación:

$$H_{2j}^{[r]} = H_j^{[r-1]} \quad H_{2j+1}^{[r]} = 0 \quad (2.02)$$

$$G_{2j}^{[r]} = G_j^{[r-1]} \quad G_{2j+1}^{[r]} = 0$$

Sea $H^{[0]} = H$, $G^{[0]} = G$ y $a_0 = f_k$, la SWT de una imagen f_k se define en la Ecuación 2.03. Donde a_r es la sub-banda de aproximación, b_r^h , b_r^v y b_r^d son las sub-bandas de detalles horizontales, verticales y diagonales, respectivamente.

$$a_{r+1} = \left[H_x^{[r]} \left[H_y^{[r]} a_r \right] \right] \quad (2.03)$$

$$b_{r+1}^h = \left[H_x^{[r]} \left[G_y^{[r]} a_r \right] \right]$$

$$b_{r+1}^v = \left[G_x^{[r]} \left[H_y^{[r]} a_r \right] \right]$$

$$b_{r+1}^d = \left[H_x^{[r]} \left[G_y^{[r]} a_r \right] \right]$$

Por lo tanto, la imagen de estrada es descompuesta en cuatro sub-bandas, descritas a continuación:

- Aproximación (LL_r) se construye pasando un filtro pasa bajas a lo largo de las filas y de las columnas, es una versión de menor resolución y con menos detalle que LL_{r-1} .
- Detalles horizontales (LH_r) se obtienen filtrando un pasa bajas a lo largo de las filas y un pasa alta sobre las columnas. Se suavizan los detalles en el sentido horizontal, mientras que se resaltan las variaciones en el vertical, enfatizando las líneas y bordes horizontales de la imagen.
- Detalles verticales (HL_r) se han creado filtrando un pasa altas a lo largo de las filas y un pasa bajas sobre las columnas. Se suavizan los detalles en el sentido vertical, mientras que se resaltan las variaciones en el horizontal, así esta imagen destaca las líneas y bordes verticales.
- Detalles diagonales (HH_r) son el resultado de filtrar un pasa altas tanto en las filas como en las columnas. Tiende a borrar los bordes horizontales y verticales, y a acentuar los diagonales.

2.2.3 Métodos de selección de características

La selección de características consiste en obtener un subconjunto de d características a partir de un conjunto inicial D , tal que $d < D$, sin degradar significativamente el rendimiento del sistema (Pudil *et al.*, 1944).

Existen diferentes métodos de selección, formados comúnmente por los siguientes elementos (Estévez, 1999):

- Un criterio de evaluación j para comparar el poder de clasificación de los distintos subconjuntos de características.
- Un procedimiento de búsqueda (algoritmo).
- Un criterio de detención, típicamente un umbral de significancia o la dimensión deseado del espacio final de características.

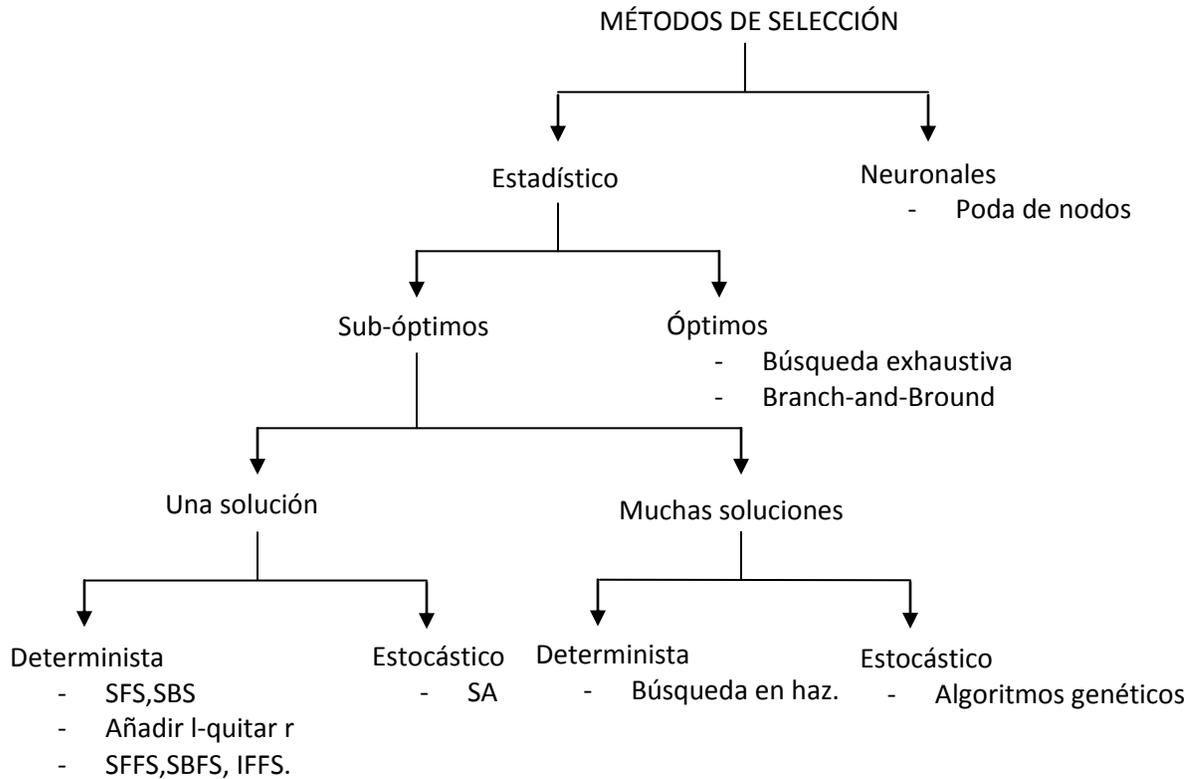


Figura 2.02. Métodos de selección de características.

En la Figura 2.02 se presenta una taxonomía de métodos de selección de características (Jain, 1997) en donde se comienza haciendo una primera división entre los métodos de selección de características basados en la teoría estadística de reconocimiento de patrones y aquellos basados en redes neuronales. Los métodos estadísticos a su vez se dividen entre métodos óptimos y sub-óptimos, llamado así por alcanzar soluciones óptimas o sub-óptimas, respectivamente. Los métodos sub-óptimos pueden ser de solución única o

de múltiple soluciones; los primeros mantienen y modifican únicamente un subconjunto de características, y los segundos mantienen una población de subconjuntos. Por último, los métodos de solución única o solución múltiple se subdividen en métodos determinísticos y estocásticos. Los métodos determinísticos son aquellos en los que siempre se obtiene el mismo subconjunto para un problema dado, y los estocásticos son aquellos en los que se introduce algún elemento aleatorio, mediante el cual se obtienen diferentes subconjuntos en cada ejecución.

2.2.3.1 Métodos óptimos

Dentro de los algoritmos más utilizados para obtener un subconjunto óptimo de características se encuentra la *búsqueda exhaustiva* y el *branch and bound*, característicos por su elevado costo computacional.

La *búsqueda exhaustiva* realiza un estudio de todas las posibles combinaciones de características, evaluando $\frac{n!}{d!(n-d)!}$ subconjuntos, donde d es el tamaño del subconjunto deseado y n el número de características del conjunto original. El número de posibilidades crece exponencialmente, haciendo impráctica la búsqueda aun para valores moderados de n .

El *branch-and-bound* es un algoritmo más rápido que la *búsqueda exhaustiva*, ya que no evalúa todos los posibles subconjuntos de características, pero debe cumplir con una condición: la función de selección de característica J debe ser monótona, es decir al añadir una nueva característica al subconjunto, el valor de J no debe disminuir. Esto lo hace susceptible a presentar la maldición de la dimensionalidad, donde para tamaños pequeños de muestra, el resultado del clasificador mejora al agregar nuevas características hasta alcanzar un máximo, para luego decaer, dejando de cumplir con la condición de monotonocidad (Fernández, 2005).

2.2.3.2 Métodos sub-óptimos con una solución

Estos métodos inician con un conjunto inicial de características que se modifica de forma iterativa hasta llegar a un determinado criterio de parada, el subconjunto que alcance este criterio, será el conjunto seleccionado.

Dentro de los algoritmos determinísticos existen dos categorías: (1) los métodos SFS (*Sequential Forward Selection*) que parten de la mejor característica individual (con mayor grado discriminativo) y va añadiendo una característica en cada iteración, y (2) los métodos SBS (*Sequential Backward Selection*) que comienzan con el conjunto completo de características y van eliminando una característica por iteración. Estos métodos presentan el inconveniente de que las características seleccionadas como es el caso del SFS, ya no pueden ser descartadas; y en el de las características descartadas, como es el caso del SBS, ya no pueden ser seleccionadas; además Cover y Van Campenhout (1977) demostraron que el mejor subconjunto de m características no necesariamente está compuesto por las m mejores características individuales. Una solución a esto son los algoritmos flotantes que trabajan de forma muy similar a los anteriores, sólo que al incluir nuevas características, por medio de un procedimiento secuencial hacia delante como en el caso del SFBS (*Sequential Floating Forward Selection*), estos son seguidos por una serie de eliminaciones condicionales de la característica con menor grado discriminativo en el nuevo subconjunto seleccionado. El algoritmo análogo, pero con búsqueda hacia atrás se denomina SBFS (*Sequential Floating Backward Selection*) (Fernández, 2005).

2.2.3.3 Métodos de redes neuronales

El método de poda de nodos es un ejemplo de estos algoritmos, que se basan en el uso de redes neuronales para realizar al mismo tiempo la selección de características y la clasificación, se caracterizan por su elevado costo computacional. Este método elimina los nodos menos importantes para reducir su complejidad. Cuando se elimina un nodo lo que se está haciendo es eliminar la característica correspondiente. El algoritmo entrena la red y

después elimina el nodo saliente. Esto se repite hasta que se alcanza un compromiso deseado entre error de clasificación y complejidad de la red (Fernández, 2005).

2.2.4 Algoritmo de búsqueda IFFS

El algoritmo IFFS (*Improved Forward Floating Selection*) es una mejora del algoritmo de búsqueda SFFS debido a que incluye una etapa de búsqueda adicional para comprobar si la eliminación de alguna característica del subconjunto actual y la adición de una nueva al conjunto resultante, permite mejorar el conjunto de características. El algoritmo IFFS muestra mejores soluciones que el SFFS, ya que realiza búsquedas mas exhaustivas (Nakariyakul y Casasent, 2009).

A continuación, se muestra un pseudocódigo para el algoritmo IFFS, donde: Y es el conjunto de D características totales, SET el conjunto de características actuales siendo evaluado, k el numero de características en SET , X_k el conjunto de k características escogidas por el algoritmo IFFS, J_k el valor de la función de evaluación J de X_k y d el número de características deseado.

- 1) Inicialización: SET $k = 0$, $SET = \emptyset$ (conjunto vacio), y $J_k = 0$ para $1 \leq k \leq D$.
- 2) Añadir característica: usar el método SFS para adjuntar una característica a SET e incrementar $k = k + 1$. Si $k = d + \Delta$ el algoritmo termina, en caso contrario, se calcula J para un nuevo SET . Si $J(SET) > J_k$, actualizar $X_k = SET$ y $J_k = J(SET)$, en caso contrario $SET = X_k$.
- 3) Retroalimentación: eliminar la característica menos significativa x_j en SET , es decir, una característica tal que $J(SET \setminus x_j) = \max_{1 \leq i \leq k} J(SET \setminus x_i)$. Esto significa que al remover x_j de SET da un mayor valor para J que cualquier de los subconjuntos resultantes de $k - 1$ características. Si $J(SET \setminus x_j) > J_{k-1}$ decrece $k = k - 1$ y se activa $SET = SET \setminus x_j$, $X_k = SET$, $J_k = J(SET)$ y se repite el paso 3, en caso contrario ir al paso 4.

- 4) Eliminar la característica débil: crear un nuevo subconjunto de k características SET'_i para $1 \leq i \leq k$. SET'_i se encuentra, primero, removiendo el i -ésimo elemento en SET y después usando el método SFS adjuntar una nueva característica a cada uno de los subconjuntos resultantes. Entre estos SET'_i , encontrar el que contenga el mayor valor de J , llamarlo SET'_s , es decir, $J(SET'_s) = \max_{1 \leq i \leq k} J(SET'_i)$. Si $J(SET'_s) > J_k$ activar $J_k = J(SET'_s)$ y $SET = SET'_s$ e ir al paso 3 en caso contrario ir al paso 2.

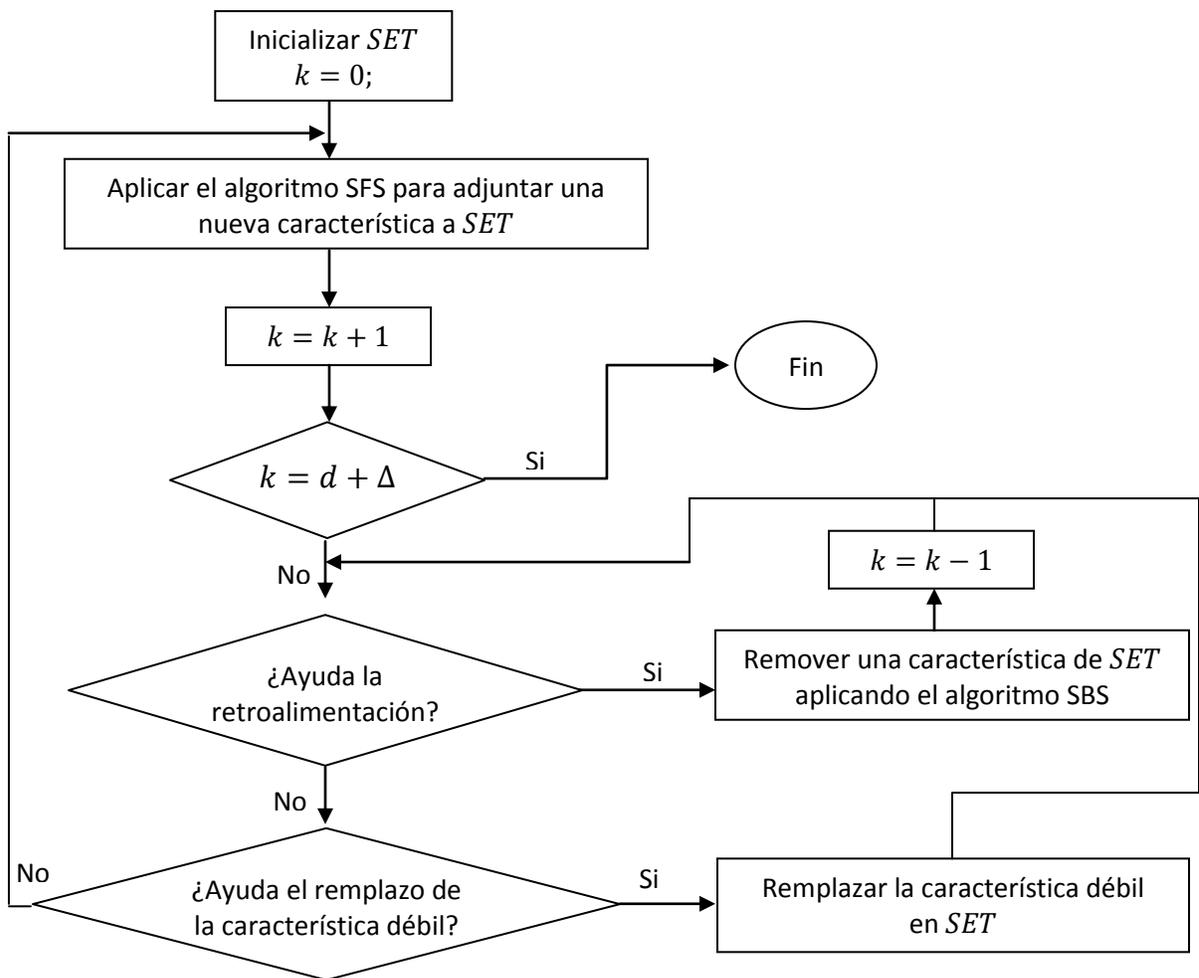


Figura 2.03. Diagrama de flujo del algoritmo IFFS.

2.2.5 Detección de transiciones

Una técnica muy común para detectar bordes es el empleo de operadores locales basados en la primera derivada o gradiente. En el caso de funciones bidimensionales discretas como $f(x,y)$, las distintas derivadas del operador gradiente se basan en diferencias entre los niveles de grises de la imagen. Las derivadas parciales $f_x(x,y)$ (gradiente fila) y $f_y(x,y)$ (gradiente columna) pueden aproximarse por la diferencia de píxeles adyacentes de la misma fila y columna, respectivamente (Ecuación 2.04).

$$G_F = \frac{\partial f(x,y)}{\partial x} \approx \nabla_x f(x,y) = f(x,y) - f(x-1,y) \quad (2.04)$$

$$G_C = \frac{\partial f(x,y)}{\partial y} \approx \nabla_y f(x,y) = f(x,y) - f(x,y-1)$$

El gradiente de la fila G_F y de la columna G_C en cada punto se obtiene mediante la convolución de la imagen con las máscaras H_F y H_C , esto es:

$$G_F(i,j) = F(i,j) * H_F(i,j) \quad (2.05)$$

$$G_C(i,j) = F(i,j) * H_C(i,j)$$

Donde F representa la imagen de entrada, H_F y H_C las máscaras del operador gradiente para filas y columnas, respectivamente. Los operadores más utilizados son: Prewitt, Sobel, Roberts, Frei-Chen. Operador Prewitt involucra a los vecinos de filas/columnas adyacentes para proporcionar mayor inmunidad al ruido, se define con las siguientes máscaras de convolución:

(a)	<table style="border-collapse: collapse; text-align: center;"> <tr><td style="border: 1px solid black; padding: 2px 10px;">1</td><td style="border: 1px solid black; padding: 2px 10px;">0</td><td style="border: 1px solid black; padding: 2px 10px;">-1</td></tr> <tr><td style="border: 1px solid black; padding: 2px 10px;">1</td><td style="border: 1px solid black; padding: 2px 10px;">0</td><td style="border: 1px solid black; padding: 2px 10px;">-1</td></tr> <tr><td style="border: 1px solid black; padding: 2px 10px;">1</td><td style="border: 1px solid black; padding: 2px 10px;">0</td><td style="border: 1px solid black; padding: 2px 10px;">-1</td></tr> </table>	1	0	-1	1	0	-1	1	0	-1
1	0	-1								
1	0	-1								
1	0	-1								

(b)	<table style="border-collapse: collapse; text-align: center;"> <tr><td style="border: 1px solid black; padding: 2px 10px;">-1</td><td style="border: 1px solid black; padding: 2px 10px;">-1</td><td style="border: 1px solid black; padding: 2px 10px;">-1</td></tr> <tr><td style="border: 1px solid black; padding: 2px 10px;">0</td><td style="border: 1px solid black; padding: 2px 10px;">0</td><td style="border: 1px solid black; padding: 2px 10px;">0</td></tr> <tr><td style="border: 1px solid black; padding: 2px 10px;">1</td><td style="border: 1px solid black; padding: 2px 10px;">1</td><td style="border: 1px solid black; padding: 2px 10px;">1</td></tr> </table>	-1	-1	-1	0	0	0	1	1	1
-1	-1	-1								
0	0	0								
1	1	1								

Figura 2.04. (a) Gradiente fila y (b) gradiente columna.

2.2.6 Binarización

La binarización de una imagen digital consiste en convertir la imagen digital en una imagen en blanco y negro, de tal manera que se preserven las propiedades esenciales de la imagen. Uno de los métodos para poder binarizar una imagen digital es mediante el histograma de dicha imagen. A través del histograma se obtiene una gráfica donde se muestran el número de píxeles por cada nivel de gris que aparecen en la imagen. Para binarizar la imagen (im), se debe elegir un valor adecuado dentro de los niveles de grises ($umbral$), de tal forma que el histograma forme un valle en ese nivel. Todos los niveles de grises menores al umbral calculado se convertirán en negro y todos los mayores en blanco.

$$bin(i, j) = \begin{cases} 255, & \text{si } im(i, j) > umbral \\ 0, & \text{si } im(i, j) \leq umbral \end{cases} \quad (2.06)$$

2.2.7 Adelgazamiento

El procedimiento de adelgazamiento consiste en ir borrando sucesivamente los puntos del borde de cada componente conexa, de forma que se preserve su topología (González y Woods, 2008).

Las condiciones exactas que determinan si un punto se puede borrar están relacionadas con el concepto de punto simple (un píxel negro P del borde de la imagen se considera simple si el conjunto de los vecinos en negro de P tienen exactamente una componente conexa que es adyacente a P) y punto final (un punto es final si tiene exactamente un vecino negro; un punto final no es más que un punto extremo de la imagen); es decir, un punto del borde de cada componente se puede eliminar si es simple y no es final.

El adelgazamiento de un conjunto A mediante un elemento estructural B , denotado como $A \otimes B$, se puede definir de manera general en término de la transformada hit-or-miss (\odot):

$$\begin{aligned}
A \otimes B &= A - (A \circledast B) \\
&= A \cap (A \circledast B)^c
\end{aligned}
\tag{2.07}$$

Debido a que este algoritmo solo relaciona un patrón con el elemento estructural, la operación denominada *background* no es requerida en la transformada hit-or-miss, de tal manera que una expresión más útil para el adelgazamiento de A está basada en una secuencia de elementos estructurales $\{B\}$.

$$\{B\} = \{B^1, B^2, B^3, \dots, B^n\} \tag{2.08}$$

Donde B^n es una versión rotada de B^{n-1} . Usando este concepto el adelgazamiento se define ahora como:

$$A \otimes \{B\} = ((\dots((A \otimes B^1) \otimes B^2) \dots) \otimes B^n) \tag{2.09}$$

El proceso consiste en adelgazar A con el paso de B^1 , después adelgazar el resultado con el paso de B^2 , así sucesivamente, hasta que A es adelgazada con B^n . El proceso entero es repetido hasta que no ocurran cambios. Cada paso de adelgazamiento individual es realizado por la ecuación 2.07.

2.2.8 Cierre de contornos

Una de las técnicas para el cierre de contornos consiste en analizar las características de los pixeles en un pequeño entorno alrededor de cada punto de la imagen que ha sido etiquetado como punto de contorno. Todos los puntos que son similares de acuerdo con un conjunto de criterios predefinidos son unidos, formando un contorno de pixeles que comparten este criterio. Las dos principales propiedades usadas para establecer estas similitudes de puntos de contornos son:

1. La magnitud de la respuesta del operador de gradiente utilizado para producir el pixel del contorno.

2. La dirección del vector gradiente.

Entonces para cada punto de coordenadas (i, j) se considera una ventana centrada en el punto. Si en la ventana ya hay un punto de contorno (i', j') tal que ambos tienen magnitudes y direcciones similares de gradiente, entonces (i, j) es etiquetado también como punto de contorno. Este proceso se repite para cada pixel de la imagen. Se debe llevar un registro de los nuevos puntos de contorno a medida que se va moviendo el centro de la ventana de pixel a pixel, asignando un nivel de gris diferente al de los puntos de contornos iniciales.

2.2.9 Etiquetado de regiones

Un operador de etiquetado puede ser empleado para agrupar un pixel binario de valor uno a una región con conectividad de 4 u 8 vecinos (Figura 2.05). La vecindad V4 considera los pixeles que se encuentran arriba, abajo, izquierda y derecha del pixel a etiquetar; la vecindad V8 de un pixel considera los 8 pixeles a su alrededor.

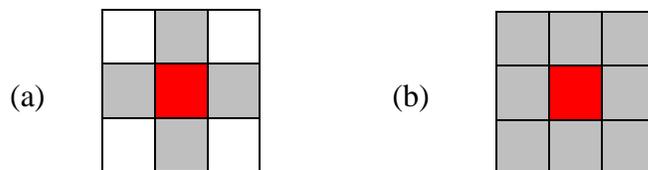


Figura 2.05. (a) Vecindad V4 y (b) V8.

La definición de esta técnica es, dos pixeles p y q de valor X pertenecen a la misma componente de conectividad C , si hay una secuencia de pixeles (p_0, p_1, \dots, p_n) de valor X en C , donde $p_0 = p$, $p_n = q$, y p_i es un vecino de p_{i-1} para $i = 1, \dots, n$.

La entrada del algoritmo es una imagen binaria y su salida es una imagen, en la cual, la etiqueta asignada a cada pixel es un entero único que identifica la conexión a la cual pertenece éste (Haralick y Shapiro, 1992).

2.2.10 Redes neuronales

Las Redes Neuronales Artificiales (RNAs) son un paradigma de aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso de los animales; compuestas por un gran número de elementos básicos (neuronas), agrupados en capas y que se encuentran altamente interconectados. Las RNAs son utilizadas para la predicción, la minería de datos, el reconocimiento de patrones y los sistemas de control adaptativo. Constituyen una parte muy importante en el estudio y desarrollo de la inteligencia artificial.

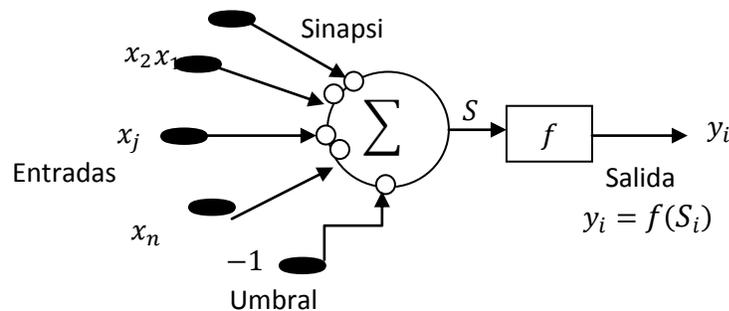


Figura 2.06. Modelo de una neurona estándar.

La estructura de una RNA posee varias entradas y salidas, las cuales serán entrenadas para reaccionar, de una manera deseada, a los estímulos de entrada. Estas salidas vienen dadas por tres funciones:

1. Función o regla de propagación (S_i): consiste en el sumatorio de cada entrada multiplicada por el peso de su interconexión ó peso sináptico (W_{ij}). A menudo a la suma se le resta un umbral θ_i .

$$S_i = \sum_{j=1}^n W_{ij}x_j - \theta_i \quad (2.09)$$

2. Función de transferencia o activación (f): Consiste en la evaluación de S_i con una función identidad, escalón, gaussiana, sinusoidal, sigmoidea, etc.

$$f(S_i) = f(\sum_{j=1}^n W_{ij}x_j - \theta_i) \quad (2.11)$$

3. Función de salida (y_i) : se aplica al valor devuelto por la función de activación. Se utiliza para acotar la salida de la neurona y generalmente viene dada por la interpretación que queramos darle a dichas salidas. Algunas de las más utilizadas son la función sigmoidea, identidad y tangente hiperbólica.

$$y_i = f(S_i) \quad (2.12)$$

Una RNA puede estar formada por diferentes capas, entendiendo como capa, un conjunto de neuronas cuyas entradas provienen de una dirección y sus salidas terminan en otra dirección. Aquí se pueden distinguir tres tipos de capas, la capa de entrada que solamente retiene los valores de entrada; la o las capas ocultas, que determinan el tipo de topología de la red de acuerdo a su número y tipo de conexiones; y la capa que proporciona la salida de la red.

El entrenamiento es una de las herramientas que las RNAs nos proporcionan para agilizar el aprendizaje. Este proceso consiste en ir ajustando los pesos (w_{ij}) gradualmente hasta que el vector de salida resultante coincida con el vector de salida deseado. Existen las siguientes clases de aprendizaje: supervisado, no supervisado, híbrido, reforzado (Martin B. y Sanz M., 2007).

Existen diferentes RNAs clasificadas de acuerdo a la conexión que existe entre sus capas. Usualmente, las capas están establecidas por el orden en que reciben la señal desde la entrada hasta la salida y están unidas en esa dirección, este tipo de conexiones se denominan conexiones hacia delante. Por el contrario, existen algunas redes en que las capas aparte del orden normal algunas capas están también unidas desde la salida hasta la entrada en el orden inverso en que viajan las señales de información, las conexiones de este tipo se llaman conexiones hacia atrás ó retroalimentadas. Algunos ejemplos de RNAs son: Perceptrón, Adaline, Madaline, Backpropagation y Kohonen, (tipo conexión hacia delante), ART, BAM y Cognitron (tipo retroalimentada).

2.2.10.1 Perceptrón

El perceptrón simple es red neuronal artificial de aprendizaje supervisado y unidireccional, inventada por el psicólogo Frank Rosenblatt en el año 1957. Está formado por dos capas, una de entrada con un número de nodos determinado y una de salida con un sólo nodo el cuál se encuentra conectado a cada uno de los nodos de la capa de entrada mediante una conexión que está valuada con un peso.

Existe un nodo extra llamado bias, el cual no tiene contacto con el exterior y su valor siempre es 1. Si se añade capas intermedias (ocultas) a un perceptrón simple, se obtiene un perceptrón multicapa o MLP. Esta arquitectura suele entrenarse mediante el algoritmo denominado retro propagación de errores o BP (Martin B. y Sanz M., 2007).

Al ser el perceptrón una red supervisada, esta debe ser entrenada con un conjunto de patrones previamente clasificados de manera que, si los clasifica incorrectamente, se pueda corregir el error mediante una regla de aprendizaje. En general, para entrenar la red, necesitaremos un conjunto de patrones previamente clasificados llamado muestra de entrenamiento y un conjunto de patrones llamado muestra de control con el que se probará el poder de generalización de nuestra red.

El entrenamiento se da en iteraciones; una iteración comienza cuando se le presenta el primer patrón de la muestra de entrenamiento y finaliza cuando se le muestra el último patrón de la muestra de entrenamiento. En cada iteración, se presentan uno por uno los patrones de la muestra de entrenamiento a la red y, si lo clasifica bien, se prosigue con el siguiente patrón pero si lo clasifica mal, se corrigen los pesos mediante la regla de aprendizaje y se sigue con el siguiente patrón utilizando los nuevos pesos. El entrenamiento concluye cuando pasa una iteración en la que clasificó correctamente todos los patrones, o bien, se alcanza un límite de iteraciones previamente definido por el experto.

III. METODOLOGÍA

En este capítulo, se describen los materiales y métodos empleados para el desarrollo del presente trabajo, con objeto de dar una solución a la problemática expuesta.

Materiales de trabajo

Para la elaboración de presente trabajo, se utilizó:

- Base de datos formada por 200 imágenes de cultivos de maíz.
- Cámara digital de 14 megapíxeles.
- Laptop con procesador Intel Core i5 y 4 GB de memoria RAM.
- Matlab v2010a (Matrix Laboratory).

Método de trabajo

La metodología tiene como objetivo la realización y evaluación de un algoritmo de visión artificial destinado a la discriminación de malas hierbas presentes en cultivos de maíz, misma que se encuentra formada por las siguientes etapas:

- (1) Adquisición de imágenes.
- (2) Creación de base de datos.
- (3) Segmentación de la vegetación.
- (4) Segmentación del cultivo y la maleza.
- (5) Evaluación de resultados.

A continuación, se muestra una descripción detallada de la metodología empleada para cada una de las etapas mencionadas. El esquema general de este capítulo se observa en la Figura 3.01.

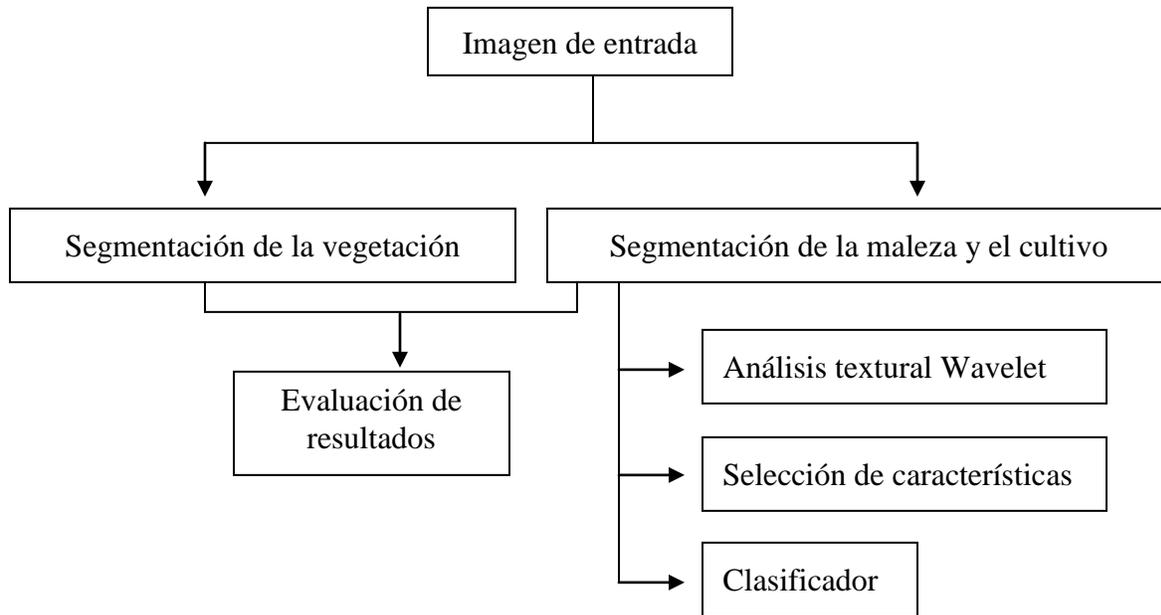


Figura 3.01. Esquema general del capítulo.

3.1 Adquisición de imágenes

Doscientas imágenes de plantaciones de maíz fueron tomadas durante el período crítico de competencia del cultivo, a una distancia de 1 metro de altura, con un enfoque superficial y bajo condiciones naturales de iluminación; de las cuales, 100 se emplearon para el entrenamiento del sistema y el resto para la evaluación del mismo. Las imágenes fueron adquiridas con una resolución de 4320 x 3240 píxeles, y escaladas a 2160 x 1620 píxeles.

3.2 Creación de base de datos

Se realizó una selección y recorte manual de áreas de interés (maleza, cultivo) de las 100 imágenes destinadas para el entrenamiento del sistema, con el objetivo de generar 20,000 patrones de 32x32 píxeles, de los cuales, 10,000 son representativas de hojas de

maleza y el resto de hojas de maíz. Los patrones se obtuvieron de manera manual mediante un algoritmo implementado en Matlab.

El tamaño de las muestras se eligió a partir de un análisis de separabilidad estadística, con el fin de determinar si las clases son lo suficientemente diferentes entre ellas, o por lo contrario, son muy homogéneas. La divergencia transformada (DT) es una distancia estadística que permite calcular la separabilidad entre dos clases o áreas de entrenamiento, y se define por Swain y Davis (1978), como:

$$D = \frac{1}{2} tr \left((c_i - c_j)(c_j^{-1} - c_i^{-1}) \right) + \frac{1}{2} tr \left((c_i^{-1} - c_j^{-1})(\mu_i - \mu_j)(\mu_i - \mu_j)^T \right) \quad (3.01)$$

$$DT = 2(1 - e^{-D/8})$$

Donde:

- i, j Clase a comparar.
- c Matriz de covarianza.
- μ Vector media.
- tr Función traza.
- T Función transpuesta.

Estas distancias presentan valores comprendidos entre 0 y 2000 unidades (los valores representan magnitudes adimensionales), donde a mayor valor, mejor separabilidad estadística entre clases. Se tendrán un valor bajo para clases próximas (poco separables) y uno alto para las clases aisladas (muy separables). Jensen (1996) mostró que la divergencia transformada con valor de 2000 proporciona una excelente separación, uno de 1900 provee una buena separación, mientras que un valor menor a 1700 indica una separación pobre entre clases.

Para este estudio, se crearon nueve conjuntos concéntricos de 200 muestras, cada uno representa una máscara cuadrada de 8, 12, 16, 20, 24, 28, 32, 36 y 40 píxeles. Los resultados mostraron una tasa de separabilidad favorable para el conjunto de muestra de 32 x 32 píxeles (Figura 3.02), los cuales fueron almacenados en una *biblioteca de clases* para su posterior análisis.

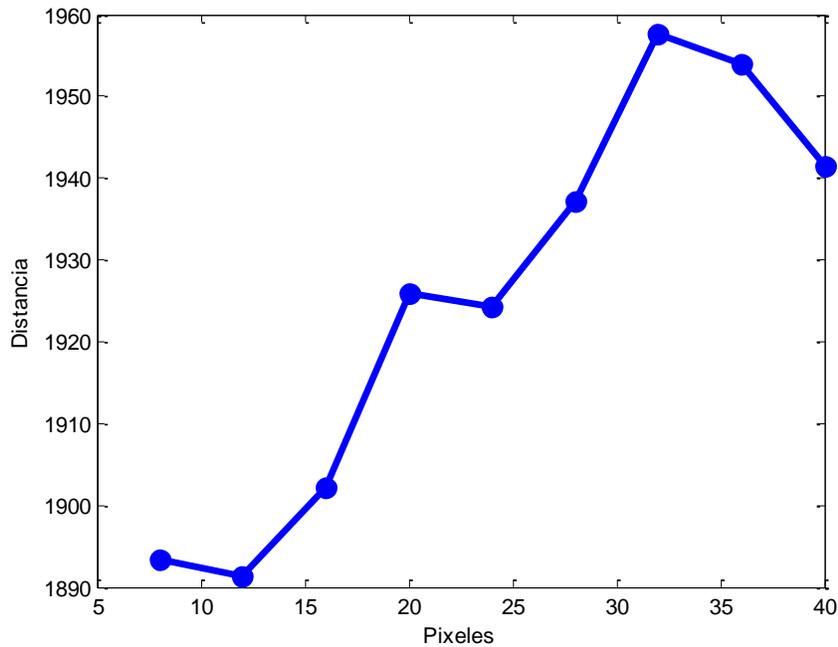


Figura 3.02. Separabilidad estadística de los conjuntos de clases.

La Figura 3.02 muestra los resultados del análisis realizado a los diferentes conjuntos de muestras, donde el eje de la ordenada representa el tamaño en píxeles de las muestras de cada conjunto, y el eje de la abscisa representa el promedio de la *DT* de cada muestra de maíz con respecto a los 200 patrones de maleza, ambas para un mismo tamaño.

3.3 Segmentación de la vegetación contra la no vegetación

Esta etapa tiene como objetivo segmentar la vegetación de la imagen, transformando la imagen de entrada RGB (rojo-verde-azul) a una imagen binaria (blanco y negro). La vegetación (maleza y cultivo) será representada con blanco y el resto (tierra, piedras, escombros o paja) con negro. Se muestra un ejemplo en la Figura 3.03. Dos métodos de segmentación fueron analizados: Método I y Método II.

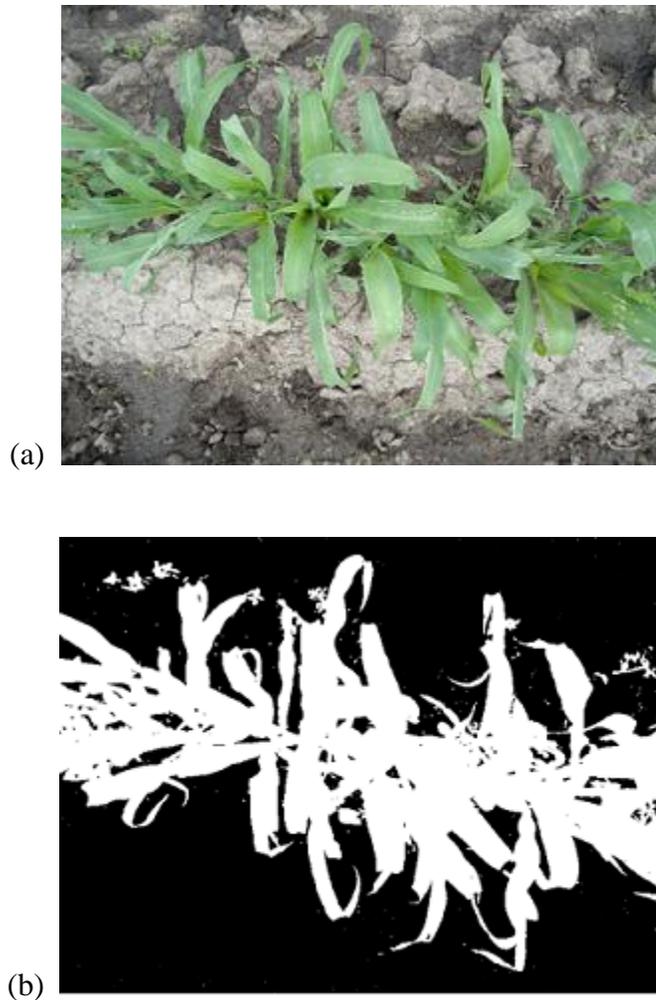


Figura 3.03. Segmentación de la vegetación. (a) Imagen de entrada, (b) Imagen segmentada.

Método I:

La segmentación se realizó mediante la generación de una imagen en niveles de gris a partir de la combinación de los tres componentes RGB que describe cada pixel de la imagen original, para su posterior umbralización. Los pasos a seguir se describen a continuación:

1. Transformar la imagen RGB a monocroma. La imagen monocroma (Imagen de niveles de gris) se obtiene a partir de la siguiente ecuación:

$$T(i,j) = rR(i,j) + gG(i,j) + bB(i,j) \quad \forall i \in \text{filas} \wedge j \in \text{columnas} \quad (3.02)$$

Donde: $R(i,j)$, $G(i,j)$ y $B(i,j)$ son las intensidades roja, verde y azul normalizadas en el pixel (i,j) y r , g y b son el conjunto de coeficientes reales que determina como la imagen de niveles gris es construida. Los valores con los cuales estos coeficientes son activados para obtener el mejor contraste entre la vegetación y el fondo, son discutidos por Woebbecke *et al.* (1995) y Ribeiro (2005).

2. Segmentación. Ésta se genera a partir de una técnica de umbralización simple, consiste en elegir un valor de intensidad y convertir todo lo que es superior a ese valor a 255 y lo que es inferior a 0, como se define a continuación:

$$salida(i,j) = \begin{cases} 255, & \text{si } T(i,j) > umbral \\ 0, & \text{si } T(i,j) \leq umbral \end{cases} \quad (3.03)$$

3. Mejorar la segmentación con la aplicación de un filtro de media de tamaño 5 x 5. Este filtro reemplaza el valor de un píxel por el resultado de promediar los valores del punto analizado y sus vecinos.

Método II:

La segmentación consiste en convertir la imagen RGB directamente a una imagen binaria dependiendo si el pixel cumple o no con las siguientes propiedades:

- 1) Componente RGB dominante.
- 2) Componente RGB dominado.
- 3) Intensidad mínima ($I_{min} > \text{Oscuridad}$).
- 4) Intensidad máxima ($I_{max} > \text{luminosidad}$).

Para la obtención de los parámetros (1) y (2) se analizaron los histogramas asociados a las tres bandas de color (roja, verde, azul) de las 100 imágenes de prueba. A partir de los histogramas, se obtuvo el valor promedio representativo de cada banda, puesto que una media alta y baja representará el componente RGB dominante y dominado, respectivamente. Posteriormente, para el cálculo de (3) y (4) se analizó la intensidad mínima y máxima, a partir del color representativo de cada pixel de la imagen.

De acuerdo a los resultados, el componente RGB dominante es la banda verde, el componente RGB dominado es la banda azul, la intensidad mínima es el nivel de gris 45 (I_{min}) y la intensidad máxima es el nivel de gris 236 (I_{max}). Por lo tanto, la segmentación de la imagen se encontró definida por la siguiente ecuación:

$$salida(i, j) = \left\{ \begin{array}{l} 255 \text{ si } \left\{ \begin{array}{l} \max(R(i, j), G(i, j), B(i, j)) = G(i, j) \\ \min(R(i, j), G(i, j), B(i, j)) = b(i, j) \\ \max(R(i, j), G(i, j), B(i, j)) \geq I_{min} \\ \min(R(i, j), G(i, j), B(i, j)) \geq I_{max} \end{array} \right\} \\ 0 \text{ otro caso} \end{array} \right\} \quad (3.04)$$

3.4 Segmentación del cultivo contra la maleza

Para la caracterización y segmentación de las hojas de maíz y las hojas de maleza se empleó la combinación de dos técnicas de análisis textural: enfoque estadístico y espectral. La finalidad de esta etapa fue etiquetar de verde el maíz y de rojo la maleza (Figura 3.04). Utilizando esta combinación de técnicas, el esquema de segmentación para este trabajo se basó en tres áreas principales: (1) Análisis textural Wavelet, (2) Selección de características, (3) Clasificador. En la figura 3.05.a y 3.05.b se muestra el esquema empleado para el entrenamiento y la evaluación del sistema, respectivamente.

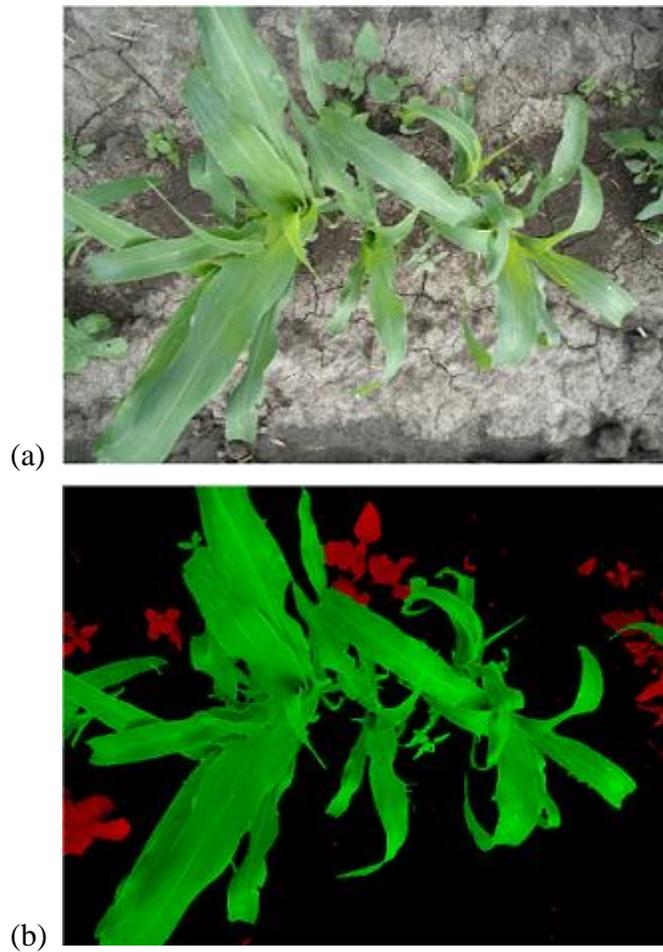


Figura 3.04. Segmentación de hojas de maleza y maíz. (a) Imagen de entrada, (b) imagen segmentada.

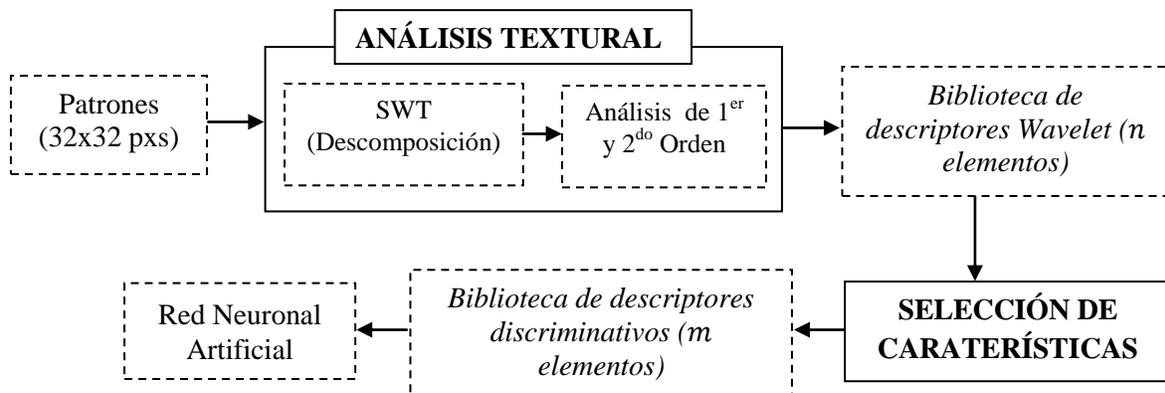


Figura 3.05a Entrenamiento del sistema de segmentación.

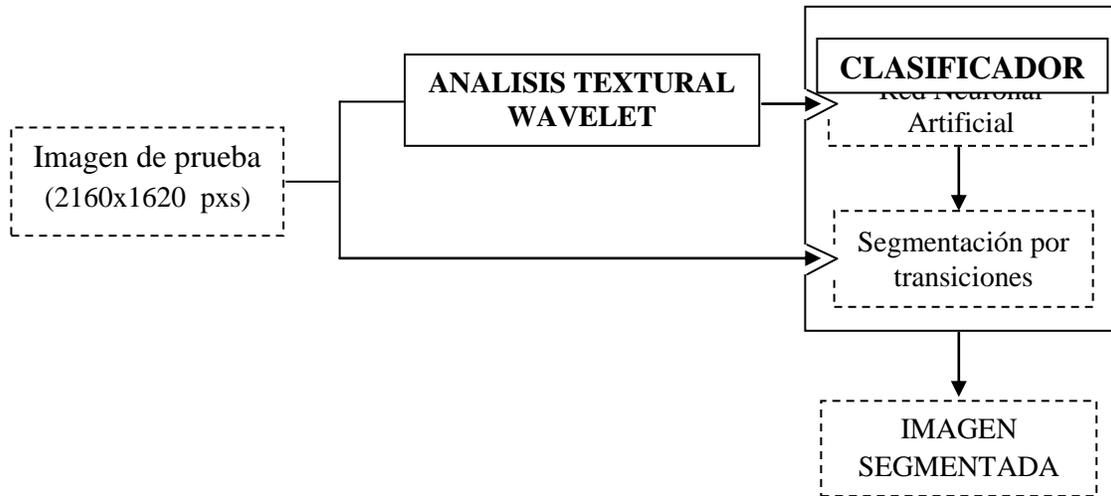


Figura 3.05b. Evaluación del sistema de segmentación.

3.4.1 Análisis textural

A continuación, se muestra como la estadística y el análisis multiescala se combinan como herramienta base para la caracterización de texturas.

3.4.1.1 Análisis textural basado en la Transformada Wavelet

El análisis textural basado en la transformada wavelet consiste en obtener la transformada (frecuencia-espacio) de la imagen y a partir de ésta, obtener ciertas cualidades digitales representativas de cada uno de los elementos de interés de la imagen (maíz y maleza).

La transformada wavelet de una imagen genera información referente a las altas frecuencias espaciales en forma de sub-imágenes de detalles horizontales, verticales y diagonales, y de bajas frecuencias en forma de aproximaciones. A partir de los detalles se puede calcular una serie de estadísticos de primer y segundo orden, cada uno de ellos obtenidos mediante procedimientos diferentes.

El análisis de textural wavelet del presente trabajo fue aplicado a las imágenes almacenadas en la *biblioteca de clase* con el objetivo de analizar y caracterizar las texturas

que describen cada una de las mismas. Los descriptores texturales obtenidos a partir de este análisis fueron almacenados en una nueva biblioteca, conocida como: *biblioteca de descriptores Wavelet*, empleada para la posterior segmentación y caracterización de imágenes de texturas desconocidas. El algoritmo de análisis textural Wavelet fue desarrollado e implementado en Matlab. La metodología utilizada para el análisis textural Wavelet se conforma de dos etapas principales, descritas a continuación:

Etapla I: Análisis de los histogramas de concurrencia para imágenes multi-resolución.

Esta etapa tiene como objetivo la extracción de los descriptores estadísticos de primer orden de los histogramas de co-ocurrencia asociados a cada sub-banda Wavelet a diferentes escalas de resolución o niveles de descomposición.

1. Descomposición Wavelet

Se aplicó la transformada Wavelet bidimensional a la imagen de entrada (imágenes de texturas conocidas o desconocidas) mediante el método de banco de filtros

2. Cálculo de los histogramas de co-ocurrencia Wavelet normalizados

Se obtuvieron los histogramas de co-ocurrencia normalizados z_j^i de los coeficientes Wavelet para los j niveles de descomposición, descritos para L valores discretos en el rango de $[\pm\infty]$.

$$p_j^i(r_k) = n_k \quad k = 0, 1, 2, \dots, L - 1 \quad (3.05)$$

$$z_j^i(r_k) = \frac{p_j^i(r_k)}{\sum_i p_j^i(r_k)} \quad i = H, V.$$

Donde r_k representa el K -ésimo valor con rango de $[\pm\infty]$, n_k el número de píxeles en la imagen con el valor r_k , L el número de valores discretos, y j el nivel de descomposición Wavelet.

3. Extracción de características

Se realizó la caracterización de las texturas mediante la información procedente de los histogramas Wavelet, formándose un vector de características con nueve elementos por cada histograma analizado. El vector de características se encuentra organizado, de la siguiente manera: Los primeros dos elementos corresponden a α y β extraídos de (Mallat, 1989), quien demostró que los histogramas de las sub-imágenes de detalle Wavelet podían ser modeladas con la siguiente familia de histogramas:

$$h(u) = ke^{-\left(\frac{|u|}{\alpha}\right)^\beta} \quad (3.06)$$

Donde α y β reflejan la varianza y lo rápido que decae el valor máximo de histograma, respectivamente; k es la constante de normalización para asegurar que $\int h(u) \cdot du = N$.

Los coeficientes α y β mostraron ser una poderosa herramienta de discriminación puesto que los valores se encuentran íntimamente ligados con la forma y la distribución del histograma. Estos fueron calculados a partir del primer (m_1) y segundo (m_2) momento del histograma wavelet normalizado.

$$\beta = F^{-1}\left(\frac{m_1^2}{m_2 N}\right), \quad \alpha = \frac{m_2 T\left(\frac{1}{\beta}\right)}{N\left(T\left(\frac{3}{\beta}\right)\right)} \quad (3.07)$$

Donde:

$$m_1 = \int_{-\infty}^{\infty} |r_k| z_j^i(r_k) dr_k \quad m_2 = \int_{-\infty}^{\infty} r_k^2 z_j^i(r_k) dr_k$$

$$F(x) = \frac{T\left(\frac{2}{x}\right)^2}{T\left(\frac{3}{x}\right)T\left(\frac{1}{x}\right)} \quad T(t) = \int_0^{\infty} e^{-r_k r_k t^{-1}} dr_k$$

Los últimos siete elementos del vector corresponden a los descriptores texturales de primer orden, los cuales fueron calculados a partir de los histogramas Wavelet normalizados (z_j^i). Las variables texturales de primer orden implementadas, se muestran a continuación:

Media: determina el nivel de intensidad promedio de la imagen.

$$\mu = \sum_{i=0}^{G-1} ip(i) \quad (3.08)$$

Varianza: describe la variación de la intensidad alrededor de la media.

$$\sigma^2 = \sum_{i=0}^{G-1} (i - \mu)^2 p(i) \quad (3.09)$$

De la varianza se deriva otro descriptor textural, que sirve como una medida de la **suavidad relativa** de la imagen, descrito como:

$$R = 1 - \frac{1}{1 + \sigma^2} \quad (3.10)$$

Tercer momento o coeficiente de asimetría: determina si una distribución es simétrica alrededor del nivel digital de máxima frecuencia. Valores positivos indican que la distribución está desplazada hacia la derecha con una mayor cola hacia la derecha del máximo. Valores negativos indican que la distribución está desplazada hacia la izquierda, con una forma más prolongada hacia ese lado del máximo.

$$\mu_3 = \sum_{i=0}^{G-1} \left(\frac{(i - \mu)}{\sqrt{\sigma^2}} \right)^3 p(i) \quad (3.11)$$

Curtosis o apuntamiento: se define como el grado en el que una distribución estadística de frecuencias es puntiaguda y se determina por la expresión,

$$\mu_4 = \sum_{i=0}^{G-1} \left(\frac{(i - \mu)}{\sqrt{\sigma^2}} \right)^4 p(i) - 3 \quad (3.12)$$

Uniformidad: uniformidad de los niveles de gris.

$$U = \sum_{i=0}^{G-1} p(i)^2 \quad (3.13)$$

Entropía: es una medida de la variabilidad de los niveles de gris, es cero para imágenes homogéneas.

$$H = - \sum_{i=0}^{G-1} p(i) \log_2[p(i)] \quad (3.14)$$

Método II: Análisis de las MCNGs para imágenes multi-resolución.

Los estadísticos de primer orden tienen la ventaja de proporcionar un análisis textural bastante sencillo, pero no pueden por sí solos caracterizar completamente las texturas, surgiendo la necesidad de apoyarse en los estadísticos de segundo orden, los cuales se caracterizan por considerar la relación de co-ocurrencia entre grupos de dos píxeles de una imagen, calculándose a partir de la matriz de co-ocurrencia de niveles de gris (MCNG).

Por lo anterior, este método tiene como objetivo la extracción de los descriptores estadísticos de segundo orden de las MCNGs asociadas a cada sub-banda Wavelet a diferentes escalas de resolución o niveles de descomposición. La metodología se muestra a continuación:

1. Descomposición Wavelet

Se aplicó la transformada Wavelet bidimensional a la imagen de entrada (imágenes de texturas conocidas o desconocidas), mediante el método de banco de filtro.

2. Construcción de la MCNG

Se obtuvo la matriz de co-ocurrencia de cada una sub-bandas Wavelet obtenidas de la etapa anterior. La matriz de co-ocurrencia se analizó para las siguientes combinaciones: (1,0), (0,1), (1,1), (-1,-1), que dan lugar a las cuatro principales orientaciones (0°, 45°, 90° y 135°) (Haralick *et al.*, 1973).

3. Extracción de características

La caracterización de los niveles de gris y patrones de la MCNG se realizó mediante la extracción de sus características o descriptores texturales, propuestos por Haralick *et al.* (1973). Para su cálculo se partió de los conceptos de matriz normalizada (P_n), formándose un vector de características con ocho elementos por cada matriz analizada. Las variables texturales de segundo orden implementadas, se muestran a continuación:

Media (μ)

Proporciona información sobre el brillo global de la imagen, sensación similar a la obtenida a partir del histograma.

$$c_1 = \sum_{i=0}^{N-1} iP_x(i) \quad P_x(i) = \sum_{j=0}^{N-1} P_n(i,j) \quad (3.15)$$

Varianza

Mide la heterogeneidad, es decir, la variabilidad de las intensidades en la imagen y aumenta su valor cuando los niveles de gris difieren de la media.

$$(3.16)$$

$$c_2 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - c_1)^2 P_n(i, j)$$

Contraste

También llamado inercia, establece la diferencia de la frecuencia entre valores altos y bajos del nivel de gris. Está directamente relacionado con la frecuencia espacial de la imagen y en imágenes con pocas variaciones locales en los niveles de gris el valor del contraste será bajo.

$$c_3 = \sum_{n=0}^{N-1} n^2 \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_n(i, j), \quad \text{suje to a } |i - j| = n \quad (3.17)$$

Entropía

Indica la aleatoriedad, complejidad o desorden en la distribución de intensidades de una imagen, es decir, la existencia de variaciones de niveles de gris en entornos próximos.

$$c_4 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_n(i, j) \log [P_n(i, j)] \quad (3.18)$$

Momento producto o covarianza

Valores positivos altos indican una mayor probabilidad de que se den juntos en la imagen valores de intensidad similar. Por el contrario, valores negativos son propios de imágenes donde píxeles vecinos difieren mucho en su nivel de gris.

$$c_5 = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - c_1) (j - c_1) P_n(i, j) \quad (3.19)$$

Homogeneidad

La homogeneidad está muy relacionada con la información local extraída de una imagen y refleja la uniformidad de una región.

$$\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P_n(i,j)}{1 + |i - j|} \quad (3.20)$$

3.4.2 Parámetros de la transformada Wavelet

3.4.2.1 Selección de la función escala

Tipicamente los algoritmos de clasificación textural basados en la transformada wavelet requieren de funciones bases que proporcionen una excelente separación de escalas y reconstrucción de la imagen como es el caso de la familia de wavelets bi-ortogonal. Sin embargo, estudios han probado que algunas bases de datos texturales han mejorado su clasificación al utilizar una wavelet Haar; porque a pesar de su discontinua (no diferenciable) y pobre reconstrucción de la señal, las imágenes texturales responden más fuertemente a estas discontinuidades (Busch y Boles, 2002).

La wavelet Haar es una función invariante al cambio, simétrica y de soporte compacto, lo que contribuye a su excelente rendimiento. La wavelet madre (ψ) y su versión escala (ϕ) se definen por la Ecuación 3.21 (Manian y Vasquez, 1998). En la presente aplicación se empleó como función base debido a:

- Su discontinuidad la hace más susceptible a la detección de cambios de tonalidad en la imagen.
- Los filtros con menor varianza al cambio representan una selección óptima para la caracterización textural (Mojsilovic *et al.*, 2000).
- Los filtros simétricos son más adecuados para el análisis textural que los filtros asimétricos. Esto se debe a que los filtros de longitud par tienen, significativamente, menos varianza al cambio que los filtros de longitud impar (Mojsilovic *et al.*, 2000).

- Debido a su soporte compacto, ésta es la única wavelet que permite una localización perfecta en el dominio de la transformada (Farhoodi y Kasaei, 2005).

$$\psi(x) = \begin{cases} 1, & 0 \leq x < \frac{1}{2} \\ -1, & \frac{1}{2} \leq x < 1 \\ 0, & \text{otro caso} \end{cases} \quad \phi(x) = \begin{cases} 1, & 0 \leq x < 1 \\ 0, & \text{otro caso} \end{cases} \quad (3.21)$$

3.4.2.2 Selección del nivel de descomposición

La transformada wavelet consiste en un modelo de aplicación de descomposiciones y reconstrucciones de una imagen a diferentes escalas, lo que se denomina multiresolución. Es conocido que de cada una de esas resoluciones o niveles se puede extraer la información de las altas o bajas frecuencias presentes en la imagen; sin embargo, el problema recae en el momento de determinar a qué nivel o niveles se debe extender el modelo descomposición, con el fin de evitar un volumen exhaustivo de información, y por ende, facilitar el proceso de análisis.

Por lo contrario, en muchas ocasiones realizar una descomposición tan solo a nivel uno, no proporciona toda la información deseada, ya que pueden quedar objetos en la imagen que a esa resolución no son totalmente considerados. Por ello se considera importante determinar a qué nivel o niveles se debe extender el modelo de descomposición para sacar la máxima información de la imagen.

Dado el tamaño de muestra y la función wavelet a utilizar, el nivel máximo de descomposición se obtiene mediante el criterio de la Ecuación 3.22. Este criterio dice que el último nivel es aquel, para el cual por lo menos un coeficiente es correcto (Misiti y Misiti, 1996). Por lo tanto, como la mínima longitud de la imagen de muestra es de 32 píxeles y la función Haar se compone de 2 coeficientes, el nivel descomposición máximo permitido es cinco.

$$(l_w - 1) * (2^{nd}) < l_x \quad (3.22)$$

$$nd = \log_2 \left(\frac{l_x}{l_w - 1} \right)$$

Donde:

- nd Nivel de descomposición máximo permitido.
- l_x Mínima longitud de la imagen.
- l_w Longitud de la función wavelet.

Se seleccionó el cuarto nivel de descomposición como el adecuado para el presente análisis, ya que resulta irrelevante obtener las características del quinto, puesto que éste se componen de un solo coeficiente.

3.4.3 Selección de características

Una selección adecuada de las características texturales extraídas es de vital importancia, debido a que no todas contribuyen a una óptima clasificación, generando en mucho de los casos resultados redundantes y poco favorables, lo que aumenta la complejidad del clasificador. Por esta razón, se realiza la selección de un sub-conjunto de m descriptores a partir del conjunto de n descriptores almacenados en la *biblioteca de descriptores Wavelet*. El subconjunto de m descriptores es almacenado en la *biblioteca de descriptores discriminativos*. A continuación, se selecciona el método de búsqueda, la función de evaluación y se plantea la metodología empleada para la selección del subconjunto de características.

3.4.3.1 Selección del procedimiento de búsqueda

Una vez conocidas las ventajas e inconvenientes de los posibles métodos de selección de característica (sección 2.2.3), se escoge el método más adecuado para la presente aplicación de acuerdo a sus requerimientos y limitaciones.

A pesar de que el problema se puede tratar con métodos de tiempo de cálculo muy elevado, puesto que no es necesario que actúe en tiempo real, el alto costo computacional que esto implicaría hace imposible el empleo de algoritmos de selección basados en redes neuronales o estadística óptima, pues utilizar un algoritmo como el de *búsqueda exhaustiva* generaría un alto análisis de combinaciones, es por esto, que el empleo de métodos estadísticos sub-óptimos resulta una mejor opción. Trabajar con algoritmos sub-óptimos ya implica una posible deficiencia en los resultados al no ser evaluadas todas las posibles combinaciones, como consecuencia de esto se decidió emplear un algoritmo determinístico de una solución, con el objetivo de incrementar la precisión y sencillez de los resultados, al no introducir un elemento aleatorio como en el casos de los métodos estocásticos. Dentro de los métodos determinísticos de una solución se concluyó por trabajar con el IFFS, ya que su propiedad *floating* permite añadir y eliminar características del sub-conjunto, además de ser más rápido que su método opuesto SBFS al trabajar con un conjunto más reducido de características.

3.4.3.2 Selección de la función de evaluación

Una vez determinado el método de selección de características, falta por definir la función de evaluación, empleada para comparar el poder de clasificación de los distintos sub-conjuntos formados. Dash y Liu (1997) muestran una comparación de las funciones de evaluación, que son independientes del método o procedimiento de búsqueda utilizado para la selección de características. Los distintos parámetros empleados para la comparación son: (1) Generalidad: el subconjunto seleccionado es óptimo para ser utilizado en los diferentes tipos de clasificadores, no sólo para un clasificador. (2) Complejidad de tiempo: tiempo necesario para seleccionar el subconjunto de características. (3) Precisión: que tan exacta es la predicción usando el subconjunto seleccionado.

Muchos métodos de selección utilizan la distancia euclidiana como función de evaluación, sin embargo, esta asume que cada característica de un conjunto de datos es igual de importante e independiente que otra, reflejando alta similitud para casos de clasificación en espacios de alta dimensionalidad. Por esta razón, y en conjunto con la

generalidad, baja complejidad de tiempo, y precisión aceptable que caracterizan a las medidas basadas en la distancia como la de Mahalanobis, ésta es certeramente la más adecuada para la presente aplicación. Esta distancia se basa en la correlación entre variables y es invariante a la escala a diferencia de la euclidiana.

Sea X una matriz de m muestras aleatorias con n características y una muestra y_i con igual número de características, la distancia Mahalanobis d_M de la muestra y_i al grupo X está definida como (Zhang *et al.*, 2011):

$$d_M = \sqrt{(y_i - v)^T S^{-1} (y_i - v)} \quad (3.23)$$

Donde v es el vector media de todas las muestras $x_j \in X$, y S es la matriz de covarianza calculada como:

$$S = \frac{1}{m} \sum_{j=1}^m (x_j - v)(x_j - v)^T \quad (3.24)$$

El rechazo de característica consiste eliminar aquella que más disminuya la distancia entre clases, considerando que mientras menor sea la distancia mayor será la correlación entre ambos tipos de clases. Se seleccionó como criterio de detención cuando la varianza de las últimas muestras reflejara un cambio mínimo.

3.4.3.3 Metodología empleada para la selección del subconjunto

A continuación, se describen los pasos requeridos para la selección del subconjunto óptimo:

1. Normalización de los descriptores Wavelets

A veces las técnicas a utilizar en un sistema suelen ser sensibles a diferencias en el valor relativo de las variables o datos sobre las que se aplican. Para minimizar este problema se aplicó la normalización de los datos. La forma más sencilla de normalizar es

realizar una transformación lineal en cada variable de forma que todos los datos disponibles queden contenidos en el intervalo $[-1, +1]$; aunque simple, este tipo de normalización tiene el inconveniente de que no produce un buen resultado en presencia de valores atípicos. Para evitar esto, se hace uso de una normalización (\tilde{x}) basada en la norma (\bar{x}) y la desviación estándar (σ), como se muestra en la Ecuación 3.25 (Cuadrado, 2002).

$$\tilde{x} = \frac{x - \bar{x}}{\sigma} \quad (3.25)$$

Donde:

$$\bar{x} = \frac{1}{N} \sum_{k=1}^N x_k, \quad \sigma = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (x_k - \bar{x})^2}$$

2. Evaluación de los sub-conjuntos de características.

Se aplicó el algoritmo de búsqueda SFFS con una función objetivo que evalúa la separabilidad entre clase. Esta función es la distancia de Mahalanobis. No se aplicó un criterio de detención, con el objetivo de analizar la mayor cantidad de conjunto de características.

3. Selección del subconjunto.

Se selecciona el subconjunto de característica con mayor separabilidad entre clases.

3.5 Clasificador

Esta etapa es la encargada de realizar las deducciones pertinentes sobre la información extraída, que se obtuvo en etapas previas, para la clasificación de la entrada. El clasificador propuesto para el diagnóstico de la información consta de dos etapas: (1) segmentación neuronal y (2) segmentación por transiciones. En la Figura 3.07 se muestra

un ejemplo grafico de los resultados obtenidos por el clasificador para cada una de sus etapas.

3.5.1 Segmentación neuronal

Se empleó un Perceptrón Multicapa (de aquí en adelante MLP, Multilayer Perceptrón) para la toma de decisiones, por su gran adaptabilidad, robustez, capacidad de generalización y tolerancia a fallos.

La arquitectura del MLP se compone por una capa de entrada, dos capas ocultas y una capa de salida (Figura 3.06). La capa de entrada tiene una neurona por cada elemento de la biblioteca de descriptores discriminativos. La primera capa oculta está compuesta por $\frac{n}{2} + 1$ neuronas, donde n representa el número de características de entrada por patrón o muestra. El tamaño de la segunda capa oculta se determinó de forma experimental. Se utilizó como función de activación una función sigmoidea y una lineal para cada una de las neuronas de las capas ocultas y capa de salida, respectivamente. La salida deseada para la maleza se estableció en -0.5 y para el maíz en 0.5. Se empleó 20000 patrones de entrada para su entrenamiento, 10000 representativas del maíz y el resto de maleza. Se aplicó como algoritmo de entrenamiento el gradiente conjugado escalado con el fin de ajustar el conjunto de pesos que minimice el error cometido al clasificar el conjunto de patrones de entrenamiento.

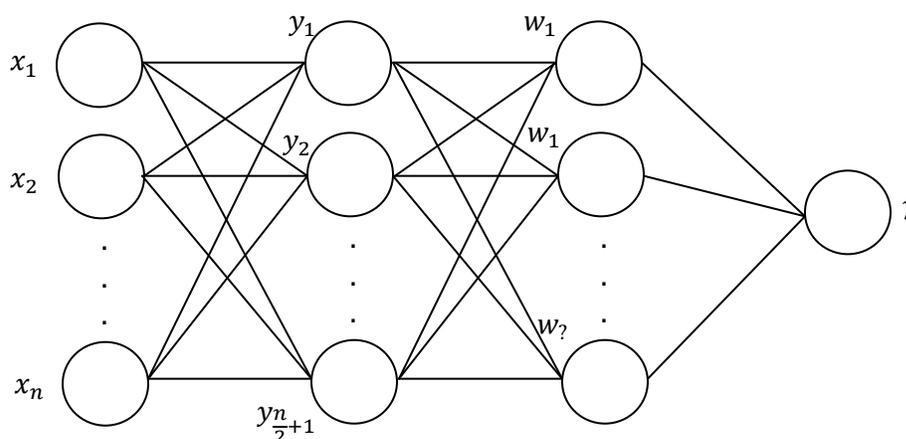


Figura 3.06. Estructura del Perceptrón Multicapa (MLP).

3.5.2 Segmentación por transiciones

Con el objetivo de optimizar el resultado de la segmentación neuronal, se realizó otra segmentación basada en detección de transiciones para la creación de particiones en la imagen. La entrada del algoritmo es una imagen binaria y su salida es una imagen cuyas regiones se encuentra etiquetada. La metodología de segmentación se describe a continuación:

1. Detección de transiciones

Se realizó los bordes verticales y horizontales de la imagen de entrada, mediante la convolución con un filtro Prewitt, cuya imagen de salida contiene valores altos en aquellas posiciones de los datos que están cerca de las transiciones, y valores bajos en las áreas homogéneas.

2. Binarización

Se realizó una sencilla técnica de umbralización, que consiste en elegir un umbral y convertir todo lo que es superior a ese valor a 255 y lo que es inferior a 0. Se estableció un umbral fijo con valor de 220. El valor del umbral fue seleccionado de manera experimental.

3. Cerradura

Se aplicó una cerradura morfológica a la imagen binaria con el objetivo de disminuir el número de transiciones discontinuas.

4. Adelgazamiento

Se realizó un adelgazamiento para definir contornos de un pixel de ancho y disminuir el ruido en la imagen.

5. Cerrado de contorno

Se cerraron puntos discontinuos en los bordes tomando a consideración la similitud de los puntos finales, con respecto a los siguientes parámetros: magnitud, distancia, dirección y sentido.

6. Etiquetado y clasificación de regiones

Se realizó un etiquetado de regiones con el fin de que cada partición de la imagen tenga un nivel de gris diferente. Las etiquetas se clasificaron como maíz o maleza en función a la moda estadística dada por el clasificador neural para cada una de ellas.

En la Figura 3.07 se muestra un ejemplo grafico de los resultados derivados de la segmentación neuronal y segmentación por transiciones para una imagen de prueba (a). (b) es la segmentación de la vegetación, donde el suelo es etiquetado de negro y la vegetación es representada con su color RGB original, esta imagen se empleó como entrada para ambas segmentaciones. En la imagen (c) se observa un realce de contornos basado en un filtro Prewitt, una cerradura morfológica, un adelgazamiento y un cerrado de contorno, la cual es usada para el etiquetado de regiones (d). En (e) se muestra los resultados de la segmentación neuronal, que en conjunto con los de (d) fueron empleados para obtener la imagen de salida (f) con el maíz, la maleza y el suelo clasificados. Como se puede observar en (e), la segmentación neuronal requiere de una etapa de mejoramiento, principalmente, por las zonas azules, que representan pixeles que aún no han sido etiquetados. Esto se debe a que la máscara de selección (32x32 pixeles) sobrepasa los bordes de la vegetación, lo cual ocasiona que la muestra contenga pixeles pertenecientes al suelo. Este tipo de muestra no es conveniente para la clasificación, por lo que no es analizada.

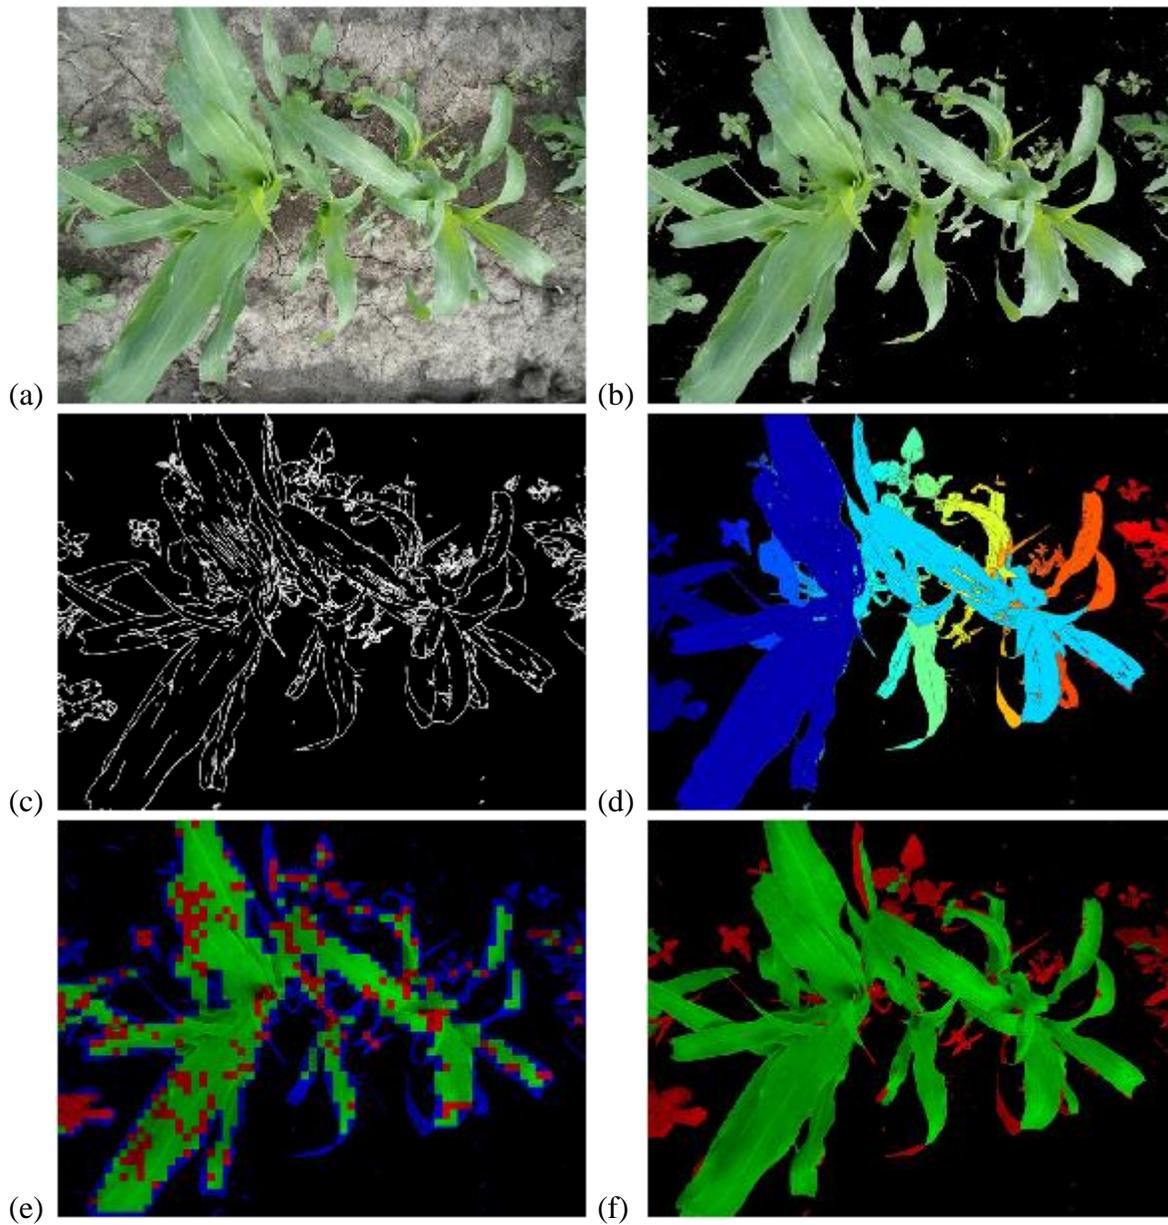


Figura 3.07. Etapas del clasificador. (a) Imagen de entrada, (b) Vegetación segmentada, (c) Realce de bordes y cerrado de contorno, (d) Imagen etiquetada por regiones, (e) Segmentación neuronal e (f) Imagen clasificada, donde el maíz es representado de verde y la maleza de rojo.

3.6 Evaluación de resultados

Para evaluar los resultados finales, se emplean las medidas de tasa de clasificación correcta (T_c), especificidad (E) y sensibilidad (S) obtenidas a partir de la matriz de confusión que muestra las diferencias entre la clase verdadera y la estimada para un conjunto de observaciones previamente etiquetadas (Bradley, 1996). La matriz de confusión se describe en el Cuadro 3.01. Donde VP (verdaderos positivos) son las observaciones correctamente clasificadas como maíz. VN (verdaderos negativos) son las observaciones correctamente clasificadas como maleza. FP (falsos positivos) son las observaciones clasificadas como maíz pero su clase real es la clase de maleza. FN (falsos negativos) son las observaciones clasificadas como maleza pero su clase real es la de maíz. Las medidas T_c , S , y E se definen en el Cuadro 3.02. Donde VP, VN, FN y FP corresponden a las definiciones dadas anteriormente, y DT es el número total de datos.

Cuadro 3.01. Matriz de confusión.

		Clase Real	
		Maíz	Maleza
Clase estimada	Maíz	VP	FP
	Maleza	FN	VN

Cuadro 3.02. Medidas de evaluación para el clasificador.

Medida de evaluación	Ecuación
Tasa de clasificación correcta (T_c)	$\frac{VP + VN}{DT}$
Sensibilidad (S)	$\frac{VP}{VP + FN}$
Especificidad (E)	$\frac{VN}{VN + FP}$

IV. RESULTADOS Y DISCUSION

En esta sección se exponen y discuten los resultados obtenidos dentro de las siguientes etapas de la metodología: (1) segmentación de la vegetación, (2) segmentación del cultivo y la maleza.

4.1 Segmentación de la vegetación

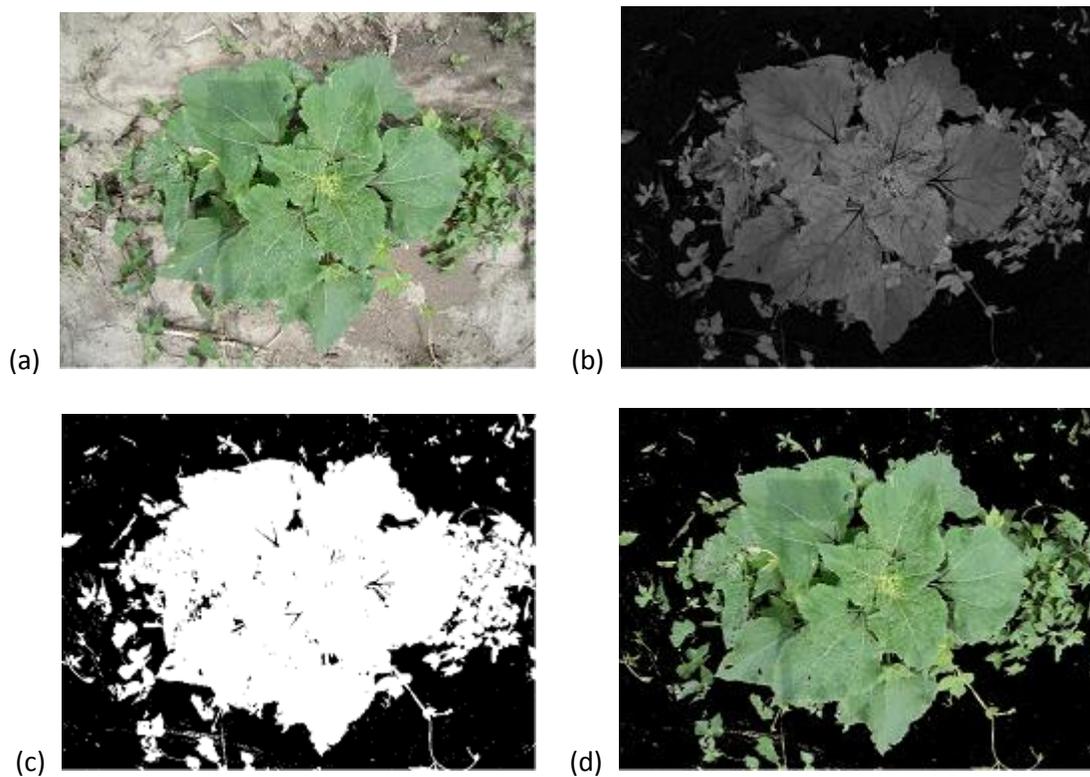


Figura 4.01a. Segmentación de la vegetación con el Método I. (a) Imagen de entrada; (b) Imagen monocroma; (c) Imagen binarizada; (d) Imagen segmentada con $r = -1, g = 2, b = -1, umbral=25$.

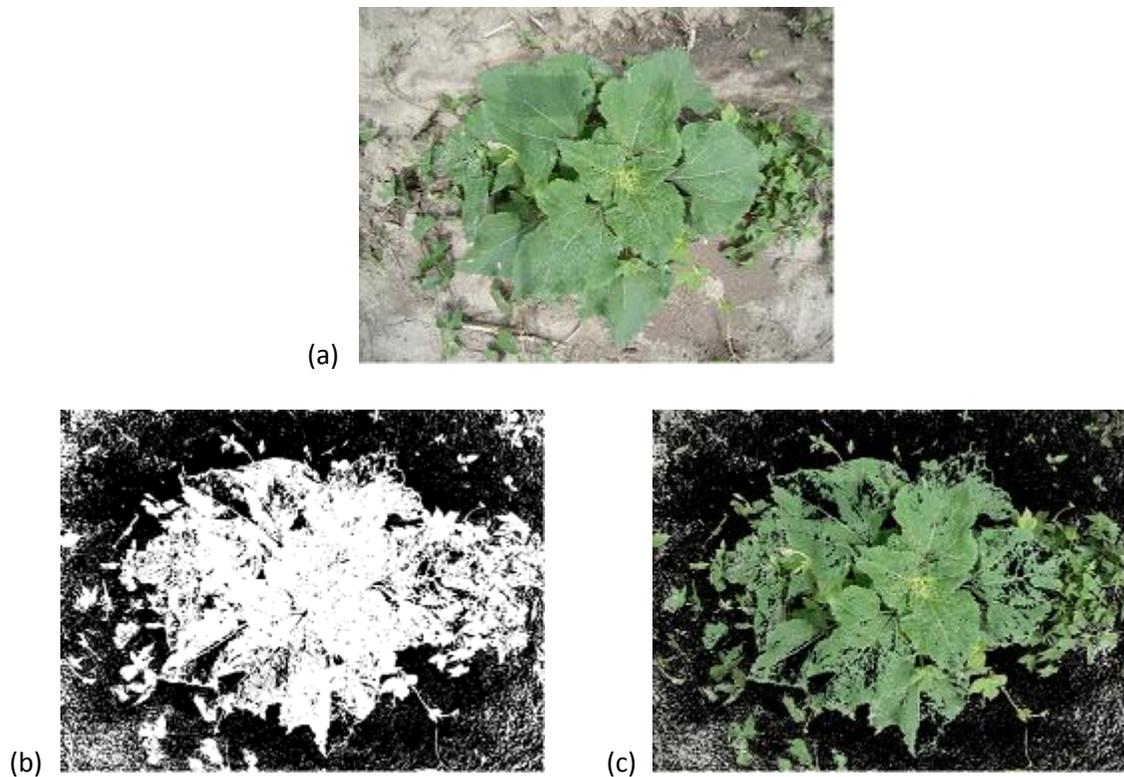


Figura 4.01b. Segmentación de la vegetación con el Método II. (a) Imagen de entrada. (b) Imagen binarizada; (c) Imagen segmentada con $I_{min}=45$, $I_{max}=236$.

En la Figura 4.01 se muestra los resultados de los dos métodos empleados para la segmentación de la vegetación, generando una mejor segmentación el Método I por ser menos propenso al ruido que el Método II.

4.2 Segmentación del cultivo y la maleza.

4.2.1 Análisis textural

Del análisis textural Wavelet se obtuvo una matriz de 216 características por 20,000 observaciones. 56 características corresponden al análisis de primer orden asociadas a un determinado descriptor textural (7 descriptores), por cada conjunto de coeficientes de

detalles Wavelet (2 conjuntos) y nivel de descomposición (4 niveles); las 160 características restantes pertenecen al análisis de segundo orden asociadas a un determinado descriptor textural (5 descriptores), por cada dirección de la MCNG analizada (4 direcciones), conjunto de coeficientes de detalles Wavelet (2 conjuntos) y nivel de descomposición (4 niveles).

4.2.2 Selección de características

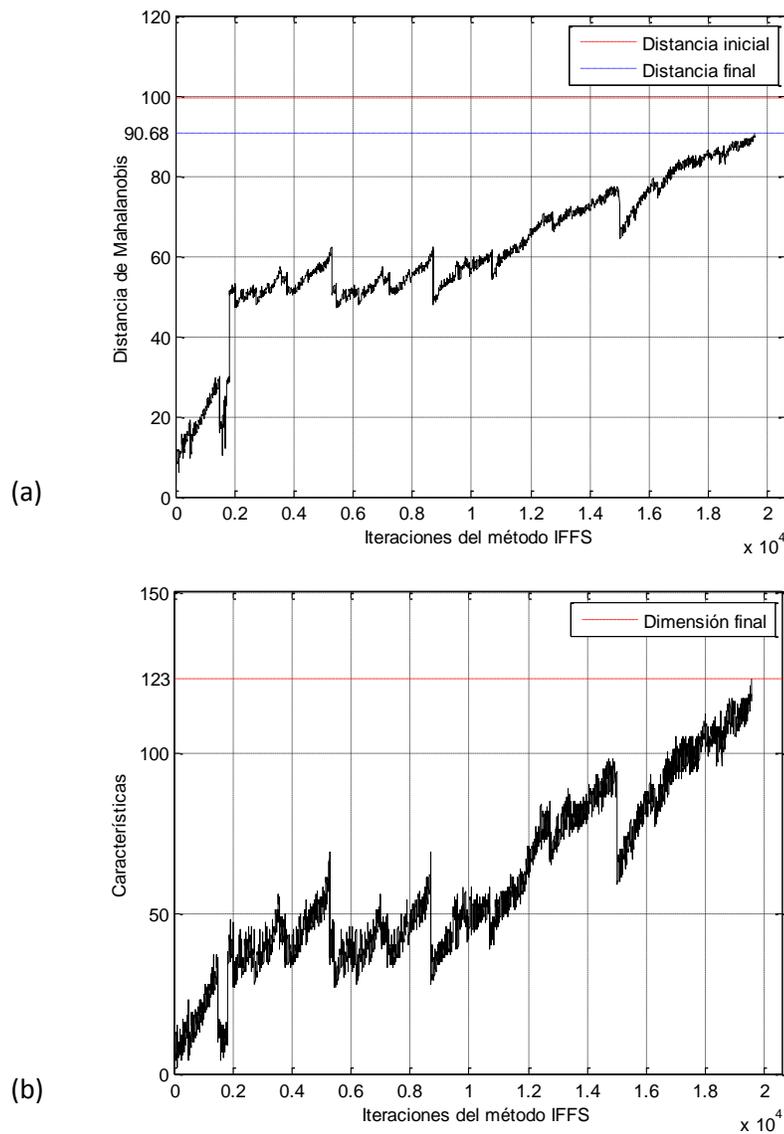


Figura 4.02. (a) Distancia de Mahalanobis, (b) para cada tamaño de subconjunto de características evaluado.

En la Figura 4.02a se observa una evolución de distancia de Mahalanobis J a medida que aumenta el número de iteraciones del algoritmo IFFS. La Figura 4.02b muestra el tamaño del subconjunto evaluado para cada una de estas iteraciones. Ambas graficas se encuentran ligadas, por lo tanto para cada distancia de Mahalanobis existe un número de características correspondiente a la misma iteracion. De acuerdo a estas figuras, el mejor subconjunto de características obtenido es aquel con 123 elementos para una distancia de 90.68, en comparacion del conjunto original de 216 elementos para una distancia de 99.38.

4.3 Clasificador

Con base al número de entradas determinadas por la etapa de selección de características, y al analisis experimental, el MLP para la segmentacion neuronal se definió con una estructura de 123 neuronas en la capa de entrada, dos capas ocultas de 63 y 42 neuronas, respectivamente, y una neurona de salida. En el Cuadro 4.01 se muestra los resultados del clasificador (combinación de la segmentacion neuronal y segmentacion por transiciones) para un conjunto de 25 imágenes de prueba. En las Figuras 4.03, 4.04 y 4.05 se muestran los resultados graficos de la metodologia, donde el maiz se representa de verde, la maleza de rojo y el suelo de negro.

Cuadro 4.01. Evaluación de resultados.

Medida de evaluación	Porcentaje
Tasa de clasificación (T_c)	94.77
Sensibilidad (S)	93.83
Especificidad (E)	95.31

En el Cuadro 4.02 se muestra una comparación de los resultados obtenidos por diferentes autores, donde la tasa de clasificación representa el número de pixeles identificados correctamente para el cultivo (T_{cc}), la maleza (T_{cm}). En el cuadro se puede

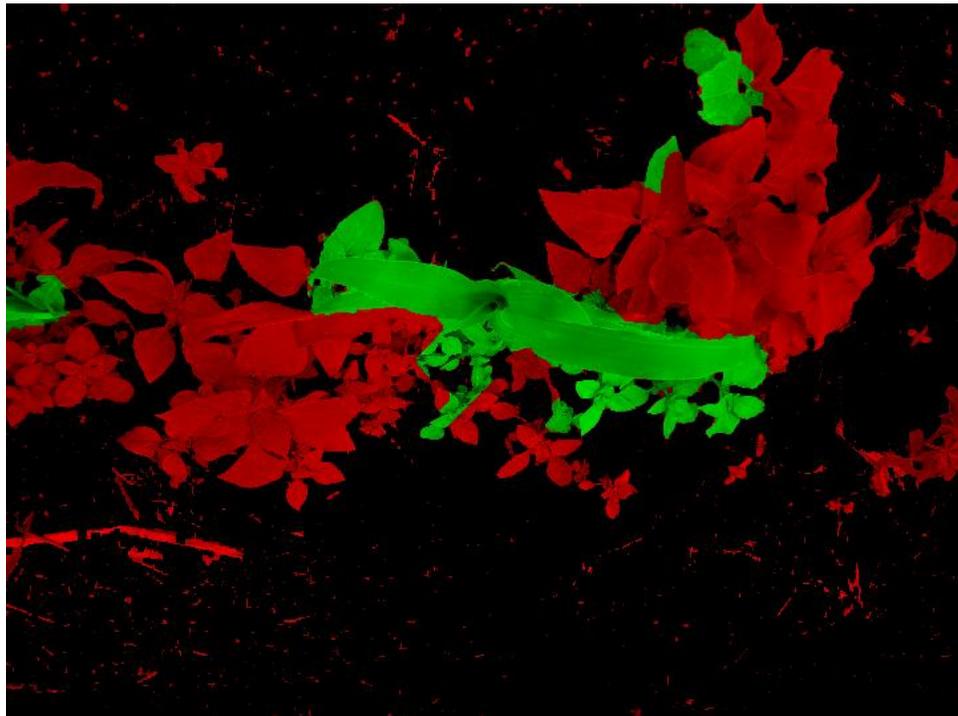
observar una tasa de clasificación competente con respecto a los otros trabajos. A pesar, de que la investigación de Kiani *et al.* (2010) presentan un mayor porcentaje de clasificación, su investigación se limitó al análisis de imágenes que contenían exclusivamente cultivo o solo maleza, además, se considera que su base de datos es muy pequeña para el entrenamiento de su sistema, provocando que este sea poco robusto.

Cuadro 4.02. Comparación de resultados con otros trabajos.

Técnica	Tasa de clasificación (%)		Autor, año
	T_{cc}	T_{cm}	
Redes neuronales	95.35	86.05	Kavdir, 2004.
Longitud de onda	66.00	78.00	Piron <i>et al.</i> , 2008.
Color y Forma	80.00	95.00	Burgos-Artizzu <i>et al.</i> , 2011.
Wavelet discreta	97.00	98.80	Kiani <i>et al.</i> , 2010.
Wavelet SWT	93.83	95.31	El presente trabajo.



(a)

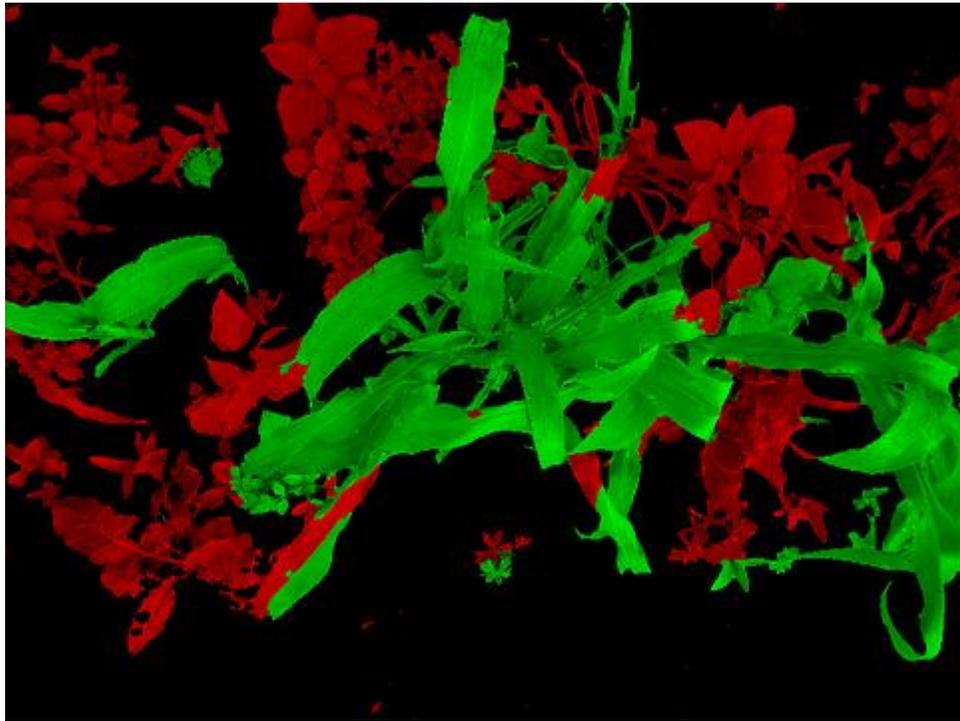


(b)

Figura 4.03. Ejemplo de clasificación I. (a) Imagen de entrada, (b) Imagen de segmentada.



(a)

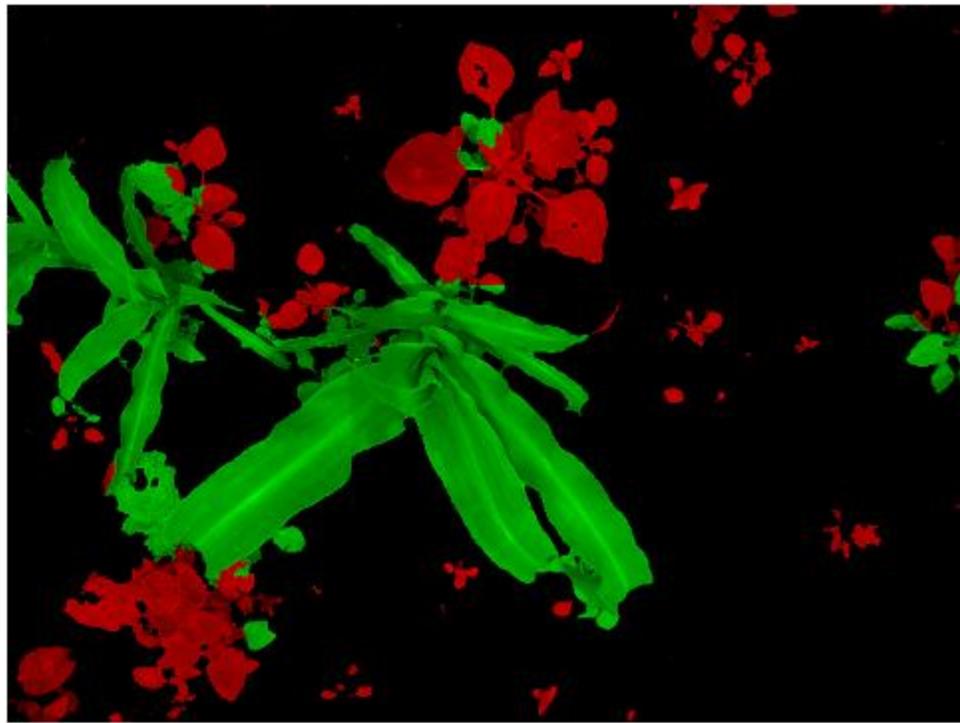


(b)

Figura 4.04. Ejemplo de clasificación II. (a) Imagen de entrada, (b) Imagen de segmentada.



(a)



(b)

Figura 4.05. Ejemplo de clasificación III. (a) Imagen de entrada, (b) Imagen de segmentada.

4.4 Conclusiones

En el presente trabajo, la discriminación de la maleza, el maíz y el suelo involucró una combinación de diferentes técnicas disponibles: Primero, se realizó la segmentación del suelo mediante la umbralización de una transformación lineal. Posteriormente, se presentó la segmentación del maíz contra la maleza, mostrando como la estadística y el análisis multiescala se combinan como herramienta base para la caracterización de texturas. Por último, se presentó el clasificador como una combinación de técnicas basadas en redes neuronales y segmentación por transiciones. Se obtuvo una tasa de clasificación bastante aceptable del 94.77%, una sensibilidad 93.83% y una especificidad del 95.31%. La sensibilidad es una medida de evaluación muy importancia en la presente aplicación, ya que mientras menor sea ésta mayor será el número de hojas de maíz catalogadas como maleza, lo cual no es favorable. Con el fin de aumentar la sensibilidad, un trabajo a futuro implica la realización de un análisis textural wavelet en combinación con un análisis de forma. Algunas conclusiones con base en los estudios realizados son:

- Los estadísticos de primer orden tienen la ventaja de proporcionar un análisis textural bastante sencillo, pero no pueden por sí solos caracterizar completamente las texturas, surgiendo la necesidad de apoyarse en los estadísticos de segundo orden.
- De las características texturales analizadas no todas contribuyen a una óptima clasificación, generando en muchos de los casos resultados redundantes y poco favorables, siendo de vital importancia realizar una adecuada selección de los datos de estudio, y de esta forma disminuir la complejidad del clasificador.
- La tasa de clasificación depende en gran medida de la calidad de los conjuntos de entrenamiento, siendo de gran utilidad la selección de una adecuada, amplia y robusta base de datos.
- La clasificación de la maleza es una tarea difícil por su similitud con el cultivo y alta variabilidad de condiciones naturales existente en el campo, aunado a esto, el maíz tiene una forma irregular y alargada de crecimiento, cuyas hojas se ven constantemente dañadas por la sequia y otros plagas, esto provoca que la

discriminación de cultivo sea mucho más compleja, sin embargo, los resultados de la metodología mostraron que el análisis textural wavelet es una herramienta prometedora para la discriminación de la maleza y el cultivo, proporcionando una mejor discriminación que las técnicas basadas en análisis de forma y color.

- El presente trabajo, mostró una metodología robusta a condiciones naturales de iluminación y humedad, con una tasa de clasificación competente para la identificación de maleza tanto en surcos como entrelazada con el cultivo.

V. REFERENCIAS BIBLIOGRÁFICAS

- Aitkenhead, M. J., I. A. Dalgetty, C. E. Mullins, A. J. S. McDonald, and N. J. C. Strachan, 2003. Weed and crop discrimination using image analysis and artificial intelligence methods. *Comput. Electron. Agric.* 39:157-171.
- Bifani, P., 1999. Medio ambiente y desarrollo, Editorial: Instituto de Estudios Políticos para América Latina y África (IEPALA), 4° ed. ISBN/ISSN: 84-89743-06-1, pp. 246-347.
- Borregaard, T., H. Nielsen, L. Nørgaard and H. Have, 2000. Crop-weed Discrimination by Line Imaging Spectroscopy. *J. Agric. Eng. Res.* 75:389-400.
- Bossu, J., Ch. Gée, G. Jones and F. Truchetet., 2009 Wavelet transform to discriminate between crop and weed in perspective agronomic images. *Comput. Electron. Agric.* 65:133-143.
- Bradley, A. P., 1996. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognit.* 30: 1145-1159.
- Burgos-Artizzu, X. P., A. Ribeiro, A. Tellaeché, G. Pajares, C. Fernández-Quintanilla, 2010. Analysis of natural images processing for the extraction of agricultural elements. *Image Vision Comput.* 28: 138-149.
- Burgos-Artizzu, X. P., A. Ribeiro, M. Guijarro, G. Pajares, 2011. Real-time image processing for crop/weed discrimination in maize fields, *Comput. Electron. Agric.* 75: 337-346.
- Busch, A., and W. W. Boles, 2002. Texture classification using multiple wavelet analysis. In: *Proceedings of the Sixth Digital image computing techniques and applications*, Melbourne, Australia. Aust. Pattern Recognit Soc.

Cover, T.M., and J.M. Van Campenhout, 1977. On the Possible Orderings in the Measurement Selection Problem. IEEE Trans. Systems, Man, and Cybernetics. SMC-7: 657 – 661.

Cuadrado, A. A., 2002. Supervisión de Procesos Complejos mediante Técnicas de Data Mining con Incorporación de Conocimiento Previo [Tesis Doctoral] Departamento de Ingeniería Eléctrica, Electrónica, Computadores y Sistema. Universidad de Oviedo. Disponible en: <http://isa.uniovi.es/~cuadrado/varios/tesis.pdf> [Consultado: 21.08.12].

Dammer, K-H, and G. Wartenberg, 2007. Sensor-based weed detection and application of variable herbicide rates in real time. Crop Prot. 26: 270–277.

Dash, M., and Liu H., 1997. Feature Selection for Classification, Elsevier Intelligent Data Analysis. 1:131–156.

Daubechies, I., 1992. Ten Lectures on Wavelets. The Society for Industrial and Applied Mathematics. ISBN 10: 0-89871-274-2.

Estévez V., P., 1999. Elección de Características para Clasificadores Neuronales, Anales del Instituto de Ingenieros de Chile. 111: 65-74.

Excelsior, 2009. Migración y Pobreza en el Campo: las heridas en el campo. [En línea]. Disponible en: http://www.ceidas.org/documentos/Excelsior/Migracion_y_pobreza_Las_heridas_en_el_campo.pdf. [Consultado: agosto 2010].

Farhoodi, R., and S. Kasaei, 2005. Text segmentation from images with textured and colored background. Proceedings of the 13th Iranian Conference on Electrical Engineering (ICEE).

- Fernández, A. S., 2005. Introducción al Reconocimiento de Patrones. Curso de Doctorado. [En línea]. Disponible en: <http://www.lpi.tel.uva.es/~santi/fuzzy/patrones.pdf> [Consultado: octubre 2010].
- Feyaerts, F., and L. van Gool, 2001. Multi-spectral vision system for weed detection. *Pattern Recognit. Lett.* 22: 667-674.
- Gao, Q., Y. Zhao, and Y. Lu, 2008. Despeckling SAR images using stationary wavelet transform combining with directional filter banks, *Appl. Math. Comput.* 205: 517-524.
- Gée, Ch., J. Bossu, G. Jones, and F. Truchetet, 2008. Crop/weed discrimination in perspective agronomic images. *Comput. Electron. Agric.* 60:49-59.
- Gnanadurai, D., V. Sadasivam, J. Paul Tiburtius Nishandh, L. Muthukumaran, and C. Annamalai, 2009. Undecimated double density wavelet transform based speckle reduction in SAR images. *Comput. Electr. Eng.* 35: 209-217.
- González, R., and R. Woods. *Digital Image Processing*, 3rd Edition, Pearson Education-Prentice Hall, 2008, Upper Saddle River, NJ, USA.
- Haralick, R.M., K. Shanmugan, and I. Dinstein, 1973. Textural features for image classification. *IEEE Trans. Syst. Man Cybern.* SMC-3: 610-621.
- Haralick, R.M., and L.G. Shapiro, 1992. *Computer and robot vision*. New York: Addison-Wesley.
- Hemming J., T. Rath, 2001. Computer-vision based weed identification under field conditions using controlled lighting. *Comput. Electr. Eng.* 78:233-243.

- IEEE Std. 610.41990. IEEE Standard Glossary of Image Processing and Pattern Recognition Terminology. The Institute of Electrical and Electronics Engineers, Inc., New York, 1990.
- Ishak, A.J., A. Hussain, and M. Marzuki, 2009. Weed image classification using Gabor wavelet and gradient field distribution. *Comput. Electron. Agric.* 66:53-61.
- Jain, A., and D. Zongker, 1997. Feature selection: evaluation, application, and small sample performance. *IEEE Trans. Pattern Anal. Mach. Intell.* 19: 153-158.
- Jain , A.K. Fundamentals of Digital Image Processing. Prentice Hall, 1989
- Jensen, J.R., 1996. Introductory Digital Image Processing: A Remote Sensing Perspective. Prentice Hall, New Jersey, 316 pp.
- Kavdir, I. 2004. Discrimination of sunflower, weed and soil by artificial neural networks. *Comput. Electron. Agric.* 44:153-160.
- Kiani, S., Z. Azimifar, S. Kamgar, 2010. Wavelet-Based Crop Detection and Classification, Proceedings of the 18th Iranian Conference on Electrical Engineering (ICEE), pp. 587-591.
- Mallat, S. G., 1989. A theory for multiresolution signal decomposition: the wavelet representation, *IEEE Trans. Pattern Anal. Mach. Intell.* 11: 674-693.
- Manian, V., and R. Vasquez, 1998. Scales and rotated texture classification using a class of basis functions, *Pattern Recognit.* 31:1937-1948.
- Martin B., B., and A. Sanz. Redes neuronales y sistemas borrosos. Alfaomega, 3ra edición, 2007.

- Méndez, J., J.H. Riveira, y J.S. Mejía, 2010. Extracción de características de textura para cotejo de proyectiles en balística. *Scientia et Technica*. XVI: 229-233.
- Misiti, M., and G. Misiti, 1996. Oppenheim, J.-M. Poggi, *Wavelet Toolbox User's Guide (For Use with Matlab)*. The MathWorks Inc., 1996.
- Mojsilovic, A., M. V. Popovic, and D. M. Rackov, 2000. On the selection of an optimal wavelet basis for texture characterization, *IEEE Trans. Image Process.* 9: 2043-2050.
- Moltoni, A.F., and L. Moltoni, 2005. Pulverizacion selectiva de herbicidas: implicancias tecnológicas y económicas de su implementación en la Argentina. INTA. Instituto de Ingeniería Rural.
- Nakariyakul, S., y P. Casasent, 2009. An improvement on floating search algorithms for feature subset selection. *Pattern Recognit.* 42:1932-1940
- Nason, G.P., and B.W. Silverman, 1994. The discrete wavelet transform. *S. J. Comp. Graph. Statist.* 3:163-191.
- Onyango, C. M. y J. A. Marchant, 2003. Segmentation of row crop plants from weeds using colour and morphology. *Comput. Electron. Agric.* 39:141-155.
- Pérez, A. J., F. López, J. V. Benlloch, and S. Christensen, 2000. Colour and shape analysis techniques for weed detection in cereal fields. *Comput. Electron. Agric.* 25: 197-212.
- Persson, M. and B. Åstrand, 2008. Classification of crops and weeds extracted by active shape models. *Biosystems Eng.* 100:484-497.

- Piron, A., V. Leemans, O. Kleynen, F. Lebeau and M.-F. Destain, 2008. Selection of the most efficient wavelength bands for discriminating weeds from crop. *Comput. Electron. Agric.* 62:141-148.
- Pudil, P., J. Novovicová, and J. Kittler, 1994. Floating search methods in feature selection, Department of Electronic and Electrical Engineering, *Pattern Recognit. Lett* 15: 1119-1125.
- Ribeiro, A., C. Fernández-Quintanilla, J. Barroso, and M.C. García-Alegre, 2005. Development of an image analysis system for estimation of weed, in: *Proceedings of the 5th European Conference on Precision Agriculture (5ECPA)* pp. 169-174.
- Rosales, R. E., T. Medina, E. Contreras, L.M. Tamayo, y V. Esqueda. 2002. Manejo de maleza en maíz, sorgo y trigo bajo labranza de conservación. INIFAP-CIRNE. Campo Experimental Río Bravo. Folleto Técnico 24. Tamaulipas, México. 81p.
- Shatadal, P., D.S. Jayas and Bulley, N.R., 1991. Fourier and spatial domain analysis of image texture. In: *Automated agriculture for the 21st century. Proceedings of the 1991 symposium, Chicago, Illinois. American Society of Agricultural Engineers*, pp. 36-41.
- SIAP, 2010. Avance de siembras y cosechas. [En línea]. Disponible en: http://www.siap.gob.mx/index.php?option=com_wrapper&view=wrapper&Itemid=346. [Consultado: agosto 2010].
- Siddiqi, M. H., W. Ahmad, I. Ahmad, 2008. Weed Classification Using Erosion and Watershed Segmentation Algorithm. *Innovations and advanced Techniques in Systems, Computing Sciences and Software Engineering*, 366-369.
- Søgaard, H.T. 2005. Weed Classification by Active Shape Models. *Biosystems Eng.* 91: 271-281.

- Soares, W. L., and M. F. de Souza Porto, 2009. Estimating the social cost of pesticide use: An assessment from acute poisoning in Brazil, *Ecol. Econ.* 68: 2721–2728.
- Swain, P. H. and S. M. Davis, 1978. *Remote sensing: the quantitative approach*. New York: McGraw Hill.
- Tellaeché A., X. P. Burgos-Artizzu, C. Pajares, A. Ribeiro, 2008. A vision-based method for weeds identification through the Bayesian decision theory. *Pattern Recognit.* 41: 521 – 530.
- Tillett, N., T. Hague, and S. J. Miles, 2001. A field assessment of a potential method for weed and crop mapping on the basis of crop planting geometry. *Comput. Electron. Agric.* 32: 229-246.
- Umarani, C., S. Radhakrishnan, and L. Ganesan, 2008. Combined Statistical and Structural Approach for Unsupervised Texture Classification. *International Journal of Imaging science and Engineering (IJISE)*, 2:1934-9955.
- Universia, 2010. La maleza provoca pérdidas en los cultivos. [En línea]. Disponible en: <http://noticias.universia.net.mx/ciencia-nn-tt/noticia/2010/03/24/192507/maleza-provoca-perdidas-cultivos.html> [Consultado: agosto 2010].
- Woebbecke, D.M., G.E. Meyer, K. Von Bargen, and D.A. Mortensen, , 1995. Color indices for weed identification under various soil, residue and lighting conditions. *Transactions of the ASAE.* 38: 259-269.
- Zhang, N., M. Wang, N. Wang, 2002. Precision agriculture—a worldwide overview, *Comput. Electron. Agric.* 36:113-32.
- Zhang, Y., D. Huang, M. Ji, and F. Xie, 2011. Image segmentation using PSO and PCM with Mahalanobis distance. *Expert Syst. Appl.* 38:9036–9040.